



**POLITECHNIKA  
BYDGOSKA**  
im. Jana i Jędrzeja Śniadeckich

**RADA NAUKOWA DYSCYPLINY  
INŻYNIERIA LĄDOWA, GEODEZJA I TRANSPORT**

**ROZPRAWA DOKTORSKA**

**mgr inż. Agnieszka Grzybowska**

**PREDYKCJA WYBRANYCH CECH BETONU  
O NISKIM STOSUNKU WODNO-SPOIWOWYM  
Z WYKORZYSTANIEM SZTUCZNYCH  
SIECI NEURONOWYCH**

***PREDICTION OF SELECTED CONCRETE  
CHARACTERISTICS WITH LOW  
WATER-BINDER RATIO  
USING ARTIFICIAL NEURAL NETWORKS***

DZIEDZINA: NAUKI INŻYNIERYJNO TECHNICZNE  
DYSCYPLINA: INŻYNIERIA LĄDOWA, GEODEZJA  
I TRANSPORT

**PROMOTOR**

PROF. DR HAB. INŻ. ADAM PODHORECKI  
POLITECHNIKA BYDGOSKA IM. JANA I JĘDRZEJA  
ŚNIADECKICH W BYDGOSZCZY

**PROMOTOR POMOCNICZY**

DR INŻ. ŁUKASZ MROZIK  
POLITECHNIKA BYDGOSKA IM. JANA I JĘDRZEJA  
ŚNIADECKICH W BYDGOSZCZY

**Bydgoszcz, rok 2023**



Publikacja wydana na prawach rękopisu



*Pragnę serdecznie podziękować wszystkim osobom,  
które przyczyniły się do powstania niniejszej pracy.*

*Przede wszystkim mojemu Promotorowi i Mentorowi  
Panu prof. dr hab. Adamowi Podhoreckiemu  
za nieocenioną pomoc podczas przygotowania pracy,  
cenne uwagi i sugestie,  
a w szczególności za poświęcony czas*

*oraz*

*Panu dr inż. Łukaszowi Mrozikowi za wsparcie  
merytoryczne i nieskończoną cierpliwość.*

*Chciałam również podziękować Rodzicom,  
którzy stworzyli mi warunki do nauki  
i potrafili zmotywować do  
dalszej pracy.  
Pracę Im właśnie dedykuję.*



## SPIS TREŚCI

1. WSTĘP.....	9
2. WYBRANE INFORMACJE Z ZAKRESU BETONÓW O NISKIM STOSUNKU WODNO-SPOIWOWYM.....	12
2.1. Wprowadzenie.....	12
2.2. Charakterystyka betonów o niskim stosunku wodno-spoiwowym.....	20
2.3. Metody projektowania mieszanek betonowych .....	40
2.4. Podsumowanie .....	54
3. ISTOTA SIECI NEURONOWYCH ZWŁASZCZA W ZASTOSOWANIU DO PROJEKTOWANIA MIESZANEK BETONOWYCH.....	57
3.1. Wprowadzenie.....	57
3.2. Podstawowe zagadnienia związane z sieciami neuronowymi oraz możliwości ich implementacji .....	57
3.3. Sztuczne sieci neuronowe w projektowaniu mieszanek betonowych oraz predykcji cech kompozytu cementowego .....	69
3.4. Podsumowanie .....	81
4. PRZEDMIOT, CEL, TEZY BADAWCZE I ZAKRES PRACY .....	84
5. BADANIA LABORATORYJNE MIESZANEK BETONOWYCH .....	85
5.1. Cel, zakres i metodyka badań laboratoryjnych.....	85
5.2. Wyniki badań laboratoryjnych wybranych właściwości zaczynów, mieszanek i betonów z analizą.....	90
5.3. Podsumowanie .....	117
6. TRENOWANIE SIECI NEURONOWYCH DO PREDYKCJI WYTRZYMAŁOŚCI BETONU .....	118
6.1. Rozważany problem .....	118
6.2. Przyjęcie i klasyfikacja danych oraz projektowanie zbioru uczącego .....	119
6.3. Architektura i nauka sieci neuronowych .....	123
6.4. Predykcja wybranych cech betonu – wytrzymałości na ściskanie .....	133
6.5. Predykcja składu ilościowego mieszanki betonowej.....	143
6.6. Program (algorytm) do predykcji składu mieszanki betonowej .....	161
6.7. Podsumowanie .....	161
7. PREDYKCJA WYTRZYMAŁOŚCI BETONU Z UŻYCIEM SIECI NEURONOWYCH WRAZ Z WALIDACJĄ .....	166
7.1. Rozważany problem (wprowadzenie) .....	166
7.2. Predykcja wytrzymałości zaprojektowanego betonu (walidacja) z użyciem SSN.....	167
7.3. Predykcja składu mieszanki betonowej zaprojektowanego betonu (walidacja) z użyciem SSN.....	168
7.4. Badania laboratoryjne.....	169
7.5. Podsumowanie .....	170
8. ZAKOŃCZENIE .....	171
8.1. Wprowadzenie.....	171
8.2. O osiągniętym celu pracy i udowodnionej tezie badawczej .....	172
8.3. Ważne elementy stanowiące wynik przedmiotowej pracy .....	174
8.4. Kierunki dalszych badań .....	176
LITERATURA.....	178
SPIS RYSUNKÓW.....	199

SPIS TABEL.....	204
STRESZCZENIE .....	205
SPIS ZAŁĄCZNIKÓW .....	207




## 1. WSTĘP

Obiekty betonowe stanowią trwałe i nierozłączny element krajobrazu, bowiem beton jest jednym z najstarszych materiałów sztucznych spośród obecnie stosowanych zarówno w budownictwie, jak i całej technice. Za przyszłością betonu przemawia długa, sięgająca ponad 8000 lat historia oraz jego dalsze, niezmiennie wykorzystanie w czasach współczesnych. Naturalny zatem wydaje się równorzędny postęp w wytwarzanych i wykorzystywanych materiałach oraz rozwój konstrukcji. Beton jest najczęściej stosowanym (ok. 6 mld m<sup>3</sup> rocznie) materiałem pochodzenia antropogenicznego na świecie [1]. Jak donoszą źródła krajowe [2] produkcja betonu w Polsce w 2018 roku sięgała 20 mln m<sup>3</sup>. Rozwój myśli technicznej oraz technologicznej pozwalają na rozwiązywanie coraz bardziej skomplikowanych problemów inżynierskich, umożliwiając kształtowanie konstrukcji w złożonych formach. Szczególnie jest to zauważalne na przestrzeni ostatnich pięćdziesięciu lat w przypadku konstrukcji betonowych, bowiem współczesne projekty umożliwiają nadawanie tym konstrukcjom subtelności oraz lekkości burząc dotychczasowe stereotypy dotyczące masywności. Stosowanie betonów nowych generacji prowadzi do uzyskania szeregu korzyści takich jak: wysoka trwałość (co pozwala na obniżenie kosztów konserwacji i utrzymania konstrukcji), mniejsze gabaryty elementów (dzięki obniżeniu ciężaru własnego nie występuje konieczność zwiększania przekrojów poprzecznych). Uzyskanie odpowiedniej jakości jest możliwe przy zachowaniu ścisłego reżimu technologicznego podczas produkcji mieszanki betonowej oraz pielęgnacji gotowych elementów [3–6]. Niezbędny przy tym jest rozwój technologii, który umożliwi zapewnienie maksymalnej efektywności przy wykorzystaniu materiału. Dlatego poszukiwane są takie składniki mieszanek betonowych, które umożliwią maksymalne wykorzystanie wytrzymałości betonu na ściskanie [7–9]. Tak postawiony cel determinuje konieczność poszukiwania szybkich, efektywnych i maksymalnie dokładnych metod projektowania mieszanek betonowych, co stało się inspiracją do podjęcia rozważanej tematyki.

Rozpatrując tematykę z zakresu technologii betonu często można zetknąć się z krzywą rozwoju betonu [7,10,11], która uwidacznia, iż betony najwyższych wytrzymałości uzyskiwane są przy ekstremalnie niskich stosunkach wodno-spoiwowych. Krzywa ta skłania się ku betonom o wysokich wytrzymałościach, jednak nie determinuje ona jakości uzyskanego materiału. Widoczny jest postęp jakościowy poszczególnych składników betonu oraz rozwój ilościowy jego produkcji (uzależniony od wzrostu demograficznego). Ponadto hiperboidalny rozkład krzywej sugeruje wyczerpanie tendencji wzrostowej osiągniętych wytrzymałości na ściskanie, co może zostać utrzymane dzięki nowym odmianom betonu o podniesionych walorach mechanicznych i użytkowych. Zatem zasadniczy cel badaczy jawi się nie tylko w uzyskaniu wysokiej wytrzymałości na ściskanie, ale i również poprawie innych parametrów kompozytu cementowego. Dlatego betonu wysokiej wytrzymałości i betonu wysokowartościowego (BWW) nie można traktować jako tożsamy, a jedynie jako nachodzące na siebie zbiory, w szczególnym przypadku pokrywające się zakresami. Oba pojęcia zostaną szczegółowo omówione w kolejnych rozdziałach niniejszej pracy.

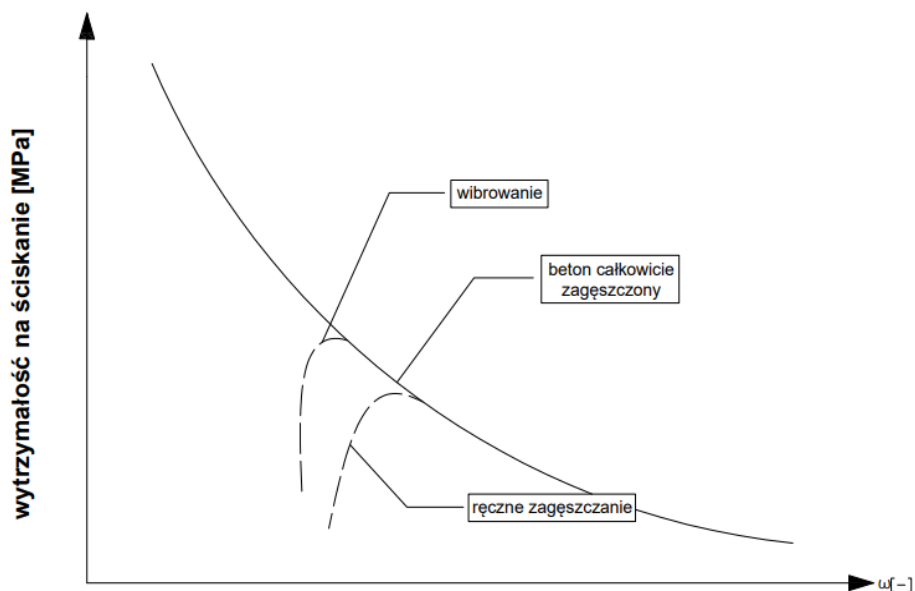
Uzyskane tworzywo o wysokiej wytrzymałości posiada ustabilizowane cechy na odpowiednio wysokim poziomie [12–14]: dobrą urabialność mieszanki betonowej (zachowaną przez okres minimum 1 godziny), wytrzymałość na ściskanie (rys 1.1) wynoszącą co najmniej 60 MPa (55 MPa wg. DIN, 42 MPa w USA), trwałość powiązaną ze szczelnością uzyskaną na drodze odpowiedniej struktury materiału po stwardnieniu.

W zestawie norm europejskich [9N,10N] oraz literaturze przedmiotu [7,11,15] beton wysokiej wytrzymałości definiuje się jako beton o wytrzymałości na ściskanie powyżej klasy C50/60 dla betonów zwykłych i ciężkich oraz powyżej klasy LC 50/55 dla betonów lekkich.



Rysunek 1.1. Kryteria podziału betonów wysokiej wytrzymałości [7,16]

W literaturze przedmiotu [17–26] podaje się, że do wykonania betonu wysokowarściowego niezbędny jest dobór wysokiej jakości komponentów, tj. cementu odpowiedniej klasy, kruszywa o dużej wytrzymałości, dodatków mineralnych oraz wysokoelektywnych domieszek chemicznych. Ponadto poszukiwane jest ekstremum funkcji wytrzymałości, które leży w obszarze niskich stosunków wodno-spoiwowych (rys. 1.2 – nie dotyczy betonów samozagęszczalnych).



Rysunek 1.2. Uogólniona krzywa wytrzymałości betonu na ściskanie w zależności od stosunku wodno-spoiwowego (na podstawie literatury przedmiotu [11,27])

Wykorzystanie odpowiednich składników prowadzi do udoskonalenia cech charakterystycznych betonu, a przede wszystkim do obniżenia porowatości. Uszczelnieniu ulega struktura matrycy cementowej. Niesie to za sobą szereg korzyści [28]:

- wyższa wytrzymałość;
- niższa porowatość;
- niższa nasiąkliwość;
- większa mrozoodporność;
- wyższa odporność na agresję chemiczną;
- dobre warunki ochrony stali.


Dążenie do osiągnięcia powyższych korzyści generuje szereg problemów z projektowaniem betonów wysokowartościowych o wysokich wytrzymałościach, bowiem tradycyjne metody projektowania stosowane do betonów zwykłych okazują się być niewystarczającymi. Szczegółowe uwagi w tym zakresie zostaną podane w dalszej części niniejszej rozprawy.

## 2. WYBRANE INFORMACJE Z ZAKRESU BETONÓW O NISKIM STOSUNKU WODNO-SPOIWOwym

### 2.1. Wprowadzenie

Technologia betonu jest dziedziną, która rozwija się w bardzo szybkim tempie. Liczne modyfikacje składu (np. stosowanie domieszek, dodatków, czy różnego rodzaju włókien) oraz wpływające na strukturę betonu powodują znaczną poprawę jego parametrów. Podkreślić należy, że poszukiwaną, wiodącą właściwością mechaniczną betonu jest wytrzymałość na ściskanie. Proces kształtowania struktury prowadzący do otrzymania betonu o wysokiej wytrzymałości zwiększa szansę na to, że również inne cechy charakterystyczne (np. mrozoodporność, nasiąkliwość, moduł sprężystości, ścieralność i inne) będą polepszone w stosunku do analogicznych, typowych parametrów betonu zwykłego [13,29–31]. Takie kształtowanie struktury odbywać się może poprzez poszukiwanie takiego stosunku wodno-spoiwowego (w/s rozumianego jako stosunek wody i dowolnej kombinacji cementu ze składnikami mineralnymi, w literaturze przedmiotu [29,32,33] oznaczanego jako  $\omega$ ), przy którym wytrzymałość na ściskanie osiągnie swoje ekstremum, a inne parametry zostaną polepszone.

Genezą do określenia skąd wywodzi się beton o niskim stosunku wodno-spoiwowym (w/s) i jak go klasyfikować jest definicja P.C. Aitcina, która konkretnie mówi kiedy mamy do czynienia z betonem wysokowartościowym (BWW). Istotne w tej definicji jest to, że BWW jest takim betonem, w którym jedna lub więcej cech charakterystycznych zostało udoskonalonych poprzez dobór i zastosowanie odpowiednich proporcji i składników. W związku z tym można zauważyć, że nie ma jednego rodzaju betonu wysokowartościowego [17], a więc nie są tożsame definicje betonu wysokowartościowego i wysokiej wytrzymałości. Według literatury krajowej i zagranicznej [11,17,31,32,34–37] BWW otrzymuje się przy bardzo niskich stosunkach wodno-spoiwowych: poniżej 0,35, często około 0,25, a sporadycznie nawet 0,20 (rys. 2.1). Ponadto nierozłącznie z niskim stosunkiem w/s związana jest konieczność stosowania nowoczesnych domieszek upłynniających [16,38,39]. W przypadku betonów o ekstremalnych wytrzymałościach konieczne jest także zastosowanie dodatków mineralnych, zwłaszcza pyłu krzemionkowego [35,40–43] oraz stosowanie specjalnych metod zagęszczania takich jak np. wibroprasowanie, prasowanie, odwadnianie próżniowe [11]. W literaturze przedmiotu stwierdzono, że beton wysokowartościowy nie jest materiałem rewolucyjnym, lecz wyrazem rozwoju innych grup betonów i stanowi coraz częściej stosowaną grupę kompozytów cementowych [6,7,11,13,44,45].



Rysunek 2.1. Wzrost wytrzymałości na ściskanie w zależności od stosunku w/c [10]

Ze względu na powyższe, zasadne staje się projektowanie mieszanek betonowych ukierunkowanych na dobór optymalnego stosunku w/s. W niniejszej pracy będzie rozważany właśnie taki rodzaj betonu (o niskim stosunku wodno-spoiwowym), bowiem jest to ważna grupa kompozytów cementowych, prężnie rozwijana, o szerokim zastosowaniu [1,7,10,39,44,46,47] na przykład w konstrukcjach wysokich, mostownictwie czy drogownictwie (tab. 2.1). Powszechność stosowania BWW warunkowana jest przede wszystkim [16]:

- niską trwałością konstrukcji z betonów zwykłych w warunkach coraz bardziej skażonego środowiska;
- małą odpornością ogniową konstrukcji stalowych oraz dużymi kosztami ich zabezpieczeń;
- relatywnie wyższymi cenami konstrukcji stalowych w stosunku do konstrukcji żelbetowych.

Pod względem ekonomicznym koszt wytworzenia BWW jest wyższy w porównaniu do betonu zwykłego, aczkolwiek może być on skompensowany przez [30]:

- zmniejszenie zapotrzebowania na beton nawet o 30% ze względu na zmniejszenie przekrojów poprzecznych (rys. 2.3);
- zmniejszenie zapotrzebowania na stal, szczególnie w odniesieniu do elementów ściskanych, co spowodowane jest wzrostem wytrzymałości na ściskanie betonu;
- możliwości szybszego demontażu i przeniesienia deskowania, co spowodowane jest znacznym przyrostem wczesnej wytrzymałości. Dzięki temu możliwa jest szybsza i efektywniejsza realizacja inwestycji;
- zmniejszenie kosztów utrzymania obiektu poprzez zwiększenie jego trwałości.

Tabela 2.1. Przykłady wymagań stawianym BWW w zależności od przeznaczenia [48]

Rodzaj konstrukcji	Właściwości w porównaniu do zwykłych betonów
mosty	większe: wczesna i końcowa wytrzymałość, urabialność, trwałość; mniejsze: odkształcalność
konstrukcje morskie	większe: trwałość, wytrzymałość na ściskanie i ścinanie, urabialność, odporność na uderzenia oraz na ścieranie
budynki wysokie	większe: wytrzymałość na ściskanie i ścinanie, urabialność, wytrzymałość wczesna; mniejsze: odkształcalność
tunele	większe: trwałość, wytrzymałość na ściskanie, wczesna wytrzymałość, szczelność
nawierzchnie drogowe	większe: wytrzymałość na ścieranie i uderzenia, odporność na cykle zamrażania i odmrażania, wytrzymałość na ścinanie, trwałość, urabialność
elementy prefabrykowane	większe: wytrzymałość wczesna, wytrzymałość na ściskanie i ścinanie, urabialność; mniejsze: masa konstrukcji
elementy odwodnienia	większe: trwałość i odporność na ścieranie, wytrzymałość na ściskanie, urabialność


a)




b)



Rysunek 2.2. Przykłady obiektów zrealizowanych przy zastosowaniu BWW: a) Petronas Towers; b) Burj Khalifa [7]



Rysunek 2.3. Przekrój poprzeczny słupów o równoważnej nośności przy różnej wytrzymałości betonu na ściskanie [16]



Rysunek 2.4. Ciężar 1m słupa równoważnej nośności w zależności od wytrzymałości betonu na ściskanie [16]

Jak stwierdza Aitcin [44] ustalenie systematyki betonów wysokowartościowych jest funkcją poglądów autora. Nie istnieje zatem jeden zunifikowany podział, aczkolwiek wyodrębnić można kierunki zastosowań BWW na podstawie wymagań, które muszą spełniać [16]

- narażony na ścieranie erozyjne;
- odporny na ścieranie;
- z kruszywami reaktywnymi;
- o zredukowanym cieple hydratacji;
- odporny na korozję chemiczną;
- natryskowe – torkret;
- o wysokich wczesnych wytrzymałościach;
- „in situ” o wysokiej wytrzymałości;
- prefabrykowany o wysokiej wytrzymałości;
- do budowli morskich i przybrzeżnych;
- samozagęszczalne mieszanki betonowe.


#### Beton narażony na ścieranie pochodzenia erozyjnego

Jedne spośród pierwszych znaczących zastosowań BWW, mających na celu podniesienie odporności na ścieranie pochodzenia erozyjnego, zostało wdrożone podczas naprawy tamy Kinzua (Pensylwania, USA), na skutek wykonania szczegółowych badań laboratoryjnych [49]. Wytrzymałość betonu na ściskanie, którą uzyskano przy zastosowaniu 18% udziału pyłów krzemionkowych wynosiła 86 MPa. W 1990 roku (po 7 latach eksploatacji) oceniono, iż stopień uszkodzeń elementów poddanych naprawie jest relatywnie niższy, w porównaniu do elementów wykonanych ze standardowych kompozytów cementowych. Kolejny przykład zastosowania takiego rodzaju betonu (narażonego na uszkodzenia erozyjne) stanowią elementy wbudowane w celu naprawy dolnego sklepienia rzeki Los Angeles. Wytrzymałość na ściskanie oscylowała w granicach 55÷72 MPa, przy czym udział mikrokrzemionki w betonie był zmienny. Jako kolejne przykłady zastosowań tego rodzaju betonu można przytoczyć naprawy: jazów spływowych w Nowym Meksyku oraz Idaho czy tuneli Lowell Creek na Alasce [50].

#### Beton odporny na ścieranie

Cecha ta jest niezwykle istotna w odniesieniu do różnego rodzaju nawierzchni [51]. Najszersze zastosowanie beton wysokowartościowy, zorientowany na podwyższonej ścieralności, znalazł przy realizacji posadzek przemysłowych. Równie ważną grupę zastosowania stanowią nawierzchnie drogowe, narażone na zintensyfikowaną degradację spowodowaną ścieraniem. W literaturze przedmiotu [16] stwierdzono, że nawierzchnie wykonane z betonów wysokowartościowych (z zawartością mikrokrzemionki na poziomie 7-10%) charakteryzują się odpornością na ścieranie 2 do 3 razy większą aniżeli tradycyjne nawierzchnie asfaltowe. Nawierzchnie betonowe stanowią coraz szerzej stosowaną alternatywę dla typowych rozwiązań bazujących na mieszankach mineralno-asfaltowych [52,53]. Prócz podwyższonej odporności na ścieranie, pożądane są tutaj inne cechy, takie jak choćby odporność na agresję chemiczną (ze względu na środki odladzające). Ponadto powszechnie stosowane są drobnowymiarowe elementy wibroprasowane, takie jak kostka brukowa [54] oraz podkłady kolejowe (narażone na ścieranie piaskiem). Wskazać należy również w tym miejscu nawierzchnie o szczególnym zastosowaniu, takie jak pasy startowe podlegające silnym obciążeniom. Zatem prócz ścieralności, determinantą przy projektowaniu składu mieszanki betonowej staje się wytrzymałość na ściskanie sięgająca do 140 MPa [55]. Na rysunku 2.5 zaprezentowano zależność stopnia ścieralności od wytrzymałości betonu.





Rysunek 2.5. Ścieralność w funkcji wytrzymałości betonu [16]

#### Beton z kruszywami reaktywnymi

Powszechnie funkcjonującą nazwą tej grupy betonów są betony RPC (Reactive Powder Concrete), czyli betony z proszkiem reaktywnym. Nazewnictwo takie spowodowane jest ograniczeniem maksymalnego wymiaru kruszywa do  $d \leq 600 \mu\text{m}$  oraz dodatkiem proszków reaktywnych [56,57]. Charakterystyczne dla tego rodzaju betonu jest dozowanie cementu na poziomie  $1000 \text{ kg/m}^3$  oraz wysoka zawartość pyłu krzemionkowego –  $300 \text{ kg/m}^3$ . Eliminacja kruszywa grubego z matrycy cementowej prowadzi do minimalizacji, inicjalizacji i propagacji mikrospękań, wynikających z mechanicznych oraz środowiskowych uwarunkowań. Znamienne jest również stosowanie mikrowłókien stalowych (o długości ok. 12-13 mm). Omawiany typ betonu został zastosowany przy budowie dachu oraz fasady stadionu Jean Bouin (Paryż) [58].

#### Beton o zredukowanym cieple hydratacji

Jak już wspomniano, BWW charakteryzuje się dozowaniem cementu na wysokim poziomie, co w konsekwencji prowadzi do zintensyfikowanej reakcji egzotermicznej, powodującej samoociepniecie betonu. Zastąpienie części cementu mikrokrzemionką pozwala na minimalizację tego zjawiska, bowiem ciepło emitowane podczas hydratacji cementu może spowodować spadek końcowej wytrzymałości na ściskanie nawet o 15% [59]. Przykłady zastosowań tego betonu w praktyce stanowią most w Tjorn (Szwecja) czy tama Alta (Norwegia).

#### Beton odporny na korozję chemiczną

Uszczelnienie struktury kompozytu cementowego poprzez zastosowanie mikrokrzemionki powoduje zmniejszenie przepuszczalności betonu, a co za tym idzie podwyższeniu ulega odporność na agresję chemiczną. Wówczas zawartość pyłów krzemionkowych waha się w granicach 10-18% (w stosunku do masy cementu). Ze względu na tą cechę, tego typu betony pożądane są przy realizacjach szczególnie narażonych na agresję chemiczną: nawierzchnie drogowe (w tym parkingi), posadzki przemysłowe w zakładach produkcji spożywczej czy chemicznej, zbiorniki na ciecze, bądź konstruk-


cje narażone na ekspansję wody morskiej. Szczególny przykład stanowi statek „Crete Joist” (Norwegia), poddawany cyklicznym oddziaływaniom termicznym oraz agresji chlorków pochodzących z wody morskiej [51,60]. Elementy statku zostały wykonane z betonu o wytrzymałości na ściskanie rzędu 75 MPa (burty) oraz 120 MPa (żebra). Pomimo ponad sześćdziesięcioletniego narażenia na wspomniane czynniki korozja betonu spowodowana agresją chemiczną przebiega niezwykle powolnie.

#### Betony natryskowe – torkret

Przykładowo przytoczyć tutaj można stosowanie mieszanki BWW o podwyższonej płynności, przeznaczonej do iniekcji kabli w elementach podlegających sprężaniu. Zastosowanie mikrokrzemionki pozwala na zwiększenie przyczepności pomiędzy kablami i konstrukcją, co wiąże się z efektywniejszym i szybszym sprężaniem kabli. Betony tego typu są szeroko stosowane do realizacji tuneli (Austria, Szwajcaria) [61,62].

#### Betony o wysokich wczesnych wytrzymałościach


Cecha ta jest niezwykle pożądana we wszystkich typach konstrukcji, zarówno prefabrykowanych, jak i tych wykonywanych monolitycznie, bowiem umożliwia szybszą realizację obiektu. Przykład stanowić może lotnisko w Montealu, do którego budowy użyto 3000 prefabrykowanych elementów [15,62]. Zastosowanie 15% dodatku pyłu krzemionkowego pozwoliło na uzyskanie betonu o wytrzymałości rzędu 48 MPa, po 18 godzinach od wykonania elementu. Przyrost wytrzymałości BWW w porównaniu do konwencjonalnych betonów zilustrowano rysunkiem 2.6.



Rysunek 2.6. Wzrost wytrzymałości mieszanki w funkcji czasu [16]

#### Beton „in situ” o wysokiej wytrzymałości

Betony klasyfikujące się w tej grupie wykorzystywane są przede wszystkim do wznoszenia budynków wysokościowych. Jak już wspomniano, uwarunkowane jest to możliwością zmniejszenia przekrojów poprzecznych, więc istotnie rzutuje na koszty samej budowy; pozwala również na wygospodarowanie dodatkowych pięter, co nabiera szczególnego znaczenia przy zatłoczonych metropoliach świata [46]. Dążenie do osiągnięcia jak najwyższej wytrzymałości betonu na ściskanie staje się przyczyną rozwoju nowych grup betonów ukierunkowanych na tą cechę (rys. 2.7).



Rysunek 2.7. Porównanie zależności naprężenie-odkształcenie dla różnych betonów [7]

#### Elementy z betonu prefabrykowanego o wysokiej wytrzymałości

W odniesieniu do prefabrykacji, najbardziej pożądaną cechą jest możliwość szybkiego rozformowania elementów, dzięki czemu przyspieszeniu ulega cykl produkcyjny. Ponadto zmniejszenie gabarytów przekrojów w istotny sposób ułatwia transport oraz montaż, co jest szczególnie istotne w budynkach wysokich. Prefabrykaty wykonane z BWW znajdują zastosowanie w różnych gałęziach przemysłu, począwszy od realizacji nawierzchni drogowych [54], poprzez rozwiązania budownictwa mieszkaniowego (półprefabrykowane stropy, słupy i ściany w budynkach prefabrykowanych) i przemysłowego (fundamenty pod maszyny, płyty dachowe, ustroje ramowe hal). Ponadto implikacja prefabrykowanych belek strunobetonowych w drogowych obiektach inżynierskich pozwala na oszczędności rzędu 40% [16]. Szczęólnego wymiaru prefabrykacja nabiera w odniesieniu do budowy tuneli, bowiem składowe stanowią tutaj setki elementów. Przykład stanowiąc mogą: tunel kolei francuskiej TGV, do realizacji którego użyto około 50 tys. prefabrykatów betonowych o wytrzymałości na ściskanie 57 MPa oraz trzy tunele znajdujące się 90 m pod lustrem wody kanału La Manche. Do ich wykonania została zaprojektowana mieszanka betonowa o stosunku wodno-spoiwowym od 0,32 do 0,35, a końcowa wytrzymałość betonu na ściskanie wynosiła 45-75 MPa w zależności od odcinka. Szczęólną grupę zastosowań stanowią obudowy skarbców oraz reaktorów jądrowych, gdzie uzyskuje się betony o wytrzymałościach rzędu 140 MPa [55].

#### Betony do budowy morskich i przybrzeżnych

Obiekty wykonywane z tych betonów stanowią grupę wyjątkowo narażoną na agresję chemiczną w postaci jonów chlorkowych, pochodzących z wody morskiej. Dzięki

szczelniejszej strukturze matrycy cementowej, aniżeli w przypadku betonów zwykłych, podniesieniu ulega ochrona przed penetracją jonów chlorkowych [60]. Przykładami konstrukcji mogą być obiekty mostowe wzniesione na jeziorze Słonym, betonowe elementy elektrowni morskich czy platformy przybrzeżne. Dla tych wzniesionych na Morzu Północnym zastosowano beton o wytrzymałości na ściskanie 75 MPa, przy udziale mikrokrzemionki na poziomie 3%. Istotnym kryterium przy opracowywaniu składu była urabialność mieszanki betonowej, ze względu na zagęszczenie zbrojenia sięgające miejscowo 1000 kg/m<sup>3</sup> [63].

#### Samozagęszczalne mieszanki betonowe

Odpowiednia kompozycja składu mieszanki betonowej pozwala na uzyskanie mieszanki o podwyższonej ciekłości, eliminując tym samym konieczność mechanicznego zagęszczenia. Uzyskany kompozyt charakteryzuje się brakiem widocznych defektów strukturalnych, przez co beton tego typu predestynowany jest do wykonywania obiektów szczególnych, o unikalnych i skomplikowanych formach architektonicznych lub fasad, od których oczekuje się najwyższej jakości.

W oparciu o przedstawione cechy oraz podane przykłady zastosowań można zdefiniować następujące korzyści wynikające ze stosowania betonów wysokowartościowych [28]:

- wyższa wytrzymałość, prowadząca do smuklejszych i lżejszych konstrukcji (rys. 2.3);
- szybsza stabilizacja strat sprężenia i tolerancji montażowych;
- nowe możliwości konstrukcyjne, zwłaszcza w ustrojach zespolonych i obiektach pracujących w środowisku agresywnym;
- wysoka wytrzymałość „młodego” betonu umożliwiająca wczesne obciążanie konstrukcji, a zarazem przyspieszenie realizacji obiektu;
- możliwość dobierania urabialności i czasu przerobu mieszanki stosownie do wymagań transportu i układania betonu;
- zmniejszenie zużycia materiałów i wysoka estetyka obiektów;
- wysoka trwałość wznoszonych obiektów.

Wskazać należy także w tym miejscu mankamenty wynikające z modyfikacji składu mieszanki, ukierunkowane na eliminację niekorzystnych cech [64]:

- zwiększenie wytrzymałości materiału, jego trwałości i urabialności może pogorszyć inne właściwości mechaniczne i użytkowe, np. zwiększenie wytrzymałości na ściskanie może łączyć się ze zwiększeniem kruchości materiału i zmniejszeniem krytycznych wartości mechaniki pęknięcia, a lepsza urabialność może wiązać się z pogorszeniem trwałości betonu;
- zwiększone zużycie cementu intensyfikuje problem skurczu.

Oczekiwania stawiane wobec wyrobów generują potrzebę eliminacji wystąpienia możliwych defektów, rozpoczynając już od etapu projektowania. Staranny dobór jakościowy komponentów jest bowiem konieczny do uzyskania pożądanych właściwości betonu [29,65].


## **2.2. Charakterystyka betonów o niskim stosunku wodno-spoiwowym**


Wprowadzenie do składu mieszanki dwóch składowych nieobecnych w składzie betonów zwykłych, tj. mikrokrzemionki oraz superplastyfikatora, wpływa na radykalną poprawę właściwości betonu, prowadząc do otrzymania betonu wysokowartościowego.

Modyfikacje właściwości mogą odbywać się również na drodze wprowadzenia do struktury kompozytu mikrobrojenia w postaci syntetycznych lub stalowych włókien [66]. Ponadto, jak już wcześniej wspomniano, skład betonów wysokowartościowych spośród innych grup betonów zwykłych wyróżnia się tym, że (rys. 2.7):


- zwiększeniu uległa zawartość frakcji drobnoziarnistych pochodzących od cementu, pyłów krzemionkowych oraz popiołów lotnych;
- stosuje się niższy stosunek wodno-spoiwowy;
- minimalizuje się zawartość kruszywa grubego w łącznym bilansie objętościowym;
- ogranicza się wymiar ziaren, co w połączeniu z superplastyfikatorami pozwala na uzyskanie wysokiej urabialności.

Powyższe ograniczenia dotyczące kruszywa oraz cementu istotne są z punktu widzenia szczelności uzyskanego stosu okrucowego, a także ewentualnej koncentracji naprężeń. Wymiar ziaren mikrokrzemionki jest dwa razy niższy aniżeli cementu, zatem to on stanowić będzie dolną granicę uziarnienia. Charakterystyczne dla betonów wysokowartościowych ograniczenie stosunku wodno-spoiwowego wymaga doprecyzowania. Według niektórych autorów [11] stosunki w/s powinny kształtować się na poziomie 0,2-0,35. Na potrzeby niniejszej rozprawy przyjęto, iż niski stosunek wodno-spoiwowy to taki, który jest mniejszy od wodożądności normowej użytego cementu. Dla wodożądności normowej otoczka wodna na ziarnach cementu przyjmuje grubość o wartości minimalnej, przy przestrzeniach międzyziarnowych całkowicie wypełnionych wodą (wynika to ze zjawiska wiązania wody błonkowej siłami napięcia powierzchniowego). Po przekroczeniu granicy wodożądności normowej (zmniejszeniu stosunku wodno-spoiwowego) zbyt mała ilość wody determinuje konieczność stosowania domieszek upłynniających, na skutek występujących problemów z urabialnością.





Rysunek 2.8. Porównanie składów betonów w zależności od przeznaczenia: NC – beton normalny; HPC – beton wysokowartościowy; UHPC – beton ultrawysokowartościowy; RPC – beton z proszków reaktywnych [11]




Rysunek 2.9. Struktura betonu wysokowartościowego [31]


Ze względu na zmniejszenie stosunku w/s w porównaniu z betonami zwykłymi, dla betonów wysokowartościowych charakterystyczne jest zwiększenie zawartości cementu do ilości przekraczającej  $400 \text{ kg/m}^3$ . Optymalna ilość wynika z konieczności zapewnienia

nia właściwego dystansu pomiędzy ziarnami kruszywa grubego, przy zastosowaniu domieszki superplastyfikującej. Udział cementu może być zredukowany poprzez zastąpienie jego części mikrowypełniaczem w postaci pyłu krzemionkowego. Podobny efekt można uzyskać stosując inne pucolanowe dodatki, takie jak popioły lotne [67] czy pyły bazaltowe [68]. Zarówno do betonów wysokowartościowych, jak i zwykłych stosowane są cementy portlandzkie, jednak dla tych pierwszych należy zwrócić szczególną uwagę na wysoką jakość oraz powtarzalność składu. Konieczny jest staranny dobór właściwości cementu oraz jego zawartości, bowiem istotnie rzutuje to na omówione wcześniej parametry betonu wysokowartościowego. Preferowaną cechą cementu jest wysoki stopień rozdrobnienia, choć wartość tego parametru nie została w sposób jawny zdefiniowana [11,32]. Ponadto, ze względu na upłynnianie mieszanki, istotne jest utrzymanie ilości glinianu trójwapniowego  $C_3A$  na niewielkim poziomie (<10%), jednocześnie zachowując jak najwyższą zawartość faz krzemianowych (zwłaszcza alitu). Dla cementów stosowanych do produkcji betonów wysokowartościowych optymalna mialkość cementu oscyluje wokół  $4000 \text{ cm}^2/\text{g}$  [11].

Istotną cechą charakteryzującą kruszywo użyte do produkcji BWW jest przyczepność jego pomiędzy ziarnami kruszywa, a stwardniałym zaczynem cementowym, bowiem na styku tych dwóch faz dochodzi do inicjacji mechanizmu pęknięcia. Zatem ziarna kruszywa powinny być zbliżone do izometrycznej, sześcienniej bryły tak, aby uzyskać maksymalną powierzchnię właściwą (w celu polepszenia przyczepności mechanicznej zaczynu). Eliminacji powinny ulegać ziarna wydłużone lub spłaszczone. Ze względu na powyższe, do produkcji betonów wysokowartościowych zalecane są kruszywa łamane, które cechują się lepszą przyczepnością do zaczynu aniżeli kruszywa otoczkowe, które z kolei ze względu na mniejszą powierzchnię właściwą zapewniają lepszą urabialność [69]. Obok powierzchni właściwej, na przyczepność zaczynu rzutuje mineralogiczny skład kruszywa (rys 2.10). Zabiegi mające na celu poprawę zwiększenia przyczepności kruszyw mineralnych do zaczynu, np. w postaci zwiększenia ilości zastosowanego cementu nie gwarantują uzyskania zamierzonego celu.



Rysunek 2.10. Wytrzymałość na ściskanie betonów wysokowartościowych z różnym kruszywem grubym [69]



Rysunek 2.11. Przyczepność pomiędzy stwardniałym zaczynem, a różnymi typami kruszyw przy stosunku  $w/s = 0,35$  [70]

Jak można zauważyć na podstawie rysunków 2.9 oraz 2.10, ziarna kruszyw węglanowych cechujące się wytrzymałością  $R_{skaly}$  równą 120 MPa, wykazują lepszą przyczepność do zaczynu aniżeli ziarna kruszyw bazaltowych o wytrzymałości  $R_{skaly}$  równej 400 MPa. W konsekwencji wyższe charakterystyki wytrzymałościowe uzyskano dla pozornie słabszego kruszywa. Zatem przyczepność staje się kwestią bardzo istotną przy komponowaniu składu kruszywa mieszanki betonowej BWW. Ponadto pryncypialna jest rola uziarnienia, bowiem krzywa uziarnienia dobranego kruszywa powinna przebiegać w sposób ciągły. Jest to ważne ze względu na osiągnięcie pożądanej urabialności mieszanki betonowej oraz wysokiej wczesnej wytrzymałości betonu na ściskanie. Wskazane jest, aby kruszywo drobne (piasek) oraz kruszywo grube były tego samego rodzaju, przy czym dąży się do uzyskania krzywej przesiewu mieszczącej się w obszarze krzywych granicznych [70]. Zastosowany piasek powinien być mineralogicznie jednorodny (pozbawiony z powierzchni miki i gliny), a jego średnica ziaren powinna oscylować w granicach 2 mm, bowiem korzystna jest eliminacja frakcji miałkich (do 0,25 mm) ze względu na wysoką zawartość cementu oraz mikrokrzemionki. Uzupelnienie stosu okruchowego najdrobniejszymi frakcjami może ograniczyć ryzyko segregacji składników, wycieku wody zarobowej, co może być przydatne np. w przypadku betonów samozgęszczalnych.


Czynnikiem najbardziej różnicującym budowę wewnętrzną betonu zwykłego od betonów modyfikowanych jest zastosowanie dodatków, tj. mikrokrzemionki, jak i domieszek w postaci plastyfikatorów i superplastyfikatorów, czy też ewentualne włókien stalowych lub syntetycznych, korygujących parametry matrycy betonu [71]. Domieszki wprowadza się w celu modyfikacji cech technologicznych mieszanki betonowej lub zaprawy, a także zaczynu [72]. Domieszki określa się jako produkt chemiczny dodawa-




ny do składu w relatywnie niewielkich ilościach (zwykle 2-4%, maksymalnie 5%) w porównaniu do masy cementu. Składnik ten, ze względu na jego niewielki udział, jest pomijany przy ogólnym bilansie objętościowym elementów mieszanki. W ogólności celem stosowania domieszek jest uzyskanie pożądanych modyfikacji, stanowiących ulepszenie parametrów mieszanki betonowej i/lub stwardniałego betonu [11]. Superplastyfikatory (domieszki upłynniające) umożliwiają osiągnięcie ciekłej konsystencji mieszanki przy wykorzystaniu ilości wody zarobowej zbliżonej, a nawet niższej od tej, która wynika z minimum niezbędnego do pełnej hydratacji cementu. Dzięki superplastyfikatorom możliwa jest poprawa urabialności mieszanki betonowej przy zachowaniu stałego stosunku w/s bądź możliwa jest redukcja stosunku w/s przy utrzymaniu urabialności mieszanki na stałym poziomie. Efekt taki uzyskuje się poprzez pełniejszą hydratację cementu (zwiększeniu ulega powierzchnia jego ziaren na skutek dezagregacji zlepionych konglomeratów). W procesie tym zmniejszona zostaje ilość wody zarobowej oraz skróceniu ulega czas wiązania, co przekłada się na wysoką wytrzymałość wczesną. Domieszki upłynniające poprzez korzystny wpływ na matrycę cementową (zmniejszenie porowatości oraz uszczelnienie struktury) przyczyniają się do zwiększenia mrozoodporności betonu oraz jego odporności na agresję [72]. Mechanizmy działania superplastyfikatorów można podzielić na [39,72,73]:

- elektrostatyczny – polega na tym, że ziarna cementu zostają otoczone ujemnymi ładunkami dzięki czemu wzajemnie się odpychają;
- smarny – polega na tym, że ziarna cementu zostają pokryte warstwą smarną dzięki czemu zmniejsza się tarcie wewnętrzne w świeżej mieszance betonowej;
- steryczny – dzięki któremu na powierzchni ziaren cementu ukształtowany zostaje łańcuch polimeru, który zapobiega zbliżaniu się do siebie ziaren cementu;
- hydrofilowy – przekłada się na zmniejszenie napięcia powierzchniowego wody umożliwiając tym samym zwilżenie powierzchni zdezagregowanych ziaren cementu.

Superplastyfikator osadza się na ziarnach cementu dzięki czemu ładunek tych ziaren staje się jednoimienny (dochodzi do wzajemnego odpychania ziaren) [74]. Na rysunku 2.12 przedstawiono współdziałanie mechanizmów – elektrostatycznego i sterycznego.



Rysunek 2.12. Współdziałanie mechanizmów: 1) elektrostatycznego i 2) sterycznego [73]



Rysunek 2.13. Mechanizm smarny: a) zaglomerowane ziarna cementu; b) ziarna cementu pokryte warstewkami smarnymi; c) rozproszone ziarna cementu [73]

Na rysunku 2.13 przedstawiono schemat powstawania jednomolekularnej warstwy smarującej, która ułatwia poślizg stałych cząstek mieszanki, a co za tym idzie minimalizuje tarcie wewnętrzne i zwiększa ciekłość mieszanki betonowej. Literatura przedmiotu nie określa ilościowo zakresu efektywności.

Do badań zostały wykorzystane dodatki typu II [28] w postaci pyłów krzemionkowych pozyskanych z Huty Łaziska. Jest to amorficzny materiał, który powstaje podczas wytopienia metalicznego krzemu w piecach łukowych. Cząstki pyłu krzemionkowego można określić jako idealnie sferyczne (średnica  $0,1 \mu\text{m}$ ) o powierzchni właściwej oscylującej około  $20 \text{ m}^2 / \text{g}$ , zatem ich rozmiar jest blisko 100 – krotnie mniejszy od ziaren cementu. Intensyfikacja reakcji pucolanowej (zachodzącej z wodorotlenkiem wapnia) jest zależna od ilości zastosowanego dodatku, a w jej efekcie powstaje żel uwodnionych krzemianów wapnia. Uzyskany produkt jest jednorodny, trwały (tworzy matrycę ściśle przylegających do siebie produktów hydratacji). Obecność pyłu krzemionkowego wpływa na przyrost wczesnej wytrzymałości betonu poprzez skrócenie czasu wiązania, lecz pojawiają się problemy z urabialnością takiej mieszanki (konieczne jest stosowanie superplastyfikatorów w celu ich rozwiązania) [22]. Rozważając betony zwykle można tutaj mówić o zasadniczych różnicach w strukturze betonu, bowiem rozdrobnienie ziaren pyłu krzemionkowego przyczynia się do wypełnienia przestrzeni międzyziarnowych w mieszance betonowej, co skutkuje większą szczelnością struktury matrycy cementowej. Zmniejsza się porowatość, która w sposób istotny rzutuje na wytrzymałość betonu na ściskanie. Stwierdzić więc można, że zastosowanie dodatku w postaci mikrokrzemionki (o charakterystyce pucolanowej), przy jednoczesnym dozowaniu superplastyfikatora umożliwi osiągnięcie niskiego stosunku w/s (występuje niska zawartość porów kapilarnych). Na skutek tego w strefie przejściowej (wokół ziaren kruszywa grubego), będącej jednym z największych mankamentów betonów zwykłych, możliwa jest redystrybucja naprężeń [24,29]. Taki zabieg (zmniejszenia ilości wody wokół ziaren kruszywa ze względu na wzrost wodożądności mieszanki) prowadzi do minimalizacji ryzyka powstawania i propagacji rys, występowania zjawiska odsączania wody z mieszanki betonowej (tzw. bleedingu) oraz ogranicza jej przepuszczalność. Ponadto zastosowanie  $2 \div 3\%$  pyłu krzemionkowego (w stosunku do masy cementu) przyczynia się rozproszenia kryształów portlandytu (zwykle formują się równoległe do powierzchni kruszywa lub zbrojenia) osłabiających strukturę matrycy cementowej [41]. Mikrokrzemionka przeciwdziała również możliwej segregacji składników, rzutuje na zwiększenie przyczepności uwodnionego zaczynu do kruszywa grubego oraz zbrojenia i wpływa istotnie na parametry mechaniczne, reologiczne betonu (pełzanie) takie jak wytrzymałość na ściskanie i rozciąganie [18,43].

Łączne zastosowanie domieszek redukujących ilość wody zarobowej oraz dodatków pucolanowych o dużym stopniu rozdrobnienia wpływa korzystnie na konsolidację struktury kompozytu cementowego, przekładając się na podwyższenie parametrów wytrzymałościowych oraz trwałości w porównaniu do betonu zwykłego. W tabeli 2.2 przedstawiono przykładowe kompozycje ilościowe mieszanek BWW:

Tabela 2.2. Przykładowe kompozycje mieszanek betonowych [69,75]


Cecha/składnik	Jednostka	Mieszanka betonowa				
		A	B	C	D	E
wytrzymałość na ściskanie	MPa	70	85	76	74	68
rodzaj kruszywa grubego	-	diabaz	grys bazaltowy	Bazalt	dolomit	Granit
stosunek w/s	-	0,31	0,32	0,28	0,28	0,28
cement CEM I 42,5R	kg/m <sup>3</sup>	500	476	479	479	479
woda	kg/m <sup>3</sup>	155	156	128	128	128
piasek 0/2 mm	kg/m <sup>3</sup>	650	665	699	699	699
kruszywo grube 2/8	kg/m <sup>3</sup>	1150	665	136+408	125+376	117+356
kruszywo grube 8/16	kg/m <sup>3</sup>	-	580	817	752	703
superplastyfikator	kg/m <sup>3</sup>	3,5	6,8	9,6	9,6	9,6
mikrokrzemionka	kg/m <sup>3</sup>	18	24	18	18	18

Poza starannym doбором składników, dążąc do uzyskania wysokiej wytrzymałości na ściskanie, należy również osiągnąć jak największy (na miarę dostępnej technologii) stopień zagęszczenia mieszanki minimalizując w ten sposób porowatość betonu. Konieczne jest więc stosowanie specjalnych metod zagęszczania mieszanki betonowej, aby usunąć z niej jak największą ilość niechcianego powietrza. W tym celu można wykonać m.in. wibroprasowanie, prasowanie, wirowanie, odwadnianie próżniowe [11].


Poznanie właściwości zaczynu umożliwia racjonalne projektowanie mieszanki betonowej, którą można rozpatrywać jako zawiesinę kruszywa w zaczynie. W późniejszym okresie zaczyn decyduje o szybkości przyrostu wytrzymałości, ciepłe twardnienia, skurczu wysychania i pęcznienia przy nawilżaniu. Ostatecznie skład fazowy stwardniałego zaczynu decyduje w dużym stopniu o odporności betonu na czynniki agresywne i trwałości konstrukcji betonowych. W początkowym okresie zaczyn cementowy jest gęstą zawiesiną ziaren cementu w wodzie. Struktura tej zawiesiny zależna jest od stosunku wodno-spoiwowego i uziarnienia cementu [74]. Powszechnie przyjmuje się, że niski stosunek wodno-spoiwowy gwarantuje uzyskanie betonu wysokiej jakości, natomiast wysoki współczynnik (gdy ilość wody przekracza wartość wynikającą z hydratacji cementu) wpływa niekorzystnie na jego podstawowe właściwości. Wraz ze wzrostem ilości wody w betonie spada mrozoodporność, obniżają się warunki ochrony stali oraz zachodzą przyspieszone procesy korozji [19]. Współczynnik wodno-spoiwowy pozostaje zatem jednym z fundamentalnych parametrów betonu. Ponadto struktura zaczynu cementowego zależy także od sił działających między ziarnami cementu, a cząsteczkami wody, na co z kolei ma wpływ ładunek powierzchniowy, stężenie jonów w roztworze i zjawisko adsorpcji [76]. Z uwagi na fakt, że do roztworu przechodzą głównie kationy, ziarna cementu ładują się ujemnie [74]. Na powierzchni ziaren cemen-

tu tworzy się ciągła warstewka wody, wynikająca z jej silnego przyciągania przez powierzchnię ziarenek. Przy energicznym mieszaniu (oddziaływania od mieszania są dominujące) woda ta wykazuje tendencję do tworzenia warstewek o jednakowej grubości. Wobec powyższego powstaje tzw. elektryczna warstwa podwójna, składająca się ze sztywno związanych z powierzchnią ziarna jonów dodatnich (tzw. warstwa Sterna) oraz warstwy dyfuzyjnej zawierającej jony luźniej związane [72,76].


Wodożądność normową definiować można jako ilość wody, którą należy dodać do 1 kg spoiwa w celu uzyskania zaczynu o konsystencji normowej, wyznaczonej na drodze badania aparatem Vicata. Jest to parametr szczególnie istotny z punktu widzenia projektowania składu mieszanki betonowej, bowiem nieodpowiednia ilość wody zarobowej (za duża lub za mała) ma bezpośrednie przełożenie na parametry zaczynu, a co za tym idzie zaprawy oraz betonu. Ilość wody przekraczająca wodożądność spoiwa powoduje wzrost porowatości zaczynu cementowego, natomiast zbyt mała ilość wody powoduje nieprzehydratyzowanie wszystkich ziaren cementu. Można stwierdzić, że wodożądność cementów wzrasta wraz z ich stopniem rozdrobnienia, lecz istnieje możliwość jej regulacji przy pomocy domieszek chemicznych. Zaczyn o ilości wody przekraczającej wodożądność normową spoiwa ( $\omega \gg \omega_n$ , gdzie  $\omega_n$  oznacza stosunek w/s, przy którym zaczyn ma konsystencję normową) jest ośrodkiem, w którym ziarna fazy stałej zawieszono są w fazie ciekłej. Wobec tego elektryczna warstwa podwójna kształtuje się swobodnie (rys 2.14). Opisana sytuacja dotyczy betonów zwykłych. Zaczyn o ilości wody wynikającej z wodożądności normowej spoiwa ( $\omega = \omega_n$ ) jest ośrodkiem, w którym osiągnięto maksymalną szczelność upakowania ziaren fazy stałej. Sytuacja ta odpowiada całkowitemu wypełnieniu przestrzeni międzyziarnowych wodą, gdzie grubość warstwy wodnej otoczki na ziarnach osiąga minimalną wartość wynikającą z sił oddziaływania elektrostatycznego [29,77]. Gdy stosunek wodno-spoiwowy jest mniejszy od wodożądności normowej ( $\omega < \omega_n$ ), elektryczna warstwa podwójna zaczyna na siebie zachodzić, co uniemożliwia przedostanie się wody pomiędzy ziarna cementu. Dochodzi do powstania wolnych (wypełnionych powietrzem) przestrzeni międzyziarnowych. Sytuację tą zaprezentowano na rysunku 2.16. W przypadku stosunku wodno-spoiwowego zdefiniowanego jako  $\omega < \omega_n$  rozważany może być zaczyn, który posłuży do wykonania BWW.



Rysunek 2.14. Struktura ziaren cementu przy  $\omega \gg \omega_n$ , gdzie  $\omega$  oznacza stosunek wodno-spoiwowy, a  $\omega_n$  oznacza wodożądność normową spoiwa (stosunek wodno-spoiwowy, przy którym zaczyn ma konsystencję normową badaną aparatem Vicata) (opracowane na podstawie literatury [29,77])



Rysunek 2.15. Struktura ziaren cementu przy  $\omega = \omega_n$ , gdzie  $\omega$  oznacza stosunek wodno-spoiwowy, a  $\omega_n$  oznacza wodożądność normową spoiwa (stosunek wodno-spoiwowy, przy którym zaczyn ma konsystencję normową badaną aparatem Vicata) (opracowane na podstawie literatury [29,77])




Rysunek 2.16. Struktura ziaren cementu przy  $\omega < \omega_n$ , gdzie  $\omega$  oznacza stosunek wodno-spoiowy, a  $\omega_n$  oznacza wodożądność normową spoiwa (stosunek wodno-spoiowy, przy którym zaczyn ma konsystencję normową badaną aparatem Vicata) (opracowane na podstawie literatury [29,77])

Przy założonych parametrach jakościowych komponentów, cechy stwardniałego betonu zależą nie tylko od składu ilościowego, ale także od stopnia rozdrobnienia poszczególnych komponentów, w szczególności spoiwa. Jest to parametr ściśle powiązany ze strukturą zaczynu. Stwardniała matryca zaczynu cementowego stanowi sieć gęsto ułożonych produktów hydratacji. Przestrzenie pomiędzy nimi stanowią pory (które mogą być różnego pochodzenia). Najczęściej występującymi porami są [19]: „pory kapilarne i żelowe, porowatość strefy kontaktowej zaczyn-kruszywo, zamknięte pory powietrzne wprowadzone celowo przy zastosowaniu domieszki napowietrzającej lub spieniającej, pustki wynikające z niedostatecznego zagęszczenia, tzw. raki”. Ilość występujących przestrzeni powietrznych, ich kształt oraz rozmieszczenie to kluczowe aspekty mające wpływ na wytrzymałość i trwałość zaczynu cementowego. Niewielkie pory (żelowe) nie rzutują w sposób istotny na jakość betonu, natomiast większe kapilarne już tak. Powstają one na skutek procesu przemian fazowych zachodzących w matrycy cementowej. Pory żelowe (mające średnice do 3 nm) mogą mieć kształt igielkowy, płytkowy lub płatkowy (są mniejsze o rząd wielkości od cząsteczki wody)[19]. Pory kapilarne na ogół powstają na skutek stosowania większej ilości wody aniżeli wynika to z wodożądności mieszanki (zajmują przestrzeń pomiędzy produktami hydratacji), a ich wielkość jest szacowana na 0,13  $\mu\text{m}$  [19,74]. Istotny jest zatem odpowiedni dobór ilości wody i spoiwa, co determinuje stosunek w/s i przekłada się bezpośrednio na jakość betonu. Niska wartość stosunku wodno-spoiowego pozwala zatem uzyskać betony wysokiej jakości, poprzez minimalizowanie samorzutnego powstawania ciągłych porów kapilarnych. Istotna jest przy tym również właściwa pielęgnacja betonu na mokro [4] (jako czynnik powodujący zmniejszenie samorzutnego powstawania rys), a jako przykład posłużyć może zjawisko skurczu (kontrakcji) zaczynu cementowego,

tj. zmniejszenia objętości układu wskutek wzajemnego fizykochemicznego oddziaływania składników zaczynu cementowego [74]. Skutki tego zjawiska są szczególnie widoczne w przypadku betonów o wysokich wytrzymałościach, w których oprócz dobrej jakości kruszywa i cementu, konieczne jest zwykle zastosowanie dużej ilości spoiwa oraz niskiej względnej ilości wody. W przypadku, gdy wysokowartościowy beton o stosunku 0,30 (stosunek wodno-spoiwowy  $\omega$ ) nie jest właściwie pielęgnowany wodą przed związaniem, może pojawić się w nim od 200 do 300 samoistnych mikroodkształceń skurczowych w ciągu pierwszych 24 godzin [44]. Te mikroodkształcenia prowadzą (przy braku środków zaradczych, np. zbrojenia rozproszonego) do powstania mikrodelfektów w postaci bardzo drobnych i licznych rys chaotycznie rozmieszczonych w objętości betonu [78]. To w oczywisty sposób degradowuje strukturę i w efekcie obniża szeroko pojętą trwałość betonu. Właściwie ukształtowany beton wysokowartościowy charakteryzuje niska przepuszczalność, bowiem stanowi on szczególnie gęstą mikrostrukturę uwodnionego zaczynu cementowego z nieciągłym układem porów kapilarnych [35].

Zjawisko skurczu przebiega natomiast odmiennie w przypadku betonów wysokowartościowych i zwykłych. Skurcz spowodowany hydratacją zachodzi szybciej, przez co może wywołać dodatkowe naprężenia w początkowym okresie dojrzewania (gdy możliwość odkształceń zostaje ograniczona). Ze względu na zwiększoną szczelność oraz zredukowaną ilość wody zarobowej, skurcz BWW spowodowany wysychaniem jest znacznie mniejszy w porównaniu do betonów zwykłych. Na intensywność zachodzących procesów rzutuje również kompozycja i proporcje dobranych składników (cementu, wody oraz w szczególności kruszywa). Można zaobserwować istotne różnice odkształceń skurczowych (nawet kilkukrotne) dla betonów z różnym udziałem objętościowym tego samego kruszywa (rys. 2.17) [32]. Ponadto, z oczywistych względów, na końcową wartość skurczu bezpośrednio przekłada się ilość wody zawarta w mieszance betonowej. Przykład stanowią mogą mieszanki betonowe o konsystencji plastycznej i wilgotnej, bowiem stwierdzono, iż dla pierwszej z nich odkształcenia skurczowe będą miały o 25% większą wartość. Z jednej strony pryncypialne jest dążenie do jak najlepszej urabialności, z drugiej zaś zwiększenie stosunku wodno-spoiwowego nie jest pożądane. Na uzyskanie właściwego kompromisu pozwalają domieszki superplastyfikujące, które również pośrednio redukują odkształcenia skurczowe.




Rysunek 2.17. Wpływ stosunku wodno-cementowego oraz zawartości kruszywa na skurcz betonu [32]


Ze względu na niedobór fazy ciekłej, w sytuacji przedstawionej na rysunku 2.15 dochodzi do występowania niezhydratyzowanych ziaren cementu. Jak stwierdzono w literaturze przedmiotu [17] cement, który nie uległ hydratacji, nie wpływa szkodliwie na wytrzymałość, bowiem wśród zaczynów cementowych o stosunku żeluz do objętości równym 1,0 większą wytrzymałością charakteryzują się zaczyny o wyższej zawartości cementu niezhydratyzowanego (tj. o niższym stosunku wodno-spoiwowym). Istnienie takich niezhydratyzowanych ziaren cementu w betonach o niskim stosunku wodno-spoiwowym okazuje się zatem zjawiskiem korzystnym, gdyż umożliwia samoleczenie betonu w obliczu mikrodefektów [38,66]. W przypadku powstania rysy (pod wpływem wody) występująca wolna przestrzeń wypełniana jest produktami hydratacji. Ponadto nakreślone na rysunku 2.15 wolne przestrzenie między porami wpływają na obniżenie oczekiwanej wytrzymałości BWW. Determinuje to również zmniejszenie gęstości pozornej zaczynu, wyrażającej stosunek masy do objętości wraz z zawartymi w spoiwie (cemencie) pustkami powietrznymi. Obniżenie wytrzymałości spowodowane obniżeniem gęstości pozornej zaczynu przedstawiono na rysunku 2.18. Zgodnie ze źródłem literaturowym [11] nie podano mian na osiach pionowych i poziomych, aby zachować uniwersalność rysunku; bowiem przedstawione trzy krzywe pochodzące od betonu wibrowanego, całkowicie zagęszczonego oraz ręcznie zagęszczonego odnoszą się do wysokowartościowego betonu jednej klasy.

Oprócz stosunku wodno-cementowego na odkształcenia skurczowe wpływa także ślad fazowy spoiwa. Zwykle konkretnemu rodzajowi i klasie cementu odpowiada uniikalny skład fazowy. Związek ten pokazano na rysunku 2.18.





Rysunek 2.18. Wpływ rodzaju cementu na skurcz zaprawy normowej [na podstawie Górażdże cement]



Rysunek 2.19. Graficzna interpretacja zestawienia parametrów struktury zaczynu cementowego [77], gdzie  $V_c$  – objętość cementu [dm<sup>3</sup>];  $V_z$  – objętość zaczynu cementowego [dm<sup>3</sup>];  $\rho$  – gęstość zaczynu cementowego [kg/dm<sup>3</sup>];  $\rho_{teor}$  – gęstość teoretyczna zaczynu cementowego [kg/dm<sup>3</sup>];  $\rho_{rzecz}$  – gęstość rzeczywista zaczynu cementowego [kg/dm<sup>3</sup>];  $\omega$  – stosunek wodno-spoiwowy [-];  $\omega_n$  – wodożądność normowa spoiwa [-];  $p$  – porowatość zaczynu [%]

Parametry mechaniczne betonów wysokowartościowych wynikają bezpośrednio ze struktury matrycy cementowej oraz składu. Jak już wspomniano, zagęszczone produkty hydratacji uwodnionego zaczynu cementowego charakteryzują się wysoką wytrzymałością oraz lepszym, aniżeli w przypadku betonów zwykłych, powiązaniem z ziarnami

kruszywa grubego. Dzięki eliminacji lokalnych osłabień (pory powietrzne powstałe w efekcie zalegania wolnej wody, bleeding, rysy skurczowe) uzyskany produkt jest wysoce jednorodny, co determinuje odmiennosć mechanizmów zachodzących podczas obciążania BWW i betonów zwykłych. Dla betonów zwykłych charakterystyczna jest prawidłowość:

$$f_k > f_b > f_z \quad (2.1)$$


gdzie:

$f_k$  – wytrzymałość na ściskanie kruszywa [MPa]


$f_z$  – wytrzymałość na ściskanie zaprawy [MPa]

$f_b$  – wytrzymałość na ściskanie betonu [MPa]

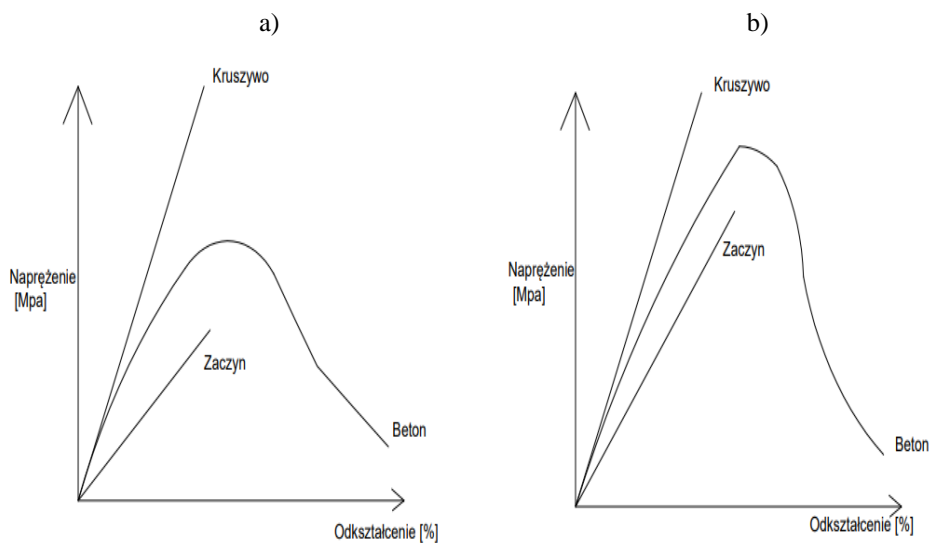
W związku z wyrażeniem (2.1) mechanizm niszczenia zostaje zainicjowany w najslabszym elemencie struktury, czyli strefie przejściowej pomiędzy matrycą, a ziarnami kruszywa grubego. Dochodzi do propagacji rys i w konsekwencji wyluskania ziaren. W odniesieniu do BWW newralgiczna strefa kontaktowa zapewnia dystrybucję naprężeń pomiędzy ziarnami kruszywa grubego (rys 2.20) oraz zaprawą, zatem mechanizm niszczenia przebiega w odmienny sposób. Miejcem inicjalizacji i propagacji rys stają się ziarna kruszywa grubego, co jest charakterystycznym wyznacznikiem BWW. Zauważyć można prawidłowość polegającą na tym, że wytrzymałość betonu wzrasta, jeżeli maleje różnica pomiędzy wytrzymałością i odkształcalnością matrycy cementowej oraz kruszywa (rys 2.21).



Rysunek 2.20. Porównanie zależności naprężenie – odkształcenie dla betonów wykonanych z różnych kruszyw: B – bazaltowe; G – granitowe; O – otoczkowe [70]




Rysunek 2.21. Typowe wykresy naprężenie-odkształcenie betonu konwencjonalnego oraz wysokowartościowego [32]



Rysunek 2.22. Zależność naprężenie-odkształcenie zaczynu, kruszywa i betonu dla: a) betonu zwykłego; b) betonu wysokowartościowego [16,69]

Dwuskładnikowy ośrodek złożony z zaczynu i kruszywa jest kruchy oraz przejawia tendencję do nieliniowej odkształcalności, powiązanej ze zjawiskiem występowania mikrorys. Zróżnicowanie modułów sprężystości matrycy cementowej oraz kruszywa

stanowi przyczynę inicjalizacji siatki mikrorys nawet przy niewielkich obciążeniach, co odzwierciedlone jest na rysunku 2.22 a) w postaci odkształceń quasi-plastycznych [24]. Z kolei dla BWW ze względu na mniejszą różnicę pomiędzy sztywnością matrycy a kruszywa, rozkład naprężeń w strefie kontaktowej jest bardziej równomierny, dzięki czemu zostaje zmniejszone prawdopodobieństwo wystąpienia niepożądanych koncentracji naprężeń inicjujących mikrorysy. Stanowi to przyczynę bardziej gwałtownego pęknięcia betonów wysokowartościowych w porównaniu z betonami tradycyjnymi. Stwierdzono, iż dla betonów zwykłych średnia wartość naprężeń powodujących wystąpienie mikrorys wynosi około 40-50% końcowej wytrzymałości, podczas gdy dla BWW osiąga 70-80% [16]. Adekwatnym wydaje się zatem stwierdzenie, iż betony wysokowartościowe są materiałem bardziej kruchym aniżeli betony zwykłe. Na rysunku 2.23 zaprezentowano porównanie wybranych właściwości mechanicznych betonów zwykłych i BWW.




Rysunek 2.23. Porównanie wybranych właściwości mechanicznych betonów zwykłych i BWW, gdzie  $f_c$  – wytrzymałość na ściskanie;  $f_t$  – wytrzymałość na rozciąganie;  $E$  – moduł odkształcalności podłużnej;  $K_{IC}$  – współczynnik intensywności naprężeń;  $G_f$  – energia pęknięcia;  $C_t$  i  $L_o$  – parametry określające rozmiary strefy mikrozarysowania wokół czubka rysy [30]

Wzrost wytrzymałości na ściskanie powoduje zwiększenie krytycznej intensywności naprężeń oraz energii pęknięcia. Ponadto dla BWW odkształcenia powstające przy rozciąganiu przyrastają wolniej niż wytrzymałość betonu na ściskanie. Zwiększenie parametrów mechaniki pęknięcia betonów wysokowartościowych w porównaniu do kompozytów tradycyjnych upatrywać można w zmniejszeniu porowatości całkowitej oraz ograniczeniu siatki wewnętrznych mikrorys, bądź innych nieciągłości powodujących koncentrację naprężeń. Wówczas sumaryczny udział mikroporów w objętości kompozytu zostaje zredukowany, co ma istotne znaczenie z punktu widzenia utrzymania niskiego stosunku w/s [37].



Jak już wspomniano, dla betonów wysokowartościowych charakterystyczny jest szybki przyrost wytrzymałości na ściskanie, uzyskany dzięki małej ilości wody zarobowej oraz dużej powierzchni styku poszczególnych składowych mieszanki betonowej. Obserwuje się wprost proporcjonalny przyrost wytrzymałości betonu i zaprawy, który w pierwszej dobie stanowi funkcję zawartości  $C_3S$  i  $C_3A$  oraz stopnia rozdrobnienia

cementu. W przypadku betonów modyfikowanych samym pyłem krzemionkowym zauważa się spowolnienie rozwoju wytrzymałości w czasie, szczególnie tej wczesnej, bowiem jedno lub dwudniowa wytrzymałość nie przewyższa wytrzymałości uzyskiwanych dla betonów zwykłych. Rozpatrując natomiast późniejsze wytrzymałości zauważalny jest już ich równomierny przyrost, dlatego też dane podawane w literaturze dotyczą wytrzymałości betonu na ściskanie nawet po 180 dniach. Na rysunku 2.24 zaprezentowano możliwości współczesnych betonów wysokowartościowych, modyfikowanych domieszkami superplastyfikującymi oraz z dodatkami pyłów krzemionkowych.




Rysunek 2.24. Rozwój wytrzymałości na ściskanie dla różnych technologii betonu w funkcji czasu [30]

Trwałość betonu determinowana jest przez szczelność uzyskanej matrycy cementowej oraz brak ewentualnych mikrospekkań. Jednorodna, szczelna struktura charakteryzuje się amorfizacją hydratów oraz pozbawiona jest porów kapilarnych, przez co posiada zmniejszoną przenikalność, a tym samym wyższą odporność na oddziaływanie czynników chemicznych oraz atmosferycznych, szczególnie tych silnie oddziaływujących (np. kwaśne wysokosiarczanowe wody). Dla uzyskania kompozytu o wysokiej szczelności istotna jest predyspozycja BWW do niwelowania porów mikrostrukturalnych, w szerokim spektrum wymiarów w funkcji czasu (rys. 2.25).




Rysunek 2.25. Redukcja mikroporowatości struktury BWW jako: a) wynik przemian fazowych w czasie [16]; b) zależności stosunku  $w/c$  (promień porów wyrażono w mikro metrach) [79]

Na podstawie literatury przedmiotu [80] stwierdza się, że betony wysokowartościowe już po 72 godzinach uzyskują znacznie wyższą szczelność, aniżeli betony zwykłe (rys. 2.26).



Rysunek 2.26. Przepuszczalność betonów zwykłych i wysokowartościowych w wyniku działania wody i acetonu po 72 godzinach dojrzewania [80]

Według niektórych badaczy [16] dzięki uszczelnieniu zaczynu można wykluczyć niezamierzoną porowatość mieszanki betonowej (oraz stwardniałego betonu), co pozwoli na uzyskanie kompozytu cechującego się wysoką mrozoodpornością [12]. Znacznie wcześniej w literaturze przedmiotu [81] zdefiniowano, iż od stosunku wodno-spoiwowego zależna jest odporność betonu na mróz, bowiem im większa jest jego nasiąkliwość, tym niższa jest mrozoodporność (powstałe pory w dużej mierze zajęte są przez wodę). W przypadku betonów zwykłych porowatość sięga 12-16%, natomiast dla BWW wynosi ona 9-12% [5]. Według testu CIF (ang. Capillary suction, Internal damage and Freeze-thaw Test) ocena betonów następuje na podstawie ubytku masy po 28 cyklach, jak również za pomocą wewnętrznych uszkodzeń. Decydująca jest tutaj liczba cykli, które beton przetrwa do momentu, gdy względny moduł dynamiczny E spadnie o więcej niż 25%. Dla betonów zwykłych ilość ubytków waha się w granicach 150-1300 g/m<sup>2</sup>, podczas gdy dla BWW osiąga wartość 50-200 g/m<sup>2</sup> [11].



Rysunek 2.27. Wpływ stosunku w/c na przesiąkliwość zaczynu cementowego [16]

Kolejnym z aspektów, na który rzutuje szczelność matrycy betonu wysokowartościowego jest jego podatność na karbonatyzację, czyli oddziaływanie dwutlenku węgla na zewnętrzną strukturę konstrukcji wykonaną z betonu. Wysoka szczelność BWW utrudnia wnikanie  $\text{CO}_2$ , a co za tym idzie objawy karbonatyzacji są niewielkie [32]. Istotne znaczenie w tej kwestii ma także wysoka zawartość cementu. W porównaniu do betonów zwykłych obniżeniu ulega pH betonu (ze względu na dodatek mikrokrzemionki), przez co wzrasta oporność elektryczna mająca wpływ na korozję.

W konkluzji należy podać, że istnieją różne kierunki optymalizacji technologii produkcji i składu betonów wysokowartościowych, a ich kryteria nie są możliwe do spełnienia jednocześnie. Zatem sztuka projektowania jawi się jako swoisty kompromis pomiędzy zakładanymi cechami kompozytu, a możliwościami ich osiągnięcia. Czasami zdarza się, że kierunki są nawet sprzeczne, czego przykład stanowią mogą betony samozagęszczalne, gdzie osiągnięcie niskiego stosunku wodno-spoiwowego jest nierealne. Zatem interesujące problemy dotyczą m. in. dalszych kierunków rozwoju betonów wysokowartościowych (betony samozagęszczalne, fibrobetony, betony RPC, nanotechnologia), problematyki zależnej od jakości komponentów oraz optymalizacji związanej z doborem jakościowym i ilościowym składników.

### 2.3. Metody projektowania mieszanek betonowych

Projektowanie składu mieszanki betonowej powinno odbywać się na drodze trzech lub czterech ściśle powiązanych ze sobą etapów [65]:

- sprecyzowanie danych wejściowych i założeń do projektowania;
- dobór jakościowo-ilościowy głównych składników mieszanki betonowej (cementu, wody, kruszywa, dodatków i domieszek);



- weryfikacja opracowanej recepty laboratoryjnej na drodze doświadczalno-praktycznej, uwzględniając rzeczywiste właściwości poszczególnych składników oraz technologię wykonania realizowaną na stanowisku produkcyjnym.

Dane wejściowe do projektowania składu mieszanki obejmować powinny założenia dotyczące projektowanego obiektu (w szczególności parametrów geometrycznych elementów oraz rozstawu prętów zbrojeniowych) niezbędne do doboru adekwatnego uziarnienia kruszywa, konsystencji mieszanki betonowej oraz technologii jej transportu, układania, zagęszczania jak również końcowo pielęgnacji świeżego betonu. Sposób wykonania betonu jest zatem zależny od realizowanej przez wykonawcę technologii, infrastruktury technicznej oraz posiadanych zasobów sprzętowych (dozowanie składników, mieszanie, transport, układanie, zagęszczanie, dojrzewanie, pielęgnacja). Po zapoznaniu się z tymi zagadnieniami można zdefiniować rodzaj używanego cementu, kruszywa, domieszek i dodatków oraz miejsce poboru wody zarobowej. Projektowanie jakościowo-ilościowe rozpoczyna się przede wszystkim od ustalenia właściwości składników. Należy dobrać metodę projektowania, która najwierniej odzwierciedli oczekiwania stawiane mieszance betonowej, zdeterminowane przez warunki eksploatacyjne (obciążenia, warunki cieplno-wilgotnościowe). Ponadto, ze względów technologicznych (transport, układanie na miejscu w budowania, metoda zęszczania, wymiary elementu, intensywność zbrojenia elementu), zwrócić należy uwagę na dobór odpowiedniej konsystencji mieszanki. Wreszcie końcowo można ustalić recepturę (ilość podstawowych składników na 1m<sup>3</sup> mieszanki betonowej) i zweryfikować ją na drodze laboratoryjnej poprzez porównanie rzeczywistych właściwości mieszanki betonowej z tymi założonymi wcześniej (dokonując w razie konieczności korekt). Poprawne zaprojektowanie składu mieszanki betonowej z całą pewnością jest niezbędne do uzyskania kompozytu o założonych cechach, jednakże sam skład nie stanowi jedynej determinanty. Istotne są również warunki pielęgnacji betonu, sposób zagęszczenia, układania i transportu mieszanki betonowej.

Klasyfikacja metod projektowania składu mieszanek betonowych jest kwestią umowną, bowiem nie została w jasny sposób przedstawiona w literaturze przedmiotu [82–84]. Według niektórych autorów [21] metody ustalania składu mieszanek można podzielić na obliczeniowe i doświadczalne. Do powszechnie stosowanych metod projektowania składu betonu można zaliczyć:

- metody klasyczne, bazujące na analityczno-doświadczalnych zależnościach;
- metody bazujące na mechanicznych modelach betonu;
- metody „*particle packing*” (szczelności upakowania);
- metody sztucznej inteligencji.

#### Metody klasyczne, bazujące na analityczno-doświadczalnych zależnościach

Metody tradycyjne bazują na poszukiwaniu ilości podstawowych komponentów (cement, woda, kruszywo) mieszanki betonowej. W tej grupie wyodrębnić można wspomniane wcześniej metody obliczeniowe oraz doświadczalne [21], choć stanowi to pewne uproszczenie, bowiem metody te wzajemnie się przenikają. Metody umownie nazywane „obliczeniowymi” wymagają współczynników wyznaczanych na drodze doświadczalnej, natomiast „doświadczalne” ulegają przyśpieszeniu dzięki zależnościom analitycznym (równanie wytrzymałościowe). Metody obliczeniowe realizowane są poprzez rozwiązanie układu trzech równań określających wytrzymałość, szczelność oraz konsystencję. Kruszywo należy tutaj traktować jako całość, więc w przypadku wyodrębnienia jednej z grup frakcji zachodzi potrzeba wprowadzenia dodatkowego równania, zwykle charakteryzującego sposób projektowania. Projektowanie składu

mieszanek betonowych można zatem realizować metodami klasycznymi (tradycyjnymi) wśród których wyróżnić można metody:

- trzech równań (stanowiących podstawę większości pozostałych metod);
- czterech równań;
- doświadczalne;
- inne.

Najpopularniejszą metodą projektowania składu mieszanki betonowej w Polsce jest metoda trzech równań. Polega ona na rozwiązaniu układu równań charakteryzujących w uproszczony sposób wytrzymałość stwardniałego betonu (2.2), jego szczelność (2.3) i wodożądność (2.4):

$$f_{cm} = A \left( \frac{m_c}{m_w} + a \right) \quad (2.2)$$

$$1 = \frac{m_c}{\rho_c} + \frac{m_k}{\rho_k} + \frac{m_w}{\rho_w} \quad (2.3)$$

$$m_w = m_c \cdot w_c + m_k \cdot w_k \quad (2.4)$$

gdzie:

$f_{cm}$  – średnia wytrzymałość betonu na ściskanie [MPa]

$A$  – współczynnik zależny od jakości kruszywa i cementu [-]

$a$  – stała zależna od stosunku cementowo-wodnego równa - 0,5 dla  $\frac{m_c}{m_w} \leq 2,5$  lub 0,5 dla  $\frac{m_c}{m_w} \geq 2,5$  [-]

$m_c$  – masa cementu [kg]

$m_k$  – masa kruszywa [kg]

$m_w$  – masa wody [kg]

$\rho_c$  – gęstość cementu [kg/m<sup>3</sup>]

$\rho_k$  – gęstość kruszywa [kg/m<sup>3</sup>]

$\rho_w$  – gęstość wody [kg/m<sup>3</sup>]

$w_c$  – wodożądność cementu [-]

$w_k$  – wodożądność kruszywa [-]

Powszechnie funkcjonującą formę warunku wytrzymałości betonu (2.1) opracował Bolomey upraszczając wzór Fereta poprzez założenie, że w betonach szczelnych porowatość jest równa zero. W literaturze przedmiotu można napotkać na różne modyfikacje równań podstawowych w taki sposób, aby korzystać z nich było łatwiejsze:

- metoda B. Bukowskiego;
- metoda T. Kluza – K. Eymana;
- jednostopniowego otulenia W. Paszkowskiego;
- jednostopniowego przepelnienia B. Kopycińskiego.

Wymienione wyżej metody opierają się na trzech podstawowych równaniach, lecz wyrażonych w nieco innych postaciach. Zarówno w metodzie B. Bukowskiego jak i K. Eymana nie zachodzi bezpośrednia konieczność obliczania wartości stosunku cementowo-wodnego (c/w). Występuje natomiast dodatkowy współczynnik wynikający z równania wytrzymałości. Metody trzech równań odnoszą się do ośrodka trójskładnikowego (kruszywo, cement i woda), więc znajdują zastosowanie w projektowaniu betonów zwykłych. Kruszywo traktowane jest jako całość, pomijając stopień rozdrobnienia poszczególnych frakcji. W odniesieniu do betonów wysokowartościowych, podstawowym ograniczeniem jest uproszczenie polegające na pominięciu w bilansie objętości-

wym suprerplastyfikatora (bądź ujęcie go w ilości wody) oraz mikrokrzemionki (bądź ujęcie jej w ilości cementu). Założenie takie (dotyczące dodatków) na etapie projektowania nie jest wystarczające, bowiem każdy ze składników charakteryzuje się specyficznym dla siebie stopniem rozdrobnienia, wynikającą ze składu fazowego aktywnością i w określony sposób rzutuje na ostateczny produkt w postaci matrycy cementowej. Beton jest materiałem kompozytowym o heterogenicznych właściwościach, które są niezwykle zależne od ilości i właściwości faz składowych. Zostaje zatem pominięte kształtowanie struktury kompozytu, w tym przestrzennej konfiguracji poszczególnych składników na rzecz objętościowego wyznaczenia ilości komponentów. Kolejnym ograniczeniem metod w odniesieniu do betonów wysokowartościowych jest ważność równań, bowiem dedykowane są one dla relatywnie niewielkich wytrzymałości betonu na ściskanie, tj. 50-60 MPa. Ponadto wyznaczenie współczynników odpowiadających BWW odbywa się na drodze badań laboratoryjnych, co znacznie zwiększa pracochłonność i wydłuża czas pracy nad metodami. Specyfikę tej grupy metod można scharakteryzować następująco:

- odnosi się do ośrodka trójskładnikowego;
- umożliwia korektę składu mieszanki betonowej;
- pozwala na ilościowe określenie objętości składników;
- nie opisuje struktury kompozytu;
- nie ma możliwości oceny jak każdy składnik modyfikuje strukturę betonu;
- ważność równań ograniczona jest niską wytrzymałością.

Metody bazujące na czterech równaniach stanowią udoskonalenie klasycznego układu równań poprzez wprowadzenie dodatkowego równania, pozwalającego na rozgraniczenie kruszywa na drobne (0-2 mm) oraz grube (powyżej 2 mm). W metodach tych podstawowe jest założenie, że ilość ziaren o frakcji 0-2 mm nie jest wartością stałą dla betonów w tej samej klasie wytrzymałości, lecz zmienia się w zależności od konsystencji mieszanki betonowej. Wśród tej grupy można wyróżnić m. in. metody:

- dwustopniowego otulenia (W. Paszkowskiego);
- dwustopniowego otulenia (B. Kopycińskiego);
- dwustopniowego przepelnienia (B. Kopycińskiego).

Próbę uwzględnienia pewnych zależności wpływających na strukturę betonu podjął prof. Paszkowski zakładając, że ziarna kruszywa grubego otulone są warstwą zaprawy o określonej grubości  $r_g/2$ . Metoda ta, nosząca nazwę „metody podwójnego otulenia”, wprowadza do klasycznego układu trzech równań tzw. równanie charakterystyczne (2.5), umożliwiające obliczenie ilości kruszywa grubego ( $K_g$ ) przypadającego na jednostkę objętości mieszanki:


$$K_g = \frac{(1 - j_g)\rho_g}{1 + F_g \frac{r_g}{2}} 1000 \quad (2.5)$$

$j_g$  – jamistość kruszywa grubego [-]

$\rho_g$  – gęstość kruszywa grubego [ $\text{kg}/\text{m}^3$ ]

$F_g$  – powierzchnia zewnętrzna kruszywa grubego [ $\text{dm}^2/\text{kg}$ ]

$r_g$  – promień otulenia ziaren kruszywa grubego zaprawą [dm]



Rysunek 2.28. Spulchnienie stosu okrucowego kruszywa grubego warstwą zaprawy [77]

Powyższe założenie w sposób bardzo uproszczony pozwala na zapewnienie wymaganej szczelności i konsystencji mieszanki. Całkowicie pomija natomiast obecność ewentualnych dodatków mineralnych i domieszek chemicznych, które są tak powszechnie stosowane we współczesnym budownictwie. Z tego względu, podobnie jak większość metod klasycznych, także metoda Paszkowskiego nie jest kompatybilna z betonami nowej generacji. Bazuje ona bowiem na trzech równaniach podstawowych (oraz dodatkowym równaniu charakterystycznym), z których ważność zachowuje jedynie równanie szczelności. Wymaga ono jednak korekty, ze względu na obecność w mieszance betonowej dodatkowych składników, np. popiołów lotnych i mikrokrzemionki.

Metoda dwustopniowego otulenia według B. Kopycińskiego oparta jest na założeniach zbliżonych z metodą W. Paszkowskiego, ale jako efekt końcowy formuluje się ilości składników mieszanki betonowej w objętościach absolutnych. Współczynniki dotyczące kruszywa w tej metodzie poddano tabelaryzacji.

Metoda przepelniania jam kruszywa w odniesieniu do założeń jest podobna, jednakże niezbędne jest przepelnienie jam pomiędzy ziarnami kruszywa grubego ( $\mu_g$ ) zaprawą, czego stopień zależny jest od konsystencji mieszanki betonowej (im bardziej ciekła konsystencja, tym stopień przepelnienia przyjmuje większą wartość). Do charakterystycznego zestawu trzech równań zostało dodane kolejne, pozwalające na określenie zawartości kruszywa grubego ( $K_g$ ) w jednostce objętości mieszanki betonowej.

$$K_g = \frac{1000\rho_g}{1 + \mu_g \frac{j_g}{1 - j_g}} \quad (2.6)$$

gdzie:

$j_g$  – jamistość kruszywa grubego [-]

$\rho_g$  – gęstość kruszywa grubego [kg/m<sup>3</sup>]

$\mu_g$  – stopień przepelnienia jam kruszywa grubego zaprawą [-]

Specyfikę tej grupy metod można scharakteryzować następująco:

- w sposób uproszczony opisują strukturę kompozytu;
- nie uwzględniają przestrzennej konfiguracji ziaren kruszywa drobnego i ewentualnych dodatków;

- kruszywo podzielone jest na dwie grupy frakcji, podczas gdy rzeczywista krzywa uziarnienia charakteryzuje się ciągłością.

W dążeniu do modyfikacji równania wytrzymałości betonu skupiono się na doświadczalnym określeniu wpływu kruszywa grubego oraz obecności domieszki na wytrzymałość betonu. Modyfikacja uwzględniająca dodatek mikrokrzemionki i jej wpływ na wytrzymałość betonu jest jedną z bardziej znanych zależności, odnoszącą się do BWW. Została sformułowana na podstawie wzoru Féreta przez F. De Larrard'a [3]:

$$f_{cb} = \frac{\alpha_k \cdot f_{cz}}{\{(1 + 3,1 \cdot \omega) : [1 - 0,4 \exp(-11 \cdot m_m : m_c)]\}^3} \quad (2.7)$$

gdzie:

$f_{cz}$  – średnia wytrzymałość znormalizowanej zaprawy cementowej [MPa]

$f_{cb}$  – średnia wytrzymałość betonu na ściskanie [MPa]

$\alpha_k$  – współczynnik uwzględniający rodzaj zastosowanego kruszywa [-]

$\omega$  – współczynnik wodno-cementowy [-]

$m_c$  – masa cementu [kg]

$m_m$  – masa mikrokrzemionki [kg]

Doświadczalną zależność wytrzymałości betonu od jego składu, z uwzględnieniem mikrokrzemionki sformułował również prof. Śliwiński [85]:

$$f_{cb} = \frac{188,4}{21,7^{(m_w : (m_c + m_m) - 0,15 \cdot m_m : m_c)}} \quad (2.8)$$

Gutierrez i Canowas [13] zaproponowali zależność średniej projektowanej wytrzymałości na ściskanie od stosunku wodno-cementowego wraz z uwzględnieniem zawartości mikrokrzemionki w bilansie objętościowym:

$$f_{cm} = 140 \cdot e^{-Kw/c} \quad (2.9)$$

$K$  – parametr zależny od klasy cementu i zawartości pyłów krzemionkowych, przyjmowany na podstawie tabeli 2.3.

Tabela 2.3. Wartość parametru  $K$  do wzoru (2.9) [13]

Zawartość pyłów krzemionkowych [%]	Parametr $K$ [-]	
	Cement 145 A (45 MPa)	Cement 155 A (55 MPa)
0	2,10	1,97
5	1,70	1,60
10	1,41	1,31
15	1,24	1,15

W pracy [77] zaproponowano funkcję wytrzymałości, pozwalającą na uwzględnienie zastosowanego dodatku poprzez współczynnik  $\alpha_m$  odzwierciedlający przyrost wytrzymałości w stosunku do betonu bez mikrowypełniacza:

$$f_{cm} = \alpha_m \cdot \alpha_g \frac{R_c}{1,7 \cdot \omega_m^{0,78}} \quad (2.10)$$

$\omega_m$  – względna ilość wody odniesiona do łącznej masy cementu i mikrokrzemionki

Specyfikę metod bazujących na zmodyfikowanym równaniu wytrzymałości można scharakteryzować następująco:

- możliwe jest zaprojektowanie betonów o pożądanym parametrach bez ograniczeń modeli klasycznych dotyczących wytrzymałości, stosunku wodno-cementowego oraz stosowanych domieszek i dodatków;
- zależności są bardzo przydatne, ale mało uniwersalne (przydatne dla określonych grup betonów);
- nie uwzględnia się parametrów struktury zaczynu cementowego;
- duża pracochłonność wynikająca z weryfikacji doświadczalnej receptur.

Główna idea metod doświadczalnych stosowanych w kraju opiera się na tezach zaproponowanych przez W. Kuczyńskiego, tj. dodawaniu poszczególnych składników o coraz drobniejszym uziarnieniu, aż do uzyskania najbardziej gęstego zestawu (rozpoczynając od kruszywa grubego, poprzez kruszywo drobne, cement i wodę). Metoda ta została zmodyfikowana tak, aby do mieszanki kruszyw dodać właściwą objętość zaczynu. Proporcje cementu oraz wody w prosty sposób określić można z równania wytrzymałościowego. Innym uproszczeniem (wg B. Kopycińskiego) jest łączenie zaprawy o znanej objętości z kruszywem grubym. Inne przykładowe metody doświadczalne:


- zaczynożądności (metoda Kopycińskiego);
- kolejnych przybliżeń (metoda Kuczyńskiego);
- znanego zaczynu (uproszczona postać metody Kuczyńskiego).

Metoda zaczynożądności zbliżona jest założeniami do metody przepelnienia jam kruszywa grubego zaprawą. Według tej metody łączna objętość zaprawy musi mieć większą wartość niż ta w strefie kruszywa grubego. Z kolei na drodze metody kolejnych przybliżeń ustalić można (poprzez kolejne iteracje) proporcje ilościowe składników mieszanki. Kluczowe jest przyjęcie zestawu kruszyw charakteryzujących się odpowiednim uziarnieniem. Po spełnieniu tego założenia można przystąpić do określenia proporcji pomiędzy ilością cementu i wody, mając na względzie konsystencję mieszanki. Po dokonaniu uproszczeń tej metody otrzymuje się powszechnie stosowaną metodę znanego zaczynu.

Podobnie jak w przypadku metod analityczno-doświadczalnych, projektowanie mieszanki należy rozpocząć od przyjęcia podstawowych założeń dotyczących właściwości projektowanego betonu. Charakterystyczne dla tej metody jest iteracyjne komponowanie optymalnego zestawu kruszywa. Dokonuje się kolejnych przybliżeń mieszanki kruszyw tak, aby uzyskać stos okruchowy o możliwie najmniejszej jamistości i wodożądności. Wówczas określa się objętość zaczynu cementowego o znanym współczynniku wodno-spoiwowym. Z oczywistych względów metoda ta jest kłopotliwa w odniesieniu do betonów modyfikowanych domieszkami superplastyfikującymi, bowiem dobór adekwatnej ilości domieszki na drodze kolejnych przybliżeń (przy stałości założonych parametrów) jest dużą trudnością. Ponadto, ze względu na doświadczalny charakter istotnym wymogiem jest zachowanie reżimu dotyczącego dokładności dokonywanych pomiarów, bowiem ewentualne błędy (lub niedokładności) przekładają się na końcową, zwielokrotnioną wartość błędu w odniesieniu do receptury na 1 m<sup>3</sup> mieszanki betonowej. Równie istotny jest czas trwania badań, ponieważ procesy zachodzące w zaczynie cementowym powodują zmianę jego właściwości, co rzutować będzie na wyniki pomiarów i ich ewentualne zniekształcenia.

Wiele istniejących metod projektowania mieszanek, funkcjonujących w różnych krajach, opiera się na podobnym podstawowym podejściu. Relacje empiryczne, wykre-

sy i nomogramy zostały opracowane na podstawie obszernych badań eksperymentalnych. Niekompatybilność tych metod z betonami wysokowartościowymi sprawia, że w odniesieniu do tych betonów stosuje się ogólne zalecenia i doświadczenia uzyskane na drodze studiów różnych badaczy [32,83,86]. Jako pierwszy metodę umożliwiającą określenie składu mieszanki betonowej w sposób ilościowy sformułował Aitcin [13,44], uzależniając projektowaną 28-dniową wytrzymałość od stosunku wodno-cementowego (rys. 2.29).



Rysunek 2.29. Wytrzymałość na ściskanie w zależności od współczynnika wodno-cementowego [75]

W 1991 r. ACI opublikowało wytyczne dotyczące mieszanek betonowych normalnych, z uwzględnieniem innych materiałów wiążących bądź domieszek (dokument ponownie został zatwierdzony w 2002 r.) [87]. Metoda bazuje na bezwzględnej objętości projektowanej mieszanki i obejmuje kolejne etapy projektowania. Pozwala na wstępne określenie proporcji mieszanki betonowej, których weryfikacja następuje na drodze korekt zarobów próbnych. Metoda ta polega na określeniu zawartości kruszywa grubego na podstawie gęstości nasypowej kruszywa w stanie suchym. Brane są pod uwagę rzeczywiste pustki powietrzne powstałe pomiędzy ziarnami kruszywa grubego, które docelowo mają zostać wypełnione materiałem drobniejszych frakcji. Podane zostały także oddzielne tablice dla betonu napowietrzonego oraz nienapowietrzonego. Maksymalny, nominalny wymiar ziaren kruszywa wynosi 150 mm. Projektowanie mieszanki betonowej obejmuje następujące etapy:

- wybór wymaganej konsystencji mieszanki i wytrzymałości betonu;

- przyjęcie maksymalnego wymiaru ziaren kruszywa grubego;
- oszacowanie zawartości wody i powietrza;
- dobór współczynnika wodno-spoiwowego;
- obliczenie ilości cementu;
- określenie ilości kruszywa grubego;
- określenie ilości kruszywa drobnego;
- wykonanie pierwszego zarobu próbnego bez uwzględnienia mikrowypełniaczy,
- wykonanie kolejnych zarobów próbnych zastępując część cementu innymi materiałami wiążącymi (pyłami krzemionkowymi, popiołami lotnymi, itp.);
- wykonanie próbnych zarobów i sprawdzenie założonych właściwości.


Stosowanie metod opierających się na analityczno-doświadczalnych i doświadczalnych metodach projektowania składu mieszanki betonowej, w odniesieniu do betonu wysokowartościowego niesie za sobą szereg ograniczeń. Wykorzystuje się tutaj empiryczne zależności pomiędzy składem ilościowym (i niekiedy jakościowym), a takimi cechami jak wytrzymałość czy konsystencja. Metody analityczno-doświadczalne i doświadczalne pozwalają zaprojektować beton o określonych cechach, lecz nie dają możliwości prowadzenia analizy i optymalizacji przestrzennej konfiguracji składników, jak również nie umożliwiają prognozowania zachowania tego kompozytu w konstrukcji (bądź próbce) pod określonym obciążeniem. Specyfikę tej grupy metod projektowania mieszanek betonowych można scharakteryzować następująco:

- w sposób uproszczony pozwalają na określenie objętości składników;
- są bardzo wrażliwe na błędy pomiarowe;
- nie uwzględniają przestrzennej konfiguracji ziaren kruszywa drobnego i ewentualnych dodatków;
- ustalony skład mieszanki wymaga weryfikacji i ewentualnych korekt;
- optymalizują krzywą uziarnienia kruszywa ze względu na szczelność stosu okruchowego.


#### Metody bazujące na mechanicznych modelach betonu

Innym podejściem jest modelowanie struktury betonu polegające na budowie układów modelowych, których parametry są dobierane w sposób możliwie najlepiej opisujący ośrodek rzeczywisty. Metody te nadają się szczególnie do adaptacji komputerowej. Wyróżnić tutaj można dwa przykłady, tj. klasyczny model struktury Reniusa [88] oraz jeden z bardziej zaawansowanych modeli, opracowany przez Zubelewicza [89]. Pierwszy z modeli bazuje na układzie kul (odzwierciedlających kruszywo grube), które połączone są ze sobą za pomocą układu więzi modelujących stwardniałą zaprawę. Drugi zaś traktuje beton jako dwufazowy ośrodek złożony ze sferycznych ziaren kruszywa, usytuowanych w odkształcalnej sprężysto-krucho-plastycznej przestrzeni (matrycy), zapewniającej przekazywanie naprężeń pomiędzy poszczególnymi ziarnami ( $Q_n$ ,  $Q_t$ ), wokół których występują strefy koncentracji ( $\Delta\sigma$ ).





Rysunek 2.30. Model struktury Reniusa [77]



Rysunek 2.31. Model struktury betonu wg. Zubelewicza [77,89]


Modele umożliwiają określenie sposobu zachowania się kompozytu wbudowanego do konstrukcji podlegającej obciążeniom (gdzie występuje m.in. zjawisko odkształcania, mechanizm zniszczenia), a ponadto przy ich zastosowaniu możliwe jest zaprojektowanie składu mieszanki betonowej. Jednocześnie przy modelowaniu składu mieszanki betonowej występują określone problemy, polegające np. na wprowadzeniu do modelu parametrów jakościowych takich jak stosunek w/s, klasa cementu czy uziarnienie kruszywa. Powoduje to konieczność uzależnienia tych cech (głównie w sposób empirycznych) od parametrów modelu mechanicznego. Wymaga to czasochłonnej analizy i badań eksperymentalnych [17,90]. Liczna grupa modeli mechanicznych betonu nie uwzględnia dostatecznie dobrze niejednorodnej struktury tego kompozytu, traktując go jako ośrodek quasi-jednorodny. Bazują one na wynikach obserwacji doświadczalnych, pozwalających zazwyczaj na budowę złożonych modeli, których matematyczny opis

jest uogólnieniem wyniku poznania w granicach obszaru obserwacji [90]. Charakteryzując tę grupę można stwierdzić, że opracowywane na przestrzeni lat modele pozwalają z dobrą zgodnością opisać pracę betonu i żelbetu w elementach konstrukcyjnych. Brak uwzględnienia faktycznej niejednorodności struktury, wynikającej m. in. z obecności kruszywa i pustek powietrznych na poziomie makroskopowym oraz zróżnicowania struktury krystalicznej, uniemożliwia bezpośrednie wykorzystanie tych modeli do projektowania jakościowego i ilościowego mieszanki betonowej. Modele mechaniczne posiadają następującą specyfikę:

- modele należy zaadaptować do metod komputerowych;
- modele nie uwzględniają właściwego ukształtowania struktury kompozytu;
- modele płaskie nie uwzględniają przestrzennej konfiguracji ziaren kruszywa, cementu i mikrokrzemionki;
- konieczna jest czasochłonna kalibracja parametrów.

#### Metody particle packing

Temat optymalizacji składu betonu poprzez dobór właściwych ilości różnych cząstek wzbudza zainteresowanie już od ponad wieku [91,92]. Po raz pierwszy particle packing zastosowano w 1892 r. w badaniach przeprowadzonych przez Fereta w celu optymalizacji ułożenia ziaren [63], a ich początkowym celem było osiągnięcie możliwie największego upakowania w celu zmniejszenia ilości stosowanego cementu. Powszechnie uznaje się, że wydajność betonu można poprawić poprzez zmniejszenie ilości pustek powietrznych i wielkości kapilar. Idealny rozkład wielkości cząstek zależy od ich charakterystyki i zmienia się w zależności od rodzaju betonu. Dlatego jedna idealna krzywa optymalizacji nie prowadzi do mieszaniny o najwyższej gęstości upakowania. Przy projektowaniu mieszanek betonowych wysoka gęstość upakowania jest ważna dla zmniejszenia zawartości wody, zwłaszcza dla betonu o bardzo wysokiej wydajności. Modele particle packing używane są w celu oszacowania gęstości upakowania i stosunku pustych przestrzeni. Przy ich użyciu możliwa jest poprawa wydajności betonu poprzez dobór odpowiednich proporcji składników mieszanki w sposób zapewniający maksymalną gęstość upakowania. Biorąc pod uwagę wyżej wymienione efekty, strukturalne modele generują upakowanie zilustrowane poprzez krzywe gęstości podobne do nieciągłych linii pokazanych na rysunku 2.32, dając ostry szczyt przy optymalnej objętości. Właściwa konfiguracja rozkładu wielkości cząstek ma zasadnicze znaczenie dla uzyskania gęstego upakowania, bowiem dla mieszaniny zawierającej cement w połączeniu z wypełniaczem może być wyższa lub niższa, co skutkuje następującymi trzema przypadkami (rys. 2.32):



Rysunek 2.32. Krzywe (profile) upakowania cząstek o wysokiej, niskiej i pośredniej interakcji w stosunku do teoretycznych przypadków projektowych dla całkowicie nasyconych mieszanek betonowych o stałym stosunku wodno-spoiwowym: a) dodanie małych cząstek powoduje wyższą gęstość upakowania w porównaniu do teoretycznej gęstości upakowania niezbędnej do uzyskania całkowicie nasyconej mieszaniny; b) dodanie małych cząstek powoduje teoretyczną gęstość upakowania niezbędną do uzyskania całkowicie nasyconej mieszaniny; c) dodanie małych cząstek powoduje niższą gęstość upakowania w porównaniu do teoretycznej gęstości upakowania niezbędnej do uzyskania całkowicie nasyconej mieszaniny [91]

W literaturze przedmiotu przedstawiono kilka modeli upakowania cząstek pozwalających na uzyskanie wysokiej lub niskiej gęstości. Dwa klasyczne równania dla rozkładów wielkości cząstek przedstawili Furnas, Anderegg i Andreassen [92]. W teorii pakowania cząstek, rozkład wielkości cząstek (PSD) użytych materiałów jest przedstawiony jako skumulowany w odniesieniu do drobniejszej frakcji. PSD piasków i żwiru określa się przez przesiewanie, natomiast PSD cementu za pomocą granulometrii laserowej (jeśli wynik nie jest dostępny), a następnie przez przesiewanie. Zgodnie z teorią Andreassena, optymalne upakowanie można osiągnąć, gdy skumulowany PSD spełnia następujące równanie:

(2.11)

$$P(d) = \left( \frac{d}{d_{max}} \right)^q$$

gdzie:

 $P(D)$  – funkcja rozkładu skumulowanego wielkości [-] $d$  – średnica rozpatrywanej cząstki [m] $d_{max}$  – maksymalna średnica cząstki w mieszaninie [m] $q$  – parametr przyjmujący wartość z zakresu 0,33-0,5 dostosowujący krzywą w zależności od rozdrobnienia, wyznaczalny doświadczalnie [-]

Ciągła gradacja wszystkich ciał stałych (kruszywo i proszki) zapewni lepszą urabialność i stabilność zastosowanej mieszanki betonowej, która uwzględni minimalną wielkość cząstek w mieszance [93]. Na podstawie tej obserwacji zdefiniowano zmodyfikowany model Andreasena:

(2.12)

$$P(d) = \left( \frac{d - d_{min}}{d_{max} - d_{min}} \right)^q$$

Obecnie stosowane analityczne modele upakowania cząstek mogą pozwolić na obliczenie gęstości upakowania całej mieszanki betonowej na podstawie rozkładów wielkości cząstek i gęstości upakowania materiałów użytych w tej mieszaninie. Parametrami wejściowymi są gęstość upakowania i rozkład wielkości grup cząstek, ewentualnie w połączeniu z energią zagęszczania, przy której mierzy się gęstość upakowania. Wynikiem analitycznego modelu pakowania jest teoretyczna gęstość upakowania mieszaniny. Aby zoptymalizować mieszankę należy określić gęstość upakowania kilku składów mieszanek, aż do znalezienia maksymalnej gęstości upakowania. Dostępnych jest kilka modeli, ale każdy z nich różni się tym, w jaki sposób interakcje cząstek (efekt ściany, efekt rozluźnienia i / lub energia zagęszczania) są implementowane w ich matematycznych równaniach. Większość modeli uwzględnia efekt rozluźnienia i ściany poprzez odpowiednie parametry. Związek między gęstością upakowania, a zapotrzebowaniem na wodę można wykorzystać do przewidywania wymaganej ilości wody w mieszaninie. Zwiększona gęstość upakowania obniża wymaganą ilość pustej wody. Dlatego mieszanki betonowe o takiej samej urabialności mogą być zaprojektowane z mniejszym zapotrzebowaniem na wodę. W ten sposób zwiększenie gęstości upakowania umożliwia zaprojektowanie betonu o wysokiej wytrzymałości, z niskim stosunkiem woda / cement lub ekologicznego betonu o stałym stosunku woda / cement, ale z mniejszą ilością cementu. Uwzględniając korelację pomiędzy stosunkiem wodno-cementowym, wodożądnością normową cementu, rodzajem kruszywa, a strukturą betonu, jedną z dokładniejszych zależności pozwalających na określenie wytrzymałości betonu na ściskanie, zaproponował w pracy [29] A. Świtoński:

(2.13)

$$f_{cb} = \alpha_k \cdot 0,505 \cdot R_c \frac{\sqrt[3]{(1 + \omega_{zn} \cdot \rho_c) \cdot \frac{\rho_w + 0,45 \cdot \omega_n \cdot \rho_c}{\rho_w + \omega_n \cdot \rho_c} - 1}}{\sqrt[3]{(1 + \omega \cdot \rho_c) \cdot \frac{\rho_w + 0,45 \cdot \omega_n \cdot \rho_c}{\rho_w + \omega_n \cdot \rho_c} - 1}}$$

gdzie:

 $\alpha_k$  – współczynnik uwzględniający wpływ kruszywa na wytrzymałość betonu [-] $\omega_n$  – wodożądność normowa cementu [-] $\omega$  – stosunek wodno-cementowy [-] $\omega_{zn}$  – stosunek wodno-cementowy zaprawy użytej do oznaczenia klasy cementu [-]

Do zalet teoretycznego modelu struktury, na podstawie którego zostało wyprowadzone powyższe równanie, należy zaliczyć uwzględnienie w nim obecności dodatków i domieszek, nieodłącznych składników betonów nowej generacji. Dzięki przyjętym założeniom, autor bierze również pod uwagę występowanie tzw. wewnętrznego efektu ściany, czyli lokalnego zwiększenia objętościowego udziału fazy ciekłej w mieszance betonowej, na skutek wzrostu jamistości kruszywa związanego z tarciem występującym pomiędzy ziarnami kruszywa. Specyfika modeli oraz funkcji wytrzymałości bazujących na gęstości upakowania składników mieszanki betonowej:

- model przestrzenny;
- umożliwia poprawne ukształtowanie struktury kompozytu;
- możliwość uwzględniania w bilansie objętościowym domieszek i dodatków;
- możliwość uzależnienia parametrów betonu i mieszanki betonowej (w tym m.in. wytrzymałości) od podstawowych parametrów struktury;
- zminimalizowanie liczby współczynników wyznaczanych w sposób empiryczny.

#### Metody sztucznej inteligencji

Z powodu dużej różnorodności składników współczesnych kompozytów cementowych, wykorzystywanych jednocześnie i w różnych ilościach, związki między tymi składnikami, a właściwościami mechanicznymi materiałów wykraczać mogą poza możliwości prostego opisu inżynierskiego. Modele opisujące właściwości materiałów, zapisane w formie empirycznej, korzystają ze znanych powszechnie zależności matematycznych obarczonych niekiedy dużymi uproszczeniami. Na przykład analizując wpływ dodatków popiołowych na wytrzymałość czy trwałość betonu pomija się na ogół wpływ zmiennej konsystencji mieszanki lub zmiennej zawartości domieszek uplastyczniających przyjmując, że jest on pomijalnie mały [94]. Zagadnienie wyznaczania parametrów betonu komplikuje się w przypadku mnogości parametrów jego składu (różnych właściwości cementu i jego zawartości, różnych właściwości i zawartości domieszek chemicznych, włókien, ziaren kruszywa), warunków wykonania i pielęgnacji, a także agresywnych oddziaływań środowiskowych. Sformułowanie modelu empirycznego w takiej wielowymiarowej przestrzeni parametrów składu i właściwości kompozytu może okazać się zbyt skomplikowane. W takiej sytuacji do obiektywnego rozpoznania związków między składem, a właściwościami kompozytu można wykorzystać metody komputerowe, zwane niekiedy metodami sztucznej inteligencji [94]. Zaletą wykorzystania technik komputerowych w postaci sztucznych sieci neuronowych do rozwiązania

tak postawionemu problemowi jest to, że nie ma konieczności wyprowadzania jawnych zależności matematycznych, bowiem sieci w procesie uczenia przypisują kolejnym zmiennym adekwatne wagi, dążąc do podanego im wzorca (wykreowanego w procesie badań empirycznych). Szczegółowe uwagi w tym zakresie zostaną podane w kolejnym rozdziale niniejszej rozprawy.

## 2.4. Podsumowanie

Nowoczesne kompozyty cementowe, w tym BWW, będące efektem badań eksperymentalnych, prac projektowych oraz zaawansowanych technologii, definiowane są poprzez określone cechy użytkowe. Ich defekty możliwe są często do zidentyfikowania dopiero na poziomie mikrostruktury, za pomocą zaawansowanej mikroskopii skaningowej, umożliwiającej ocenę zakresu wpływu na parametry betonu. Wówczas można kierunkowo odpowiednio kształtować i projektować beton. Struktura uzyskanego materiału jest czynnikiem warunkującym właściwości oraz użyteczne funkcje kompozytu. Ponadto w szerokim zakresie można poddawać ją modyfikacjom oraz zmianom, co często jest bardziej korzystne aniżeli zmiany składu chemicznego [16,74]. Jak wykazano, warunkiem koniecznym do uzyskania betonów wysokiej jakości jest łączne spełnienie kilku czynników (dobór składników, parametry procesu wytwarzania, warunki przebiegu wiązania i twardnienia betonu) decydujących o strukturze i jakości użytkowej betonu. Istnieje zatem wiele uwarunkowanych wzajemnie czynników i parametrów, które są podstawą do rozważań wielu badaczy. Zakładając, że beton ukształtowany działaniami technologicznymi powstał na skutek pewnego zestawu fizyko-mechanicznych właściwości, zasadne staje się poszukiwanie wzajemnych zależności oraz korelacji pomiędzy ukształtowaną strukturą betonu, a jej właściwościami, w szczególności mechanicznymi. Szukana funkcja jest pryncypialna przy poszukiwaniu parametrów struktury betonów wysokich klas, jednocześnie utrudniona procesami fizyko-chemicznymi zachodzącymi w twardniejącym zaczynie cementowym.

Klasyczna technologia betonu jako determinanty jego wytrzymałości na ściskanie definiuje stosunek wodno-cementowy, stopień hydratacji cementu, porowatość betonu i gęstość składników. W celu uzyskania kompozytu wysokowartościowego wymagany jest ścisły reżim technologiczny, polegający na starannym doborze składników, zarówno w skali mikro jak i makro oraz właściwej pielęgnacji betonu. Pomimo wszelkich starań powstały kompozyt posiada wady, do których zalicza się występowanie makro i mikroporów, kapilarów, lokalnych defektów, ukierunkowanych dużych kryształów, słabych wiązań na granicy faz, niejednorodnego rozmieszczenia cząsteczek produktów hydratacji. Niedoskonałości struktury skutkują w konsekwencji obniżeniem parametrów betonu wysokowartościowego w stosunku do tych, które teoretycznie można by osiągnąć. W celu uzyskania wytrzymałego, niskoskurczowego, szczelnego i trwałego kompozytu dąży się do zagwarantowania optymalnego stosu okruszowego oraz niskiego stosunku wodno-spoiwowego, przy ilości cementu wynikającej z konieczności otulenia nim drobnych frakcji kruszywa. Ponadto dochowanie uwarunkowań technologicznych oraz udoskonalanie klasycznych procedur (staranny dobór jakościowy i ilościowy komponentów, dążenie do maksymalnie niskiej porowatości, obniżenie ilości cementu do minimum oraz inne działania predestynujące do minimalizacji defektów) zwiększa szansę na eliminację strukturalnych mankamentów betonu. Kluczowe jest ukształtowanie jak najczelniejszej struktury zaczynu na drodze redukcji stosunku wodno-

cementowego, przy jednoczesnym uzupełnieniu stosu okruszowego o fazę o dużym stopniu dyspersji. W praktyce przekłada się to na stosowanie domieszek chemicznych coraz nowszych generacji oraz dodatków w postaci aktywnych pyłów (krzemionka, żużel, popiół). Struktura strefy przejściowej ulega wówczas uszczelnieniu, a powstające wiązania chemiczne charakteryzują się dużą wytrzymałością, co pozwala na dystrybucję naprężeń pomiędzy nimi – w odróżnieniu od betonów zwykłych. Zastosowanie pucolanowego wypełniacza w postaci mikrokrzemionki, która reaguje z portlandytem, pozwala na utworzenie jednolitej i ciągłej fazy kontaktowej. Zatem działania mające na celu redukcję stosunku wodno-spoiwowego, przy zastosowaniu domieszek chemicznych oraz wypełnieniu stosu okruszowego mikrokrzemionką, prowadzą do uzyskania jednorodnej struktury zaczynów oraz betonów na tych zaczynach wykonanych. Wówczas uzyskany materiał zbliża się bardziej do wzorca homogenicznego aniżeli heterogenicznego, przez co jego właściwości ulegają korzystnym transformacjom. W związku z powyższym, niski stosunek wodno-spoiwowy można uznać za obligatoryjną cechę betonów wysokowartościowych.

Projekt mieszanki to niezbędne narzędzie we wszystkich aspektach technologii betonu, a jej głównym celem jest osiągnięcie wymaganych właściwości funkcjonalnych przy minimalnym koszcie, z uwzględnieniem parametrów środowiskowych i planowanej technologii produkcji. Nowe badania w obszarach, takich jak wysokowartościowy beton, recyklingowe kruszywo betonowe, samozagęszczalny beton itp. oraz nowoczesne informacje dotyczące rozwiązań technologicznych wskazują na potrzebę dalszego rozwoju metod projektowania mieszanek betonowych. Dotychczasowe technologie otrzymywania BBW wynikają z analitycznych i doświadczalnych zależności dotyczących projektowania betonów zwykłych, polegających głównie na określeniu i doborze poszczególnych składników mieszanki betonowej w skali makro i mikro. Doboru składników dokonuje się na podstawie uwarunkowań dotyczących minimalizacji porowatości stosu okruszowego, maksymalizacji wytrzymałości i szczelności zaczynu cementowego oraz maksymalizacji przyczepności pomiędzy zaczynem, a ziarnami kruszywa. Uzyskanemu kompozytowi stawia się szereg wymagań pod względem cech jakościowych, użytkowych oraz trwałościowych, co istotnie wpływa na zestaw zmiennych oraz innych kryteriów, które należy brać pod uwagę podczas projektowania składu mieszanki betonowej. Proces projektowania prowadzony jest głównie na drodze doświadczanej, w oparciu o stan wiedzy dotyczący BBW, lecz ze względu na brak analitycznych metod coraz częściej znajdują w nim zastosowanie metody statystyczne oraz optymalizacyjne. W przypadku betonów zwykłych wystarczająco dokładne okazują się tradycyjne metody projektowania składu mieszanki, ale w odniesieniu do pięcioskładnikowego ośrodka jaki stanowi BBW dochodzi do rozbieżności w oczekiwanych wartościach. Większość metod klasycznych ogranicza się jedynie do ilościowego określenia objętości komponentów mieszanki betonowej, pomijając przy tym wpływ stopnia rozdrobnienia składników na kształtowanie struktury betonu. Z powodu dużej różnorodności składników współczesnych kompozytów cementowych, wykorzystywanych jednocześnie i w różnych ilościach, związki między tymi składnikami, a właściwościami mechanicznymi materiałów wykraczać mogą poza możliwości prostego opisu inżynierskiego. Modele opisujące właściwości materiałów, zapisane w formie empirycznej, korzystają ze znanych powszechnie zależności matematycznych obciążonych niekiedy dużymi uproszczeniami, co bezpośrednio rzutować może na jedną z najbardziej oczekiwanych cech betonu – wytrzymałość na ściskanie.

Parametr ten występuje w klasyfikacjach normowych i odnosi się bezpośrednio do uwarunkowań konstrukcyjnych, przez co wprowadza się go jako zmienną do powszechnie stosowanych metod projektowania. Równanie wytrzymałościowe (m.in. równanie Féreta i Bolomeya) stanowi integralną część większości metod projektowania, poprzez które zostają opisane właściwości stwardniałego kompozytu, uzależnione od proporcji ilościowych i jakościowych składników mieszanki betonowej. Jest to wystarczający zakres przy projektowaniu betonów zwykłych, natomiast ze względu na ograniczenia metody te nie są kompatybilne z betonami nowej generacji. Ograniczenia te wynikają głównie z konieczności wyznaczania parametrów na drodze eksperymentalnej oraz kalibracji modeli dla betonów o wyższych wytrzymałościach. Ponadto nie zostaje uwzględniony wpływ dodatków oraz domieszek, zatem jedynym równaniem zachowującym ważność pozostaje równanie szczelności (suma objętości absolutnych składników jest równa jednostce objętości zagęszczonej mieszanki betonowej). Modyfikacjom ulega równanie wytrzymałości Féreta, które na podstawie badań zostaje dostosowywane do specyfiki betonów wysokowartościowych i przybiera różne formy. De Larrard zaproponował, aby uzależnić 28-dniową wytrzymałość betonu na ściskanie od parametrów składu mieszanki betonowej, z uwzględnieniem mikrowypełniaczy. Inne przykłady zależności w sposób kompleksowy ujmujące dodatek mikrokrzemionki przedstawiono w pracach [3,29,88]. Ponadto w przypadku betonów o niskim stosunku wodno-spoiwowym występują dodatkowe problemy, takie jak znaczny spadek urabialności i wprowadzenie dużej ilości niechcianego powietrza. Dlatego też podejmowanie działań zmierzających do sprecyzowania uogólnionych zasad projektowania lub wyznaczenia zależności funkcyjnych (pomiędzy cechami BWW, a ich składem) leży w obszarze zainteresowań wielu naukowców. Istnieje również wiele dodatkowych zmiennych, których zwyczajowo nie bierze się pod uwagę podczas procesu projektowania np. zmienną ilość domieszek plastykujących [15,94]. Zagadnienie wyznaczania parametrów betonu komplikuje się w przypadku mnogości parametrów jego składu (różnych właściwości cementu i jego zawartości, różnych właściwości i zawartości domieszek chemicznych, włókien, ziaren kruszywa), warunków wykonania i pielęgnacji, a także agresywnych oddziaływań środowiskowych. Sformułowanie modelu empirycznego w takiej wielowymiarowej przestrzeni parametrów składu i właściwości kompozytu może okazać się zbyt skomplikowane. W takiej sytuacji do obiektywnego rozpoznania związków między składem, a właściwościami kompozytu można wykorzystać metody komputerowe, zwane niekiedy metodami sztucznej inteligencji [94–96]. Zaletą wykorzystania technik komputerowych w postaci sztucznych sieci neuronowych, do rozwiązania tak postawionego problemu jest to, że nie ma konieczności wyprowadzania jawnych zależności matematycznych, bowiem sieci w procesie uczenia przypisują kolejnym zmiennym adekwatne wagi, dążąc do podanego im wzorca (wykreowanego w procesie badań empirycznych). Zagadnienie takie jest rozpatrywane w ramach niniejszej rozprawy doktorskiej, a w celu jego rozwiązania przeprowadzono badania betonów o niskich stosunkach wodno-spoiwowych. Wyniki badań eksperymentalnych zostały wykorzystane do symulacji (predykcji wybranych cech) za pomocą sztucznych sieci neuronowych (stanowiących narzędzie matematyczne służące opisowi zależności).



### **3. ISTOTA SIECI NEURONOWYCH ZWŁASZCZA W ZASTOSOWANIU DO PROJEKTOWANIA MIESZANEK BETONOWYCH**

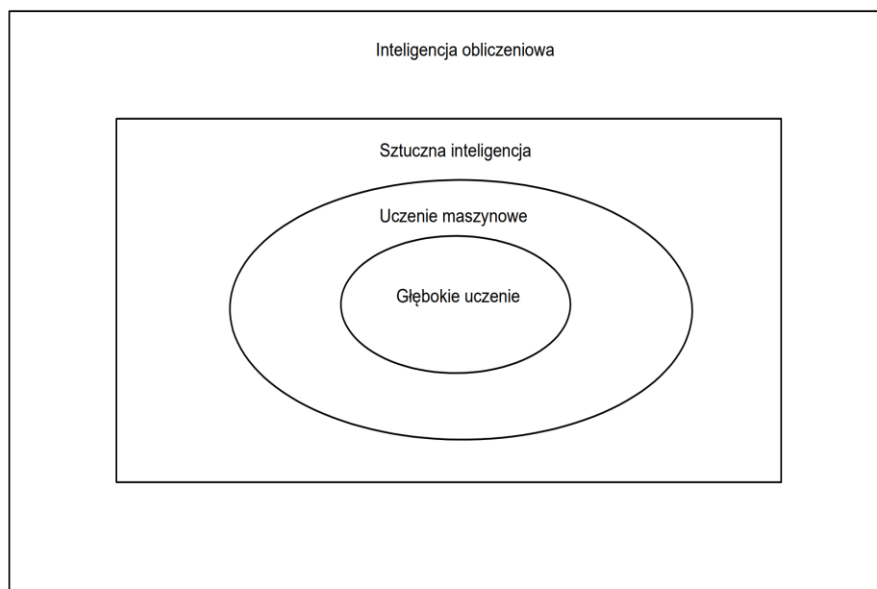
#### **3.1. Wprowadzenie**

Rozważania przedstawione w niniejszym rozdziale posłużą ukierunkowaniu na rodzaj sieci poddawany dalszej analizie i opracowaniu, z uwzględnieniem zastosowania do predykcji wybranych cech betonu. W pierwszym etapie zostaną przedstawione podstawowe informacje dotyczące sieci neuronowych i osadzenia ich w podstawowych pojęciach dziedzin uczenia maszynowego, sztucznej inteligencji, inteligencji obliczeniowej czy głębokiego uczenia. Duże zainteresowanie, które zyskały metody uczenia maszynowego sprawiają, iż rozwój tej dziedziny wydaje się niezwykle obiecujący. Eksploracja danych na dużych zbiorach przyciąga uwagę, ponieważ algorytmy uczenia maszynowego osiągnęły poziom, w którym potrafią rozpoznawać wzorce trudne do rozpoznania przez ludzkie zdolności poznawcze. W drugiej części niniejszego rozdziału zostanie przedstawiony aktualny stan wiedzy w zakresie implementacji sztucznych sieci neuronowych do predykcji wybranych cech mieszanek betonowych oraz gotowego kompozytu. Jedną z najważniejszych cech betonu jest wytrzymałość na ściskanie, która definiuje klasę betonu. Przewidywalna wytrzymałość betonu na ściskanie jest niezbędna do wykonania konstrukcji betonowej i stanowi główną cechę jej bezpieczeństwa i trwałości [97]. W tym zakresie podjęto studia literaturowe, poszukując wzorca do dalszych rozważań.

#### **3.2. Podstawowe zagadnienia związane z sieciami neuronowymi oraz możliwości ich implementacji**

##### **3.2.1. Wprowadzenie**

Zagadnienie sztucznej inteligencji, jak interpretowane jest to powszechnie, nie można określać w kategorii ujednocionej dziedziny naukowej, bowiem stanowi ona tylko wycinek informatyki. Takie uogólnienie może prowadzić do zawężenia tematyki, w skład której wchodzi różne metody obliczeniowe – często od siebie niezależne (rys. 3.1) [98–101]. W literaturze przedmiotu ciężko natrafić na formalne, finalne definicje takich pojęć jak inteligencja obliczeniowa, sztuczna inteligencja, głębokie uczenie czy uczenie maszynowe. Jedne z częściej wykorzystywanych definicji wyżej wymienionych pojęć przedstawia w swojej pracy [102]



Rysunek 3.1. Zależności pomiędzy rozpatrywanymi obszarami wiedzy (opracowane na podstawie literatury przedmiotu [98–101])

#### Inteligencja obliczeniowa (*Computational Intelligence, CI*)

Jest dziedziną nauki, która skupia się na rozwiązywaniu problemów za pomocą obliczeń w przypadkach, gdy danego problemu nie można rozwiązać w sposób zalgorytmizowany. Obejmuje wiele nowoczesnych metod analizy, które można podzielić na trzy główne obszary: obliczenia rozmyte, ewolucyjne oraz sieci neuronowe. Większość modeli wywodzących się z wymienionych obszarów bazuje na wspólnej cesze, czyli „uczeniu” się z danych. Do bardziej znanych metod inteligencji obliczeniowej można zaliczyć: modelowanie, statystykę, metody regresji i estymacji czy uczenie maszynowe. Obliczenia bazujące na inteligencji w praktyce często określane są również jako obliczeniowa sztuczna inteligencja.

#### Sztuczna inteligencja (*Artificial intelligence, AI*)

Stanowi część inteligencji obliczeniowej. Wykorzystywana jest w przypadkach, dla których nie istnieją odpowiednie metody ich rozwiązania. Sztuczna inteligencja opiera obliczenia o modelowanie wiedzy przy procesach, gdzie do rozwiązania problemu potrzebna jest inteligencja (procesy poznawcze wysokiego poziomu jak np. rozumowanie logiczne, język, myślenie). Systemy oparte na sztucznej inteligencji skupiają się na odpowiedniej interpretacji i analizie danych pozyskanych z zewnętrznych źródeł, uczą się na ich podstawie, a następnie wykorzystują pozyskaną wiedzę do wykonania określonych zadań czy celów. Badania zachodzących w trakcie tych procesów zależności opisuje się w sposób matematyczny, a następnie implementuje do programów komputerowych.

#### Uczenie maszynowe (*Machine learning, ML*)

Stanowi wycinek inteligencji obliczeniowej; zajmuje się algorytmizacją i wykorzystywaniem danych, które poddawane są procesowi nauki. Algorytmy budują model na podstawie posiadanych danych, a następnie, bez wcześniejszego zaprogramowania,

podjmują decyzję lub przewidywania. Obecnie uczenie maszynowe skupia się na dwóch konkretnych celach – klasyfikowaniu danych i przewidywaniu na ich podstawie przyszłych wyników. W procesie nauki wyodrębnić można cztery wiodące rodzaje uczenia maszynowego: nienadzorowane, nadzorowane, półnadzorowane oraz uczenie ze wzmocnieniem. Cały proces nauki zostanie szerzej opisany w kolejnych rozdziałach niniejszej pracy.


#### Głębokie uczenie (*Deep learning*)

Opiera się na głównych założeniach uczenia maszynowego, przy czym w szczególności odnosi się do wykrywania i opisu danych, ich klasyfikacji oraz rozpoznawania za pomocą sztucznych sieci neuronowych (SSN). Struktura budowanego modelu inspirowana jest ludzkim mózgiem i charakteryzuje się dużą złożonością (z wielu nieliniowych warstw przetwarzania) oraz hierarchicznością. Konfiguracja neuronów w modelach odbywa się na drodze treningu z dużą ilością danych. W efekcie za pomocą sztucznych sieci neuronowych możliwe jest rozwiązywanie skomplikowanych problemów. Sztuczne sieci neuronowe są strukturami będącymi jedną z metod szerokiej dziedziny jaką jest sztuczna inteligencja.

Na potrzeby niniejszej pracy, sieci neuronowe traktuje się jako narzędzie matematyczne służące rozwiązaniu zagadnienia predykcji wybranych cech betonu. Wobec tego autorka dysertacji podejmie próbę prezentacji jedynie podstawowych zagadnień związanych ze środowiskiem i sieciami neuronowymi.

### **3.2.2. Historia powstania i kierunki rozwoju sieci neuronowych**

Bardzo duży wpływ na dynamikę rozwoju sieci neuronowych miały prace naukowe, którym przyznano nagrodę Nobla: odruch warunkowy (1904, Pawlow), struktura sieci nerwowej (1906, Ramon y Cajal), nerwowe sterowanie mięśni (1932, Sherrington), synapsa (1963, Eccles), celowe zachowanie (1986, Lorentz i Tinbergen) [103–105]. Początki opisu matematycznego komórek neuronowych, powstałego na bazie funkcjonowania komórek mózgu ludzkiego datuje się na 1943 rok, kiedy to w W.S. McCulloch opublikował „*A logical calculus of the ideas immanent in nervous activity*” [106]. W tamtym czasie zainteresowania badaczy z dziedziny neurofizjologii oraz bioniki ukierunkowane były na opis mechanizmów, a wskazana powyżej praca zdefiniowała zasady przetwarzania danych (stanowiących informacje – również o mechanizmach) poprzez aparat matematyczny skwantyfikowany na kanwie modelu odwzorowującego sztuczny neuron. Zidentyfikowanie za pomocą opisu matematycznego podstawnych zalet działania definiowanych przez neurofizjologów, tj. przetwarzania informacji w sposób równoległy przy zastosowaniu metod uczenia się (zastępującego metody programowania), stanowiło podstawę do dalszego rozwoju i opisu sztucznych sieci neuronowych. Analizując kolejne pozycje literaturowe nie można pominąć tych, które stanowiły podwalinę do dalszego rozwoju, tj. „*The Computer and the Brain*” [107] z 1958 r. opisującą rozwiązania techniczne oraz „*Computers and the nervous system. Models and analogues in biology*” [108] z 1960 r. zawierającą podstawowe informacje biologiczne. Pierwszym zrealizowanym i skutecznie wdrożonym, działającym przykładem sieci neuronowej był Perceptron [109], stworzony przez Franka Rosenblatta oraz Charlesa Wightmana (rys. 3.2 a).



Rysunek 3.2. Widok Perceptronu: a) zbudowanego w Cornell Aeronautical Laboratory – 1957 r.; b) układu potencjometrów [109]


Połączenia częściowo elektromechaniczne, a w części elektroniczne zrealizowane w perceptronie były losowe i wręcz chaotyczne. Globalnym efektem działania sieci było rozwiązanie zadania polegającego na rozpoznawaniu znaków alfa-numerycznych pochodzących z kamery, stanowiących sygnał wejściowy, przy czym wagi na wejściach były zmieniane za pomocą potencjometrów (rys. 3.2 b). Wdrożenie prostych zasad uczenia do rozwiązywania konkretnego zadania okazało się krokiem milowym i przelożyło się na gwałtowny rozwój dziedziny sieci neuronowych. Istotne znaczenie ma inny przykład rozwiązania – sieć Madaline. Została ona zaproponowana i zbudowana przez Bernarda Widrowa w 1960 roku. Stała na skutek powielenia i połączenia pojedynczych elementów Adaline (Adaptive linear element), w wyniku czego powstał układ Madaline (Many Adaline) [110,111]. Intensywny rozwój sztucznych sieci neuronowych prowadził w tamtych czasach do prac mających na celu rozwiązanie bardzo trudnych i złożonych problemów. Podjęto nawet próbę utworzenia modelu całego mózgu.

Na początku lat 70. tempo rozwoju prac nad sztucznymi sieciami neuronowymi zostało zahamowane. Opublikowana została wtedy praca [112] zawierająca dowód na to, że sieci jednowarstwowe mogą być wykorzystywane tylko w sposób mocno ograniczony do danego zakresu. Pomimo okresu stagnacji powstały w tym czasie m. in. nowe konstrukcje sieci neuronowych (sieci Avalanche i Cerebellatron zajmujące się sterowaniem ramienia robota, sieć Brain State in the Box jako odpowiednik BAM (pamięci asocjacyjnej z dwustronnym dostępem)). Sytuacja zmieniła się dopiero po serii kolejnych publikacji pokazujących, że sieci nieliniowe nie posiadają ograniczeń. W tym samym czasie pojawiły się też nowe przepisy uczenia sieci wielowarstwowych. W latach 80. tworzono pierwsze duże konstrukcje, o znacznych mocach obliczeniowych. Stało się to możliwe dzięki opracowaniu technologii wytwarzania sztucznych komórek nerwowych. W podobnym czasie pojawiły się także po raz pierwszy sieci neuronowe ze sprzężeniami zwrotnymi (np. sieć Johna Hopfielda odtwarzająca obrazy z ich fragmentów). Druga połowa lat 80. to ponownie okres intensywnego rozwoju sieci neuronowych. J.A. Anderson opublikował wtedy przełomową książkę [113], a wspomniany wcześniej John Hopfield w swoich pracach zajmował się udoskonalaniem sieci ze sprzężeniami zwrotnymi oraz przede wszystkim wprowadził rekurencyjną budowę pamięci neuronu. Kolejna publikacja [114] ukazywała możliwości, jakie niosły za sobą

sieci warstwowe. Wraz z następnymi latami zdecydowanie wzrosła liczba projektów badawczych, skupionych wyłącznie na dziedzinie sieci neuronowych. Sztuczne sieci neuronowe były coraz częściej i szerzej wykorzystywane – możliwe było ich zastosowanie do złożonych systemów, których zachowanie się jest uzależnione od jednoczesnego, lokalnego oddziaływania dużej liczby składowych wchodzących w skład takiego systemu.

### 3.2.3. Identyfikacja struktur neuronowych

Podstawą budowy wszystkich sieci neuronowych są oczywiście struktury ludzkiego mózgu i procesy w nim zachodzące (sieć neuronowa stanowi uproszczony schemat budowy mózgu) [103]. Każda sieć składa się z dużej liczby elementów przetwarzających informacje (neuronów), skojarzonych ze sobą połączeniami o określonych parametrach (wagi), które zmieniają się podczas procesu uczenia. Schemat budowy komórki nerwowej oraz sztucznej sieci neuronowej przedstawiono na rys 3.3 [115–117].



Rysunek 3.3. a) schemat komórki nerwowej [118]; b) schemat sztucznej sieci neuronowej na podstawie [102]

Współcześnie budowane sieci neuronowe mają budowę warstwową, przy czym wyróżnia się warstwy: wejściową, wyjściową oraz warstwy ukryte, których może być kilka [103,105,119,120]

### 3.2.4. Możliwości zastosowania sieci neuronowych

Jedną z najważniejszych cech sieci neuronowych jest zdolność samoorganizacji oraz adaptacji do zmieniających się warunków. Same algorytmy SSN (sztuczne sieci neuronowe) są narzędziem informatycznym uczącym się w czasie, mają zdolność do zmiany zasobu posiadanej wiedzy, ale co najistotniejsze potrafią ją dynamicznie zmieniać. Posiadają zdolność do samouczenia się, co w sposób znaczący przyspiesza wykonywanie obliczeń. Sztuczne sieci neuronowe składają się z silnie połączonych ze sobą warstw prostych węzłów przypominających neurony. Neurony działają jako nieliniowe elementy przetwarzające w sieci. Metodologia zapewnia zatem efektywną kosztowo i niezawodną technikę modelowania procesów. Zastosowanie sztucznych sieci neuronowych jest niezwykle szerokie – nie tylko w naukach inżynierskich [121–132]. Wachlarz kierunków wykorzystania obejmuje między innymi:

- badania oraz diagnostyka układów elektronicznych;
- badania psychiatryczne;
- prognozowanie sprzedaży;
- interpretacje badań biologicznych;
- planowanie remontów maszyn;
- monitorowanie pracy siłowni jądrowych;
- analizy problemów produkcyjnych;
- dobór surowców (np. obudowy promów kosmicznych);
- sterowanie procesami przemysłowymi;
- dobór pracowników według wymaganych kwalifikacji;
- optymalizację utylizacji odpadów;
- syntezę mowy;
- inne.

Atrakcyjną właściwością sztucznych sieci neuronowych jest to, że przy odpowiedniej topologii sieci są one zdolne do charakteryzowania nieliniowych zależności funkcjonalnych. Ponadto strukturę wynikowego modelu procesu opartego na sieci neuronowej można uznać za ogólną w tym sensie, że do określenia modelu wymagana jest niewielka wiedza o procesie.

### 3.2.5. Podstawy budowy i rodzaje sztucznych sieci neuronowych

Sieć neuronowa składa się z dużej liczby elementów (neuronów), które mają zdolność przetwarzania informacji, skojarzonych ze sobą za pomocą połączeń zdefiniowanych poprzez określone parametry zwane wagami, zmiennych podczas procesu uczenia się. Neurony mogą być połączone ze sobą przy pomocy różnych zasad [133]:

- połączenia między kolejnymi warstwami w sieciach warstwowych;
- połączenia neuronów każdy z każdym;
- połączenia wybranych neuronów, np. z sąsiedztwa.

Podwaliny do formalnych definicji neuronu podali w 1943 r. Pitts i McCulloch [106] poprzez określenie sygnałów wejściowych w formie  $x_i, i=1, 2, \dots, n$ , przyjmujących war-

tości 1 lub 0 zależnie od tego, czy w chwili  $k$  zaistniał tzw. impuls wejściowy. Wówczas reguła aktywacji neuronu przyjmuje postać:

$$y^{k+1} = \begin{cases} 1, & \text{gdy } \sum_{i=1}^n w_i x_i^k \geq T, \\ 0, & \text{gdy } \sum_{i=1}^n w_i x_i^k < T, \end{cases} \quad (3.1)$$

gdzie:

$k = 0, 1, 2, \dots, n$  – oznacza czas z wyodrębnionymi momentami

$w_i$  – multiplikatywna waga przypisana do połączenia wejścia  $i$  z błoną neuronu

Relatywnie prosty model posiada jednak ogromne możliwości aplikacji, bowiem proces odpowiedniego doboru wag i progów prowadzi do realizacji funkcji, a przy stworzeniu sprzężenia zwrotnego budowy układów sekwencyjnych. Tak powstałe układy funkcjonują jako binarne, gdzie neuron opatrzony jednym wyjściem (pobudzeniem) oraz progami jednostkowym realizuje sygnał  $y^{k+1} = x^k$ . Powstały obwód wykazuje tendencję do zachowania się jako jednobitowy rejestr, który zapamiętać może obraz wejścia zdefiniowany pomiędzy dwoma momentami, a zamykająca się w ten sposób pętla sprzężenia zwrotnego finalizuje proces kreowania komórki pamięci. Jak wspomniano model ten obarczony jest istotnymi uproszczeniami, które obejmują:

- obsługę stanów binarnych jedynie w zakresie 0,1;
- definicję poprzez dyskretny czas pracy;
- synchronizm działania wszystkich neuronów założonych w architekturze sieci;
- niezmiennosc wag oraz progów.

Przyjmując takie założenie można opisać sztuczny neuron poprzez element przetwarzający, który połączony jest z wejściami synaptycznymi, a zakończony jednym wyjściem. Wówczas realizowany przepływ informacji jest tylko jednokierunkowy, pobudzany sygnałem wyjściowym neuronu:

$$y = f(\mathbf{w}^T \mathbf{x}) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (3.2)$$

gdzie:

$\mathbf{w}$  – wektor wag (moc śladu pamięciowego) równy:  $\mathbf{w} \stackrel{\text{def}}{=} [w_1, w_2 \dots w_n]^T$

$\mathbf{x}$  – wektor wejściowy równy:  $\mathbf{x} \stackrel{\text{def}}{=} [x_1, x_2 \dots x_n]^T$

Opis ten nie uwzględnia jednak wartości progowej neuronu  $\theta$ , po wprowadzeniu której elementami składowymi sztucznego neuronu są:

- $n$  sygnałów wejściowych  $x_i$  z wagami  $w_i$  (wagi, czyli pewne wartości liczbowe, których dobór i interpolacja zależą od przyjętego modelu SSN);
- jeden sygnał wyjściowy  $y$ ;
- pobudzenie  $e$  neuronu, które jest sumą ważonych sygnałów wejściowych wyrażone jako:


(3.3)

$$e = \sum_{i=1}^n w_i \cdot x_i - \theta$$

gdzie:

 $\theta$  – wartość progowaFunkcja  $f(\mathbf{w}^T \mathbf{x})$  to funkcja aktywacji (przejścia)  $f(e)$ .

Neuron posiada określoną liczbę wejść, do których wprowadzone są dane wejściowe:  $x_1, x_2, \dots, x_n$ , z połączonymi wagami:  $w_1, w_2, \dots, w_n$ . Proces zainicjowany przez dane wejściowe (istotna jest moc sygnału wejściowego) odzwierciedlany jest przez dwie podstawowe informacje zachodzące wewnątrz neuronu. Pierwsza polega na wyznaczeniu zagregowanej wartości wejściowej i realizowana jest przy wykorzystaniu funkcji agregującej, zwanej także „funkcją potencjału postsynaptycznego” (*funkcja PSP*). Drugi proces polega na wyznaczeniu wartości wyjściowej neuronu, za której wyznaczenie odpowiedzialna jest funkcja aktywacji (*funkcja przejścia*). W ogólności procesy te przedstawić można za pomocą schematu przedstawionego na rysunku 3.4.



Rysunek 3.4. Schemat działania modelu sztucznej sieci neuronowej, odzwierciedlający procesy zachodzące wewnątrz neuronu

Szczególnie ważna jest tutaj funkcja aktywacji, ponieważ zagregowana wartość wejściowa neuronu przyjmuje wartości parametrów funkcji aktywacji dla danego neuronu. Dziedzinę tej funkcji stanowi zbiór wszystkich elementów pobudzających neuron  $e$ . Można to odnieść do neuronu biologicznego pobudzanego przez potencjał, podczas gdy w neuronie sztucznym proces pobudzenia zachodzi poprzez funkcję o zbiorze łącznych pobudzeń dla neuronu. Funkcje takie można opisać w postaci:

➤ bipolarniej funkcji ciągłej

(3.4)

$$f(e) = \frac{2}{1 + \exp(-\lambda e)} - 1, \quad \lambda > 0,$$



- bipolarnej funkcji binarnej (dyskretnej) (3.5)

$$f(e) = \operatorname{sgn}(e) = \begin{cases} +1, & \text{gdy } e \geq 0, \\ -1, & \text{gdy } e < 0. \end{cases}$$

Funkcje te przy odpowiednim skalowaniu przyjmują postać:

- unipolarnej funkcji ciągłej (3.6)

$$f(e) = \frac{2}{1 + \exp(-\lambda e)}, \quad \lambda > 0,$$

- unipolarnej funkcji binarnej (dyskretnej) (3.7)

$$f(e) = \begin{cases} 1, & \text{gdy } e \geq 0, \\ 0, & \text{gdy } e < 0. \end{cases}$$

Powyższe funkcje ciągłe nazywane są funkcjami sigmoidalnymi. Wyróżnia się podstawowe typy funkcji aktywacji takie jak: liniową i nieliniową, a do popularnych można zaliczyć jeszcze: logistyczną, hiperboliczną, wykładniczą, sinusoidalną oraz równanie Gaussa [134]. Istotne jest również to, iż cechą wspólną dowolnych sieci neuronowych jest struktura składająca się z neuronów połączonych ze sobą synapsami.

Podstawową cechą sieci neuronowych jest ich zdolność samoorganizacji oraz adaptacji do zmieniających się warunków, co wynika wprost z możliwości doboru wag, które mogą zmieniać się w procesie uczenia. Algorytmy SSN są narzędziem postrzeganym jako informatyczne, aczkolwiek uczące się w czasie, bowiem mają one zdolność dostosowania zasobu posiadanej wiedzy, do możliwości jej dynamicznej zmiany. Jest to cecha fundamentalna, gdyż zdolność ta determinuje możliwość samouczenia się, co w sposób znaczący przyspiesza wykonywanie obliczeń. Uczenie polega tutaj na zmianach współrzędnych neuronów, w taki sposób, aby dążyły one do wzorca zgodnego ze strukturą analizowanych danych. Wobec tego kalibracja modelu fenomenologicznego (abstrakcyjnego) utworzonego przez sieć polega na adekwatnym doborze wag w procesie uczenia. Istotnym elementem SSN jest proces uczenia sieci. Wyróżnia się dwa podstawowe sposoby nauki:

- uczenie nadzorowane;
- uczenie nienadzorowane.

W trakcie uczenia się niektóre połączenia (wagi między neuronami) nabierają większego znaczenia, a niektóre nie biorą udziału w rozwiązaniu problemu (można by to porównać do zanikających połączeń w mózgu), dlatego istnieje możliwość określenia, które zmienne są istotne do rozwiązania istniejącego problemu [134]

Charakterystyka sieci neuronowej zależy w znacznym stopniu od sposobu połączenia neuronów, czyli tzw. architektury sieci. Ze względu na tę cechę można wyróżnić:

- sieci jednokierunkowe;
- sieć rekurencyjne;
- samoorganizujące się mapy.

W sieciach jednokierunkowych występuje tylko jeden kierunek przepływu sygnałów. Wybrany pojedynczy sygnał przechodzi w takiej sieci przez każdy neuron dokładnie jeden raz w swoim cyklu. Sieci tego typu dzielą się na jednowarstwowe, dwuwarstwowe i wielowarstwowe. Najbardziej efektywnymi sieciami są sieci wielowarstwowe składające się z warstwy wejściowej, warstw ukrytych i warstwy wyjściowej. Sieci rekurencyjne i samoorganizujące się mapy to w istocie sieci wielokierunkowe charakteryzujące się m. in. sprzężeniem zwrotnym lub uczące się przez współzawodnictwo. Poniżej przedstawiono wybrane typy sieci neuronowych:

- warstwowe sieci liniowe (Adaline / Madaline, Perceptron Wielowarstwowy);
- warstwowe sieci nieliniowe:
  - sieci uczone algorytmem wstecznej propagacji błędów (BP);
  - sieci z funkcjami o symetrii kołowej (RBF);
- sieci ze sprzężeniem zwrotnym:
  - sieci Hopfielda;
  - sieci z dwukierunkową pamięcią asocjacyjną (BAM);
- sieci uczone przez współzawodnictwo:
  - sieci Kohonena (LVQ);
  - sieci samoorganizujące się (SOM);
- sieci rezonansowe (ART);
- sieci hybrydowe.

Jednokierunkowe sieci wielowarstwowe (MLP – multilayer perceptron) – są najczęściej stosowaną w praktyce architekturą neuronową. Duży rozwój tego typu sieci związany był z opracowaniem algorytmów wstecznej propagacji błędów (ang. Error Back Propagation), który umożliwił skuteczne i efektywne trenowanie sieci – zostanie on szczegółowo opisany w dalszej części pracy. Przesłanki dotyczące stosowania sieci neuronowych MLP:

- dostępna jest duża liczba wejść;
- istnieje zależność pomiędzy wejściem, a wyjściem;
- analizowany problem wykazuje się dużą złożonością, ale istnieje rozwiązanie;
- rozwiązanie problemu może ulec zmianie w granicach podanych parametrów wejściowych;
- wyjścia mogą być rozmyte lub niejednoznaczne.

Sieci RBF – sieci o radialnych funkcjach bazowych charakteryzujące się zazwyczaj zastosowaniem jednej warstwy ukrytej zawierającej neurony radialne. Podstawą do poprawnego modelowania zależności przy wykorzystaniu neuronów radialnych jest odpowiedni dobór ich liczby ze względu na dużą nieliniowość funkcji aktywacji. Sieci RBF posiadają kilka zalet w porównaniu do sieci MLP. Zaliczyć do nich można:

- zdolność do modelowania dowolnej funkcji przy zastosowaniu jednej warstwy ukrytej;
- prostsza transformacja liniowa w warstwie wyjściowej (minimalizacja problemu minimum lokalnego);
- szybsze uczenie (nawet o rząd wielkości).

Sieć Kohonena charakteryzuje się posiadaniem dwóch warstw:

- warstwa wejściowa;
- warstwa wyjściowa składająca się z neuronów radialnych (mapa topologiczna).

Neurony są rozmieszczane w przestrzeni według określonego wzorca, tworząc mapę topologiczną na zasadzie podobieństwa neuronów. Taka architektura sieci może być pomocna przy analizie podobieństw przypadków. W przypadku rozwiązania z użyciem

sieci Fuzzy ARTMAP (sieć rezonansowa) w trybie uczenia pod nadzorem współpracują ze sobą dwa układy oparte na koncepcji ART (ang. *Adaptive Resonance Theory*). Poszczególne układy ART są systemami pracującymi bez nadzoru. Kolejne obserwacje analizowane są równoległe i niezależnie w warstwie wejściowej i wyjściowej. System Fuzzy ARTMAP rozbudowuje oddzielny blok pamięci powiązań pomiędzy kategoriami wejścia i wyjścia, zapamiętując w ten sposób, jakie zestawy danych odpowiadają określonym właściwościom materiału. Jak stwierdzono w pracy [135], za pomocą tego rodzaju sieci, w przypadku danych silnie niejednorodnych (np. z zakresu technologii betonu), uzyskano poprawne rezultaty obliczeń. Przykładem oprogramowania opartego na koncepcji wstecznej propagacji błędów są jednokierunkowe sieci wielowarstwowe MLP (perceptron wielowarstwowy, ang. *Multilayer Perceptron*). Działanie takiej sieci można opisać za pomocą sekwencji kroków:

- wprowadzenie danych wejściowych;
- określenie wyjściowych wartości neuronów ukrytych;
- ustalenie wartości warstwy wyjściowej.

Determinantą wartości wyjściowej są wagi neuronów definiowane w obrębie poszczególnych warstw (ukrytej, wyjściowej). Istotna jest również architektura sieci neuronowej oraz sposób jej trenowania (nauki) – zwykle odbywa się on z „nauczycielem”. Uczenie przeprowadza się w celu wygenerowania wartości wag, dla których wyjściowe wartości z predykcji będą zbliżone z tymi rzeczywistymi. Proces uczenia ma w efekcie spowodować zmniejszenie błędów sieci, który stanowi zagregowana miara różnic pomiędzy wartościami rzeczywistymi wyjściowymi, a obliczonymi. Z uwagi na kierunek przepływu informacji o błędach, algorytm uczenia tej sieci nazywany jest algorytmem wstecznej propagacji błędów (BP – ang. *Back Propagation*) (tzn. każdy neuron lokalnie zmniejsza swój błąd) i jest najbardziej rozpowszechnionym rozwiązaniem sztucznych sieci neuronowych. Sieci tego typu uczą się raczej powoli i mają tendencję do poprawnego odtwarzania stosunkowo gładkich odwzorowań, pozbawionych nieciągłości, tzn. przy faktycznych nieciągłościach sieci te generują znaczne błędy [135]. W takiej sieci można zidentyfikować przepływ informacji zorientowany od warstwy wejściowej do wyjściowej – transportowana jest informacja niezbędna do obliczenia zmiennych wyjściowych, a od warstwy wyjścia do wejścia przesyłana jest informacja o błędach wykorzystywanym w trakcie procesu uczenia. Trzeci rodzaj oprogramowania bazującego na metodzie najbliższych sąsiadów obrazować mogą sieci RBF. Sieć RBF (ang. *Radial Basis Function*) o radialnych funkcjach bazowych posiada trzy warstwy: wejściową (neurony liniowe), ukrytą (neurony radialne), wyjściową (neuron liniowy). Uczenie sieci o radialnych funkcjach bazowych składa się z trzech etapów: określenia centrów radialnych, odchyleń radialnych, wartości wagi neuronu warstwy wyjściowej. Etap pierwszy to dobór centrów funkcji bazowych poprzez określenie wartości wag dla każdego neuronu radialnego – są to punkty, dla których wartość wyjściowa neuronu będzie maksymalna. Drugi etap sprowadza się do doboru szerokości funkcji aktywacji – parametru określającego kształt funkcji aktywacji, przechowywanego jako wartość progowa neuronu radialnego. Określenie kształtu (szerokości) funkcji aktywacji odbywa się za pomocą metody najbliższych sąsiadów. Polega ona na tym, że w charakterze przyjmuje się odchylenie standardowe z odległości pomiędzy wektorem wag rozpatrywanego neuronu a wektorami wag najbliższych neuronów radialnych. Informacja o szerokości funkcji aktywacji przechowywana jest w postaci wartości progowej neuronu. Sieć RBF charakteryzuje się znacznie prostszą topologią, aniżeli sieć MLP. Ponadto sieci tego typu mogą okazać się nadmiernie wrażliwe nawet na nieliczne błędy lub anomalie

w danych uczących, dotyczących zmiennych ilościowych i jakościowych, np. mieszanki betonowej. Dane poddawane analizie, w przypadku korzystania z SSN, dzielone są na następujące zbiory noszące nazwy:

- zbiór uczący (ok. 70% liczebności przypadków);
- zbiór testowy (ok. 15% liczebności przypadków);
- zbiór walidacyjny (ok. 15% liczebności przypadków).

Taki podział danych sprawia, że sieć neuronowa losuje 85% danych, na których przebiega proces uczenia i korygowania wag dla wprowadzonych danych wejściowych (np. stosunek wodno-spoiwowy, masa: wody, cementu, mikrokrzemionki, kruszywa, oznaczenie rodziny betonu). Zbiór walidacyjny pozwala natomiast na ocenę (egzamin) prognozowanej wartości, np. wytrzymałości z wartościami, których program się nie uczył, ani nie testował.

### 3.2.6. Podsumowanie

Tematyka dotycząca zastosowania i implementacji sieci neuronowych do rozwiązywania konkretnych problemów jest niezwykle szeroka, stąd przedstawiono minimalistyczny opis niezbędny do zapoznania się z tymi strukturami. W ramach niniejszej pracy traktowane są one jako element aparatu matematycznego (a nie przedmiot pracy) wykorzystywanego do osiągnięcia efektu w postaci realizacji tezy pracy – zawartej w kolejnym rozdziale. Poniżej przedstawiono podsumowanie rozważań powyższego rozdziału podkreślając najistotniejsze, z punktu widzenia autorki, cechy sieci neuronowych.

SSN stworzone jako programy komputerowe wygenerowano tak, aby przekształcać dane liczbowe w sposób, który jest wzorowany na funkcjonowaniu komórek nerwowych w mózgu. Podstawowym elementem składowym sztucznej sieci neuronowej jest element przetwarzający. Jest on specyficznym modelem rzeczywistych komórek wchodzących w skład układu nerwowego, odpowiedzialnego za przetwarzanie i analizę informacji w organizmie ludzkim. Rzeczywistą komórkę nerwową można traktować jako biologiczny system przetwarzania informacji. Informacje wprowadzone za pośrednictwem wejść (dendrytów) są przetwarzane wewnątrz komórki. Przetworzony sygnał przesyłany jest za pomocą aksonu do kolejnych komórek. Ze względu na to, że sztuczne sieci neuronowe są narzędziem imitującym w uproszczony sposób pracę ludzkiego mózgu, nie można ich wykorzystać tam, gdzie potrzebne są precyzyjne i jasne wyniki – np. do obsługi kont bankowych. Sztuczne sieci neuronowe operują tak zwanymi pojęciami rozmytymi: mały, duży, jasny, ciemny, niski, wysoki itd. Dlatego też nie przydadzą się do skomplikowanych obliczeń. Stanowią ciekawy i bogaty model odzwierciedlający ludzki system nerwowy, będąc jednocześnie znacznie uproszczonym i przez to łatwiejszym do zaimplementowania. Bardzo ważną cechą sieci neuronowych jest możliwość ich uczenia się – potrafią przekształcać i modyfikować parametry poszczególnych neuronów tak, aby zwiększyć efektywność rozwiązywania zadań. Możliwe jest wykorzystanie sieci neuronowych w przypadkach, gdzie aktualne programy i komputery sobie nie radzą. Ze względu na równoległość obliczeń cechują się zdecydowanie szybszą pracą, możliwe jest także pominięcie etapu konstruowania algorytmu do rozwiązania danego problemu. Dzięki możliwości uczenia, sieci neuronowe potrafią działać skutecznie nawet w przypadku, gdy nie zna się algorytmu niezbędnego do rozwiązania określonego zadania. Każdy element sieci realizuje wszystkie czynności, dla-

tego też może ona poprawnie działać w przypadku uszkodzenia znacznej liczby elementów wchodzących w jej skład. Istnieje wiele rodzajów sieci neuronowych, jednakże najpowszechniej stosowanymi są: perceptron wielowarstwowy, sieci RBF oraz sieci Kohonena.

### **3.3. Sztuczne sieci neuronowe w projektowaniu mieszanek betonowych oraz predykcji cech kompozytu cementowego**

#### **3.3.1. Wprowadzenie**

Należy zaznaczyć, że badania eksperymentalne w zakresie betonów znacznie wyprzedziły rozważania teoretyczne [13,20,45,136–138], co autorka starała się wyeksponować w rozdziale 2. Warto więc podkreślić w tym miejscu wagę procesu kształtowania struktury betonów wysokowartościowych o niskim stosunku wodno-spoiwowym w celu otrzymania kompozytu o założonej wytrzymałości. W przypadku betonów zwykłych, wystarczająco dokładne okazują się tradycyjne metody, opierające się na prostym bilansie objętościowym składników (np. metoda trzech równań [82]), umożliwiające stosunkowo dokładne oszacowanie wytrzymałości. W odniesieniu do betonów o niskim stosunku wodno-spoiwowym metody te dają zbyt duże rozbieżności pomiędzy obliczoną wartością wytrzymałości na ściskanie, a otrzymaną w rzeczywistości [3,29,77,82,86,88]. Modele te, zwykle zapisane w formie empirycznej, korzystają ze znanych powszechnie zależności matematycznych obciążonych niekiedy dużymi uproszczeniami.

#### **3.3.2. Uczenie maszynowe adaptowane do rozwiązywania zagadnień technologii betonu**

Uczenie maszynowe należy do dziedziny sztucznej inteligencji i jest wykorzystywane do przewidywania, tj. klasyfikacji przewidywanych wartości kategoriycznych lub regresji, czyli predykcji wartości liczbowej również w zakresie projektowania mieszanek betonowych [94,139–143]. Niektóre badania dotyczące mieszanek betonowych, wykorzystujące uczenie maszynowe, koncentrowały się na tworzeniu ich modelu z określonymi składnikami, generując modele przewidujące ich wytrzymałość na ściskanie [144–147]. Projektowanie mieszanki betonowej, mającej stanowić kompozyt wysokowartościowy to złożony proces planowania składu ilościowego i jakościowego w celu uzyskania odpowiednich proporcji, rzutujących na pożądaną wytrzymałość na ściskanie. W dziedzinie inżynierii lądowej uzyskanie projektu mieszanki betonowej jest procesem trudnym i wrażliwym na wszelkie zmiany. Zagadnienie wyznaczania parametrów betonu komplikuje się w przypadku mnogości parametrów jego składu (m. in. różnych właściwości cementu i jego zawartości, różnych właściwości i zawartości domieszek chemicznych), warunków wykonania i pielęgnacji, a także agresywnych oddziaływań środowiskowych. Parametry te odgrywają dużą rolę w definiowaniu wytrzymałości na ściskanie, a jeden projekt mieszanki jest skuteczny tylko dla jednej, założonej i eksperymentalnie wyznaczonej wytrzymałości na ściskanie. W każdym procesie produkcyjnym, który obejmuje różnice we właściwościach materiału, koniecz-

ny jest nowy projekt mieszanki. Sytuacja taka prowadzi do uzyskania niedokładnych wyników projektowania konwencjonalnej mieszanki, co udowadnia, że ręczne projektowanie mieszanek jest jedynie oszacowaniem [144,148,149]. Statystyczne, eksperymentalne metody projektowania opisane w rozdziale drugim są podstawową techniką pozwalającą na osiągnięcie pożądanych właściwości i optymalizację mieszanki o pożądanej wytrzymałości. Metody te są szeroko stosowane w przemyśle do optymalizacji procesów i produktów, znalazły także zastosowanie w niektórych badaniach nad ulepszeniem betonu poprzez kształtowanie mieszanki betonowej z założeniem uzyskania kompozytu o wysokich parametrach. Dzięki zastosowaniu metod statystycznych w procesie realizacji wsadu próbnego, skraca się czas potrzebny na optymalizację wymaganego udziału procentowego różnych użytych materiałów. Próbki do badań są wytwarzane, testowane i następnie analizowane przy użyciu standardowych metod statystycznych.

Wen-Huan Chine podsumował, że wsteczna propagacja SNN jest dokładniejsza w przewidywaniu składu mieszanki betonowej do konstrukcji z wielokrotną regresją liniową [150]. Ten sam wniosek dotyczący SNN został również przedstawiony w pracy [151]. Uzyskane wyniki, w tym także te przedstawione przez I-Cheng Yeh [152] pokazały, że SSN pozwalają na uzyskanie lepszego modelowania aniżeli regresja oraz są w stanie zapewnić dokładniejszą precyzję w porównaniu z regresją liniową, wielokrotną regresją liniową i regresją nieliniową. Ponadto I-Cheng Yeh również testował odmienne podejścia do modelowania wytrzymałości na ściskanie mieszanki betonowej. W badaniach zastosowane zostały drzewa genetyczne, SNN oraz analiza regresji liniowej. Końcowo potwierdzone zostały wnioski wcześniej podanych autorów [153]. Bahador Abolpour opracował model szacowania wytrzymałości betonu na ściskanie z wykorzystaniem podejścia Fuzzy Logic pokazując zależność projektowej mieszanki od wytrzymałości betonu na ściskanie [148]. Ponadto Ghafari i in. [154] oraz Hammoudi i in. [155] porównali model SSN z innymi klasycznymi modelami, a wyniki wykazały, że model SSN ma wyższą dokładność dzięki wielowarstwowej architekturze sieci i wstecznej propagacji błędów. Sztuczne sieci neuronowe są zatem doskonałym algorytmem wyszukiwania lokalnego, ale posiadają również nieodłączne wady: są bardzo wrażliwe na początkowe wagi (SSN jest inicjowana z różnymi wagami), co powoduje problemy z lokalną wartością minimalną i różnymi wynikami uczenia [156,157]. Konwencjonalne podejścia statystyczne zostały w dużej mierze porzucone, niemniej jednak nadal istnieją. Pomimo faktu, iż analiza regresji [158–163] wydaje się prostsza i łatwiejsza, pojawia się trudność, ponieważ liczba zmiennych niezależnych rośnie, a dokładność maleje (analiza regresji wielokrotnej zwiększa dokładność modelu). W złożonych przypadkach, aby poprawić dokładność przewidywanych modeli, adaptowano różne techniki optymalizacyjne takie jak:

- sztuczne sieci neuronowe [95,96,127,143,147,164–185];
- adaptacyjne neuronowo-rozmyte systemy wnioskowania oparte na Fuzzy Logic [98–100,146,148,182,186–188];
- maszynę wektorów nośnych [189–195];
- projektowanie czynnikowe [196];
- algorytm roju cząstek (*Particle Swarm Optimization, PSO*) [197,198];
- drzewa decyzyjne, losowy las decyzyjny [189,192,194,199,200];
- drzewa modelowe, klasyfikacyjne i regresji [160,162,197,201];
- algorytmy genetyczne, programowanie ekspresji genów [172,195,202–204];

- adaptacyjny sieciowy system wnioskowania rozmytego (ANFIS) [158,161,195,205–207].

Zatem w przypadku złożonych modeli, wytrzymałość można przewidzieć za pomocą różnych modeli mapowania w betonie, zamiast za pomocą równań regresji. Metody stosowane do predykcji parametrów betonu oraz projektowania składu mieszanek betonowych, takie jak SSN są często porównywane z innymi metodami uczenia maszynowego tak, aby ustalić która z nich jest bardziej efektywna. Składniki betonu i właściwości powstałego kompozytu analizowano dotychczas między innymi z użyciem następującego oprogramowania opartego na sztucznych sieciach neuronowych:

- uzyskanego za pomocą implementacji sieci Fuzzy ARTMAP;
- opartego na koncepcji sieci ze wsteczną propagacją błędów BP;
- bazującego na sieciach wykorzystujących połączenia neuronów z innymi neuronami najbliższego sąsiedztwa, metodę najbliższych sąsiadów.

Yeh [170] zaproponował metodę optymalizacji dozowania wysokowartościowej mieszanki betonowej dla danej urabialności i wytrzymałości na ściskanie z wykorzystaniem SNN i programowania nieliniowego. W celu udowodnienia prawidłowości rozważań metodologia została porównana z wynikami eksperymentalnymi dla różnych proporcji mieszanki. Sieci neuronowe typu perceptron wielowarstwowy jako narzędzie służące predykcji i określaniu parametrów fizycznych betonu, były wykorzystywane między innymi w pracach [94,134] na przykład do predykcji wytrzymałości betonu na ściskanie. Guang i Zong [171] wykorzystali sieci neuronowe do przewidywania 28-dniowej wytrzymałości betonu na ściskanie za pomocą wielowarstwowych sieci neuronowych opartych na wstecznej propagacji błędów. Gupta i in. [143,152,208] próbowali wykorzystać SSN do dokładnego przewidywania wytrzymałości betonu na podstawie takich parametrów jak: projekt mieszanki betonowej, rozmiar i kształt próbki, technika i okres utwardzania, warunki środowiskowe. Yeh [143,152] zademonstrował zdolność SSN do modelowania kompozytu zawierającego popiół lotny i beton żuźlowy. Model pomógł zbadać złożone nieliniowe zależności między elementami betonowymi, a zachowaniem się całości betonu. Ozturan oraz Lee [209] wykorzystali technikę ANN do przewidywania 28-dniowej wytrzymałości betonów towarowych o niskiej i średniej wytrzymałości. Dokładność wyników SSN porównano z modelami wielokrotnej regresji liniowej. Alshihri i in. [184] wykorzystali sieci neuronowe do przewidywania wytrzymałości na ściskanie lekkiego betonu konstrukcyjnego. Sieć neuronowa była w stanie z powodzeniem przewidzieć wytrzymałość na ściskanie po 3, 7, 14 i 28 dniach dojrzewania. Aggarwal i Aggarwal [210] przedstawili porównawczą wydajność modeli opracowanych do przewidywania 28-dniowej wytrzymałości na ściskanie przy użyciu sieci neuronowych dla danych zaczerpniętych z literatury i danych opracowanych eksperymentalnie dla betonu samozagęszczalnego, zawierającego popioły paleniskowe jako częściowe zastąpienie kruszywa drobnego. Badania wykazały, że model opracowany na podstawie danych literaturowych można łatwo rozszerzyć o dane eksperymentalne. Oztas i in. [175] wykorzystali czterowarstwową sieć wraz z dwoma ukrytymi warstwami do przewidywania opadu betonu i jego 28-dniowej wytrzymałości na ściskanie. Dzięki uzyskanym wynikom autorzy pracy [175] ustalili, że sztuczne sieci neuronowe są narzędziem o dużej dokładności i możliwe jest ich praktyczne wykorzystanie do prognozowania konsystencji i wytrzymałości betonu na ściskanie. Elsanadedy i in. [211] zastosowali analizę wrażliwości do badań wytrzymałości betonu zbrojonego z włóknami polimerowymi pod kątem wpływu różnych czynników. Po przeprowadzeniu badań stwierdzili, że zastosowana przez nich sieć neuronowa z czterema warstwami

ukrytymi jest znacznie lepsza jako narzędzie prognostyczne w porównaniu do wyników uzyskanych przy wykorzystaniu metody regresji. Przewagę sieci neuronowych nad metodami regresji wykazali także Sobhani i in. [212] prognozując wytrzymałość samozagęszczającej się mieszanki betonowej po upływie 28 dni.

Przez pewien okres wykorzystanie SSN w projektowaniu mieszanek betonowych skupiało się głównie na przewidywaniu optymalnych proporcji mieszanki, a nie na właściwości betonu. Oh i in. [213] jako pierwsi omówili ten temat, opracowując predykcyjny model proporcjonalności mieszanki betonowej. Jednak jak pokazano w pracy [214], podejście to choć przydatne, nadal pociąga za sobą konieczność rozwoju nowego modelu dla każdej zmiany składu mieszanki betonowej. Aktualnie badania koncentrują się na opracowaniu SSN do przewidywania wytrzymałości na ściskanie dla betonu wysokowartościowego, świeżego, zwykłego lub innego. Tabela 3.1 zawiera przegląd dotyczący mieszanek betonowych; przedstawiono różne rodzaje mieszanek, które zostały użyte jako narzędzie do badań przy wykorzystaniu SSN. Część prac skupiała się na problemach technicznych, takich jak wyznaczenie optymalnego algorytmu dla przewidywania wytrzymałości na ściskanie, a inne na czynnikach, które mogą wpływać na jakość wyników zarówno testów eksperymentalnych, jak i modeli predykcyjnych. Lee [215] przedstawił obszerne badanie skuteczności SSN w przewidywaniu wytrzymałości na ściskanie betonu. Opracowanie obejmowało pięć niezależnych modeli z 73 zmiennymi wejściowymi i aż siedmioma wyjściami. Chopra i in. [200,216,217] opracowali modele SSN dla prognozowania wytrzymałości na ściskanie, skupiając się na wykonaniu samego modelu. Autorzy pracy [216] wykorzystali siedem różnych algorytmów, aby określić optymalny zakres zbioru danych. Co więcej, zaobserwowali skuteczność modelu SSN w porównaniu z programowaniem genetycznym [216], drzewem decyzyjnym i modelem losowych lasów [200]. Golareshani i in. [218] porównali wyniki dla modeli SNN oraz ANFIS do tworzenia modeli predykcyjnych dla betonu zwykłego i wysokowartościowego. Ponadto prace badawcze, takie jak [219] skupiały się na wpływie różnych materiałów składowych, w tym przypadku odpadów budowlanych i rozbiórkowych. Badania przeprowadzone przez Yamana i in. [220] skoncentrowały się na samozagęszczalnym betonie o dużej płynności. Opracowano modele SNN z dwoma zestawami danych, gdzie pierwszy model obejmował wszystkie sześć wyjść, a drugi miał postać modelu wiele wejść – jedno wyjście. W odniesieniu do betonów przyjaznych dla środowiska, Elevado i in. [221] przedstawili całkowicie „zielony beton”, zastępując cement portlandzki popiołem lotnym oraz grube kruszywo odpadową ceramiką. SSN wykorzystano do prognozowania wytrzymałości na ściskanie takiego betonu, a wyniki pokazały, że istnieje alternatywa dla tradycyjnego betonu. Przeprowadzono kilka badań z implementacją doświadczeń pochodzących z placów budowy tak, aby ulepszyć modele SSN w sposób pragmatyczny i użyteczny w realistycznych warunkach.

Prace in situ implikują brak możliwości kontroli warunków środowiskowych, które oddziałują na beton zarówno w stanie świeżym, jak i stwardniałym. Dlatego testowanie betonu pobranego w warunkach budowy jest trudniejszym zadaniem niż testowanie betonu z laboratorium; jednak zbiór danych jest znacznie bardziej obszerny i wnikliwy. Namyong i in. [222] przedstawili statystyki badania betonu pobranego w warunkach budowy na podstawie 1442 wyników z 59 różnych mieszanek. Tak duży zbiór danych został wykorzystany do ustalenia równań regresji dla predykcji wytrzymałości na ściskanie. DeRousseau i in. [223] oceniali skuteczność SSN i innych metod uczenia maszynowego do przewidywania wytrzymałości na ściskanie betonu pobranego w warunkach budowy za pomocą dwóch zestawów danych zarówno terenowych, jak



i laboratoryjnych. Ta praca potwierdziła, że dokładne przewidywanie wytrzymałości betonu polowego na ściskanie jest osiągane za pomocą modeli uczenia maszynowego, trenowanych na podstawie danych zebranych dla betonu pobranego w warunkach budowy. Za pomocą hybrydowych danych szkoleniowych przewidywano wydajność betonu laboratoryjnego, przy czym modele mogą zostać znacznie ulepszone. Ponadto praca Younga i in. [192] zawierała prawdopodobnie najobszerniejszy zbiór danych, jaki kiedykolwiek wykorzystano w tego typu badaniach. Modele SNN zostały oparte na ponad 10 000 próbek danych, uzyskanych z placów budowy i testowanych laboratoryjnie. Prognozowanie z użyciem SSN obejmowało również właściwości mechaniczne stwardniałego betonu, takie jak:

- wytrzymałość na zginanie [224] dla zaprawy z dodatkiem zeolitu modyfikowanego lub dla kompozytów hybrydowych [225];
- moduł sprężystości betonu z kruszywem recyklingowym [226];
- współczynnik Poissona dla betonu lekkiego [227];
- wytrzymałość zmęczeniowa [228];
- odporność na zamrażanie i rozmrażanie [229];
- właściwości elektryczne [230].

Prowadzono również badania ukierunkowane na właściwości świeżego betonu, takie jak:

- skurcz [231];
- przepuszczalność chlorków [232,233];
- dyfuzyjność [234];
- zawartość wolnych przestrzeni powietrznych [235];
- zależność wytrzymałości na ściskanie od mikrostruktury betonu [236].

Tabela 3.1. Różne rodzaje mieszanek betonowych badanych za pomocą SSN

Typ kruszywa/rodzaj spoiwa	Zwykły cement	Pył krzemionkowy	Żużel wielkopiecowy	Popiół lotny	Mikro i Nano-krzemionka	Metakaolinit
Standaryzowane kruszywo drobne/grube	[192,193, 198,200, 207,213, 216,222, 223,237–240]	[162, 175,179, 188,212, 241, 242]	[160,162, 190–192,194, 206,218, 237,243–248]	[160,162, 175,179, 190–192,194, 203,206, 237,242–246,249]	[203,245, 250]	[241,251]
Kruszywo pochodzące z recyklingu betonu	[155,167, 252–255]	bd.	bd.	[256,257]	bd.	bd.
Kruszywo pochodzące z recyklingu gumy	[258,259]	[195]	bd.	bd.	bd.	bd.
Pył bazaltowy	[259]	bd.	[260]	bd.	bd.	bd.
Kruszony wapień/piasek	[181,261, 262]	[205]	bd.	bd.	bd.	bd.
Popiół z łusek ryżowych	[255]	[205, 263]	bd.	[263]	[263]	[263]
Kruszywo sztuczne	[260,264]	[205]	bd.	[265]	[265]	[265]

Osiągnięcia w badaniach nad modelowaniem projektów mieszanek betonowych przedstawia również Mehdi Nikoo w pracy [266] gdzie prezentuje proces predykcji uzyskany dzięki ewolucyjnym sztucznym sieciom neuronowym. Badania obejmowały algorytmy genetyczne do określania optymalnych wag SSN, a wynikowo stwierdzono, że można poprawić wydajność niektórych algorytmów, w tym maszyny wektorów nośnych oraz SNN (Spiking Neural Networks) [267–269]. Zaprezentowano wyniki algorytmów genetycznych oraz SNN stwierdzając, że wartość współczynnika korelacji parametru wytrzymałości betonu na ściskanie dla okresu czasu wynosi 0,910, dla testowania jest równa 0,935, a w przypadku walidacji wynosi 0,899. Uzyskano wysokie wartości dla zgodności, ale ograniczone tylko do kilku parametrów, takich jak: cement, piasek, żwir i woda. Uwzględniając parametry wraz z dodatkami: elementami popiołu węglowego (popiołu lotnego), żużla wielkopieczowego i innymi dodatkami, wartości współczynnika korelacji można zmniejszyć. Dlatego tak niezbędnym jest przeprowadzenie badań obejmujących złożone parametry.

### 3.3.3. Baza danych i topologia sieci

Na podstawie powyższego można stwierdzić, że praktyczne spostrzeżenia są niezwykle ważne, jednak pełne zrozumienie istoty procesu kształtowania struktury wymaga wnikliwej analizy teoretycznej tego problemu. Z tego względu należy podkreślić wyższość metod analityczno-doświadczalnych nad doświadczalnymi. Kalibracja modeli teoretycznych jest niezbędna dla każdorazowej zmiany parametrów wejściowych, jak również przy wprowadzeniu nowych zmiennych. Proces kalibracji wymaga przeprowadzenia badań laboratoryjnych próbnymi seriami betonów. Te czynności badawcze wymagają określonych nakładów czasowych i finansowych. W celu ograniczenia zakresu czasochłonnych i często kosztownych prac laboratoryjnych, potrzebnych do kalibracji modeli stosowanych w poszczególnych metodach, istnieje możliwość wykorzystania sztucznych sieci neuronowych do predykcji dowolnej cechy betonu, jak również świeżej mieszanki. Uzyskana na podstawie badań eksperymentalnych baza posłuży do utworzenia programu pozwalającego na szybkie i efektywne projektowanie mieszanki betonowej, służącej do produkcji betonu wysokowartościowego. Stosowanie metod sztucznej inteligencji, takich jak sztuczne sieci neuronowe, wymaga przygotowania odpowiednich baz danych. Bazę danych można zaprezentować w postaci macierzy złożonej z wierszy i kolumn, które wypełniają nie tylko liczby, ale także charakterystyki jakościowe i nazwy. Istotne jest odpowiednie określenie struktury baz danych oraz analiza danych eksperymentalnych. Podstawowym zadaniem jest uzgodnienie jednolitej formy rejestracji i przekazywania kompletnych danych. Składają się one z danych wejściowych, stanowiących informację o tym co wiadomo o danym materiale i jego wykonaniu oraz danych wyjściowych dotyczących cech, właściwości, które będą poddawane dalszej analizie i predykcji. Podczas opisu różnych zadań, ta sama wielkość może być inaczej rozpoznawana. Przykładem może być wytrzymałość betonu na ściskanie. Przy predykcji tej cechy betonu na podstawie składu ilościowego mieszanki betonowej, wytrzymałość ta może być zmienną wyjściową (tj. szukaną). Z kolei podczas rozważań dotyczących właściwości mechanicznych betonu, po pewnym czasie, może być definiowana jako zmienna wejściowa.

W odniesieniu do betonu o niskim stosunku wodno-spoiwowym bazę danych stanowi wyselekcjonowany i uporządkowany zestaw informacji na temat tego materia-


łu, technologii, eksploatacji, jego cech i właściwości. Opracowanie bazy danych, w oparciu o parametry betonu o niskim stosunku wodno-spoiwowym, będzie elementem podejmowanym w dalszych rozważaniach niniejszej pracy. Po zbudowaniu bazy danych będzie można przystąpić do określania topologii sieci neuronowej, tj. określenia liczby danych wejściowych i wyjściowych, ustalenia liczby i organizacji neuronów w poszczególnych warstwach, sprecyzowania funkcji aktywacji i błędu. Badane będą betony, których składniki zmieniać się będą w stosunkowo niewielkim zakresie, ponieważ niewielka zmiana stosunku wodno-spoiwowego będzie miała znaczący wpływ na przebieg zmian fazowych w zaczynie cementowym. Zaczyn o ilości wody wynikającej z wodozadności normowej spoiwa jest ośrodkiem, w którym osiągnięto maksymalną szczelność upakowania ziaren fazy stałej [29,88]. Sytuacja ta odpowiada całkowitemu wypełnieniu przestrzeni międzyziarnowych wodą, zaś grubość warstwy wodnej otoczki na ziarnach osiąga minimalną wartość wynikającą z sił oddziaływania elektrostatycznego. Jeżeli  $\omega < \omega_n$ , to elektryczne warstwy podwójne otaczające sąsiadujące ze sobą ziarna zaczynają na siebie zachodzić, co uniemożliwia przedostanie się wody pomiędzy ziarna cementu. Dochodzi do powstania wolnych (wypełnionych powietrzem) przestrzeni międzyziarnowych. Konieczne jest zatem stosowanie superplastyfikatorów oraz specjalnych metod zagęszczania. Złożoność owego zagadnienia wpływa na dobór adekwatnej sieci neuronowej. Dane wejściowe stanowiąc mogą zmienne ilościowe i jakościowe:

- zmienne o charakterze ilościowym (stosunek wodno-spoiwowy, masa: wody, cementu, mikrokrzemionki, kruszywa);
- zmienne o charakterze jakościowym (np. oznaczenie rodziny betonów);
- czynniki technologiczne.

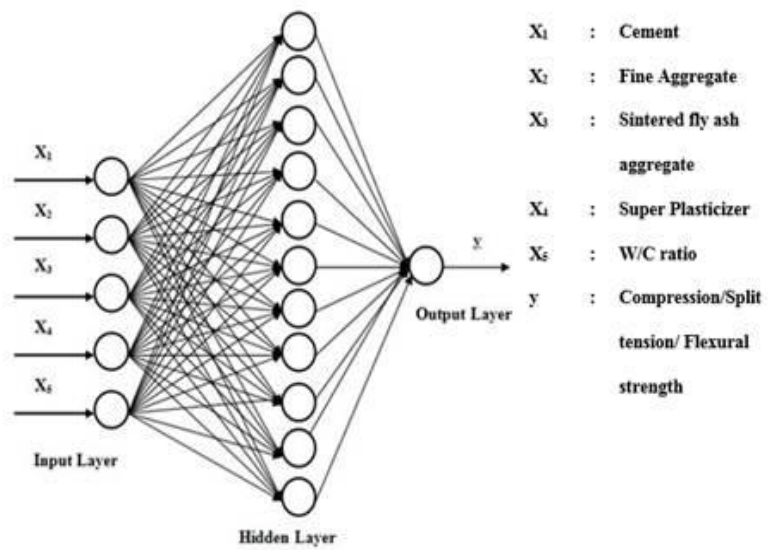
Dane wyjściowe mogą stanowić wprost parametry betonu:

- wytrzymałość betonu na ściskanie;
- mrozoodporność;
- nasiąkliwość;
- wytrzymałość betonu na rozciąganie;
- urabialność;
- trwałość;
- ścieralność;
- trwałość.


Topologia sieci wynika zatem z rodzaju zadania, jakie ma zostać rozwiązane. Decyzje dotyczące struktury sieci nie wpływają na jej zachowanie w stopniu decydującym. Przykładowe architektury sieci przedstawiono na rysunkach 3.5 – 3.9.



Rysunek 3.5. Architektura sieci według Santosa [270]



Rysunek 3.6. Architektura sieci według Nagarajan [271]



Rysunek 3.7. Architektura sieci według DeRousseau [223]




Fig. 1. Single ANN architecture.





Fig. 2. Modular ANN architecture.

Rysunek 3.8. Architektura sieci według Lee [215]



Rysunek 3.9. Architektura sieci według Mohammada Adil [272]

W pracy [271] (architektura sieci przedstawiona na rys. 3.6) zdefiniowano problem z czynnikami wpływającymi na nieliniową zależność między wejściami i wyjściami w przypadku 28-dniowej wytrzymałości betonu na ściskanie, rozciąganie i zginanie. Architektura modelu sieci na wspomnianym rysunku pokazuje, że warstwa wejściowa składa się z 5 węzłów, warstwa ukryta ma 11 węzłów i jedna warstwa wyjściowa odpowiada wytrzymałości (ściskanie, rozciąganie i zginanie). Do przewidywania 28-dniowej wytrzymałości na ściskanie betonu z kruszywem normalnym zastosowano

jednowarstwowy model SNN podobny do zastosowanego w pracy [240]. Wykazał on dobrą dokładność przewidywania. Podobnie skuteczny okazał się model z 11 wejściami, siedmioma neuronami w jednej ukrytej warstwie oraz jednym wyjściem i siedmioma wyjściami (odpowiednio pięć i trzy neurony w każdej warstwie ukrytej oraz dwa wyjścia). Oznacza to, że trenowanie i walidacja poprawności odgrywają główną rolę podczas korzystania z narzędzia prognozowania. Ponadto model SSN ma pojedynczą strukturę warstw ukrytych, używaną również m. in. do przewidywania współczynnika Poissona [227] oraz wytrzymałości na ściskanie w oparciu o zmierzoną prędkość impulsu ultradźwiękowego [273]. Podobnie w pracy [164] do wykonania predykcji wytrzymałości betonu na ściskanie (w zależności od prędkości fali ultradźwiękowej, liczby odbić, siły wyrwywającej, wieku betonu, gęstości pozornej) wykorzystano sieć jednokierunkową wielowarstwową, opartą na algorytmie wstecznej propagacji błędu. Architekturę zdefiniowano jako pięć danych wejściowych (jedna warstwa ukryta zawierała 10 neuronów oraz jedno wyjście). Wyniki eksperymentalne przedstawione w tej pracy potwierdziły przydatność SSN do modelowania nieliniowej zależności między różnymi parametrami, a właściwościami betonu. Istotne czynniki wpływające na wytrzymałość betonu zidentyfikowano jako cement, kruszywo grube, kruszywo drobne, superplastyfikator i stosunek wodno-cementowy.

Jak stwierdzono w [272] wybór liczby neuronów w różnych warstwach sztucznej sieci neuronowej (SNN) jest kluczowym krokiem decyzyjnym związanym z jej pomyslnym trenowaniem. Chociaż o liczbie neuronów w warstwie wejściowej decyduje liczba parametrów wejściowych i podobnie w warstwie wyjściowej liczba neuronów jest ustalona przez parametry wyjściowe, o tyle liczba neuronów w warstwie ukrytej nie jest stała, przy czym ogólna wydajność SSN zależy od prawidłowego zamodelowania realistycznego rozwiązania w postaci sieci neuronowej. Beton można realizować poprzez wiele składów, aby osiągnąć określone wyniki lub ich kombinację. Zaobserwowano, że wyniki te powtarzają się i podążają za wzorami. Ponadto w przypadku kilku rodzajów mieszanek betonowych dostępne są tylko rzeczywiste dane laboratoryjne, bez metody projektowania mieszanki. Sprawia to, że osiągnięcie różnych wymaganych wyników jest zadaniem bardzo złożonym i kosztownym. Posiadanie SSN, umożliwiającej przewidywanie mieszanki betonowej w celu obsługi takich zmian pozwoli zaoszczędzić dużo czasu i pieniędzy. W pracy [213] Ju-Won Oh i in. prezentują implementację SSN opartą na wstecznej propagacji błędu, składającej się z warstwy wyjściowej, zawierającej skład mieszanki (zawartość wody, cementu kruszywa drobnego i grubego), 10 neuronów w warstwie ukrytej oraz sześć wejść w postaci wymaganej wytrzymałości na ściskanie, maksymalnej frakcji, stosunku w/c, zawartości piasku i pyłu. Na takiej sieci testowano 372 elementową macierz danych wyodrębniając z niej zbiór uczący i testowy.

W pracy [274] testowano zbiór 70 danych, a SSN z 22 węzłami została uznana za optymalną dla przypadku jednej warstwy ukrytej. Maksymalny procentowy błąd (1,3526) został uzyskany przy niewielkiej liczbie epok (8). Również SSN z 6 węzłami w pierwszej warstwie ukrytej i 5 węzłami w drugiej warstwie ukrytej uznano za optymalną, ponieważ dała najniższą wartość maksymalnego procentowego błędu (1,2268) przy 98 epokach. Porównanie wydajności wyżej wymienionych SSN wykazało, że oba typy sieci radziły sobie dobrze z tego typu danymi. Jedna ukryta warstwa SSN z 22 węzłami była optymalna ze względu na czasochłonność (mniejsza liczba epok), jednak optymalna była sieć z dwiema ukrytymi warstwami z 5-6 węzłami ze względu na maksymalny procentowy błąd. W rzeczywistości różnica w dokładności między SSN była

bardzo mała w porównaniu z wyższą redukcją w liczbie epok, więc sieć z jedną ukrytą warstwą była bardziej preferowana.

Fangming Deng i in. [257] przedstawili architekturę sieci konwolucyjnej (głębokiego uczenia się) do predykcji wytrzymałość betonu z recyklingu na ściskanie, testując 74 próbki – zastanawiać może w tym przypadku taki rozmiar zbioru danych (mały zbiór danych może skutkować niedopasowaniem – oznacza to, że model nie jest wystarczająco dobrze dopasowany do danych w takim stopniu, co rzutuje tym samym na jego efektywność). Zmienne wejściowe obejmowały: stosunek wody do cementu, stosunek wymiany kruszywa grubego z recyklingu, stosunek wymiany drobnego kruszywa z recyklingu i wymianę popiołu lotnego. W części wyników swojej pracy autorzy stwierdzają, że zastosowana przez nich architektura głębokiego uczenia zapewniła wyższą wydajność, zdolność uogólniania i precyzję w porównaniu ze standardową SSN, przy czym praca [167] wykazuje porównywalny stopień precyzji między SSN, a głębokimi sieciami neuronowymi.

DeRousseau [223] (schemat sieci na rysunku 3.7) przedstawia przykład możliwych wejść i wyjść do modelu. Autor przyjmuje stanowisko, iż w projektowaniu mieszanek betonowych z wykorzystaniem SNN, węzły warstwy wejściowej są zmiennymi decyzyjnymi mieszanki betonowej, a warstwa wyjściowa to cel(e). Zbiór danych stanowiących 73 zmienne decyzyjne mieszanki betonowej (warstwa wejściowa) posłużył do modelowania zależności między wytrzymałością na ściskanie (warstwa wyjściowa). Zmienne decyzyjne pogrupowano w cztery kategorie: istotne proporcje, podstawowe informacje, zmienne pomiarowe oraz historię temperatury i wilgotności. Przewidywalna wydajność modelu jest udoskonalana poprzez „uczenie” sieci na zbiorze danych, który zmienia wagi między węzłami. Seung-Chang Lee w pracy [215] przedstawia sieci neuronowe służące do przewidywania rozwoju wytrzymałości betonu. Architektura sieci pojedynczej uwzględnia wszystkie neurony warstwy wejściowej i wyjściowej. Wyniki predykcji według autora nie są odpowiednie, aby przewidzieć wytrzymałość betonu po zmianie temperatury twardnienia w określonym dniu. Do rozwiązania problemu użyto wiele architektur lokalnych definiujących problem w obrębie jednej pojedynczej architektury globalnej. Oznacza to, że wszystkie dane wejściowe i wyjściowe neuronów są podzielone na kilka architektur i może to dawać ostateczne wyniki poprzez łączenie wyników z indywidualnej architektury, co zostało zaproponowane poprzez sieć modułową SSN, która ma wiele architektur składających się z pięciu SSN (ANN-I~V).

W swoich badaniach Mohammad Adil [272] przeprowadził dogłębną analizę w celu podjęcia decyzji o liczbie neuronów do projektowania mieszanki betonu, a wyniki obliczeń sieci neuronowych dla różnej liczby neuronów i warstw zostały skorelowane. Dla szeregu mieszanek betonowych zostały uporządkowane i znormalizowane dane wejściowe (właściwości składników betonu, takie jak: ciężar właściwy cementu, kruszywa grube i drobne, gęstość objętościowa w stanie suchym kruszyw grubych i drobnych, rodzaj cementu, rodzaj domieszki, stosunek wodno-cementowy, rodzaj i temperatura twardnienia oraz właściwości po twardnieniu, takie jak: wytrzymałość na ściskanie, moduł sprężystości i wytrzymałość na rozciąganie). Stwierdzono, iż struktura sieci ma bezpośredni wpływ na czas nauki i dokładność klasyfikacji, pomimo że nie ma określonej metody lub podejścia w celu określenia najlepszej struktury służącej uzyskaniu zadowolającej wydajności sieci. Architekturę sieci neuronowej, która daje najlepsze wyniki dla określonego problemu można określić doświadczalnie. Potwierdzono, że rozmiar sieci ogólnie wpływa na czas nauki, złożoność i co ważne zdolność generalizacji sieci. Według autorów wymagania obliczeniowe dotyczące uczenia się rosną wraz ze



wzrostem rozmiaru sieci i dlatego preferowane jest, aby rozmiar sieci był jak najmniejszy. Uzyskanie dobrego przybliżenia funkcji nie jest łatwym zadaniem, dlatego trzeba przeszukać szereg architektur sieci. Jeśli liczba neuronów jest mniejsza w porównaniu do złożoności problemu wówczas może wystąpić niedopasowanie, choć z drugiej strony, jeśli w komórce jest zbyt wiele neuronów, spowoduje to nadmierne dopasowanie wpływające na wydajność sieci. Istnieje kilka technik tworzenia sieci w sposób konstruktywny lub destrukcyjny, jednak wspólnymi kryteriami decydującymi o tym, czy sieć ma optymalną architekturę są walidacja krzyżowa i wczesne zatrzymanie. W artykule oceniono kilka sieci neuronowych pod kątem projektowania mieszanek betonowych, stosując technikę budowy sieci, tj. zaczynano od najmniejszej sieci i stopniowo zwiększano liczbę warstw ukrytych i neuronów warstwy ukrytej, aż do osiągnięcia optymalnej architektury. Stwierdzono, że dla 17 wejść i 5 wyjść prosta sieć neuronowa z pojedynczą lub podwójną warstwą ukrytą działała lepiej niż ta posiadająca 3 lub więcej takich warstw (rys. 3.10).

Na podstawie przeglądu zastosowania SSN, przedstawionego w literaturze do przewidywania właściwości betonu można sformułować wnioski odnoszące się do ww. publikacji:

- liczba warstw ukrytych powinna być niewielka;
- więcej ukrytych warstw wydłuża proces uczenia się i często powoduje wynik fałszywie dodatni;
- algorytmy, m.in. Levenberg-Marquardt, wstecznej propagacji błędu, są wybierane zgodnie z charakterem danych i typem danych wyjściowych;
- rozmiar zbioru danych wpływa na wydajność algorytmu, a tym samym na całkowity błąd.

Wielokrotnie zostało wykazane, że algorytm Levenberga-Marquardta oraz wstecznej propagacji błędu najlepiej odpowiada na średniej wielkości zbiór danych zawierający kilkaset próbek. Funkcje aktywacji są domyślnie nieliniowe, głównie sigmoidalne, a tangens hiperboliczny, ponieważ funkcje te pokrywają się z anizotropowym zachowaniem betonu. Testowe próbki powinny być zróżnicowane, aby zapewnić najlepszą ocenę modelu, ale jednocześnie muszą mieścić się w realistycznym przedziale ufności.

### 3.4. Podsumowanie

Cechą wyróżniającą sztuczne sieci neuronowe spośród innych metod komputerowych jest to, iż w sposób szczególnie generują zależności pomiędzy informacją wejściową, a informacją wyjściową. SSN różnią się w istotny sposób od konwencjonalnych programów komputerowych, które można określić jako sekwencyjne, czyli aby rozwiązać problem obliczeniowy należy utworzyć algorytm składający się z zadanego ciągu instrukcji. Są one realizowane w założonej kolejności, więc w programie takim należy przewidzieć wszystkie ewentualności na jakie program ma reagować, np. jak silny jest związek pomiędzy stosunkiem wodno-spoiwowym, a wytrzymałością betonu na ściskanie i następnie odpowiednio zlokalizować je w zadanej instrukcji. W działaniu sieci neuronowej można wyodrębnić etap nauki, kiedy to sieć gromadzi informacje potrzebne jej do określenia co i jak ma robić (w etapie tym mieści się również walidacja), oraz etap normalnego działania, podczas którego opierając się o zdobytą wiedzę sieć rozwiązuje konkretne zadania.

Pomimo powszechnego stosowania betonów od kilku dziesięcioleci, popularność nowoczesnych kompozytów cementowych stale rośnie. Tendencja ta jest uwarunkowana przede wszystkim ciągłymi pracami badawczymi, mającymi na celu polepszenie ich podstawowych właściwości, co w praktyce skutkuje coraz częstszym stosowaniem betonów wysokowartościowych. W niniejszej pracy podjęto problem opisu wybranych właściwości betonów o niskich stosunkach wodno-spoiwowych. Nie ulega wątpliwości, że wytrzymałość jest wiodącą cechą mechaniczną betonu jako materiału budowlanego.

Sformułowanie modelu empirycznego w wielowymiarowej przestrzeni parametrów składu i właściwości kompozytu wysokowartościowego może okazać się zbyt skomplikowane. W takiej sytuacji do obiektywnego rozpoznania związków między składem, a właściwościami kompozytu można wykorzystać metodę sztucznej inteligencji – sztuczne sieci neuronowe (SSN). Możliwość wykorzystania SSN przy projektowaniu mieszanek betonowych została przedstawiona w wielu pracach naukowych m. in [134,142,143,165–175,180–182,184,185,205,217,245–247,275–299]. SSN jest użytecznym narzędziem do przewidywania różnych aspektów w dziedzinie inżynierii lądowej, pozwalającym z relatywnie dużą pewnością przewidywać także właściwości wytrzymałościowe betonu poprzez uwzględnienie czynników wpływających, które modyfikują jego właściwości. W przypadku warunków wymagających dużej dokładności i rozwiązywania złożonych problemów, SSN może dać lepsze rezultaty niż analiza regresji. Regresja to metoda zajmująca się zależnościami liniowymi, natomiast sieci neuronowe radzą sobie z nieliniowościami. Więc jeśli dane mają pewne nieliniowe zależności, sieci neuronowe działają lepiej niż regresja. Obecne procedury projektowania mieszanek obowiązują tylko dla ograniczonego zakresu składów konkretnego rodzaju betonu, który został poddany wcześniejszej ocenie eksperymentalnej. Kruszywo spiekane z popiołu lotnego jest wytwarzane sztucznie, a wytrzymałość betonu wykonanego z takiego kruszywa nie może być taka sama we wszystkich przypadkach ze względu na skład, uziarnienie i inne czynniki wpływające na produkcję samego kruszywa. Ponadto różne inne czynniki wpływają na wytrzymałość betonu, niezależnie od kruszywa. Przykładowo zachowanie lekkiego betonu z kruszywem można przewidzieć jedynie poprzez ciągłe eksperymenty laboratoryjne, które są czasochłonne i wymagają większych nakładów siły roboczej. Ten problem można w znacznym stopniu rozwiązać za pomocą metod prognozowania SSN. Dlatego uznano aktualny stan wiedzy w tym zakresie za niewystarczający, co posłużyło jako impuls do rozpoczęcia studiów literaturowych z tematyki implementacji SSN do predykcji cech betonów o niskim stosunku wodno-spoiwowym. Uzyskane wnioski generujące problemy badawcze posłużyły jako składowe stanowiące fragment analizy teoretycznej przygotowywanej rozprawy doktorskiej.

Na podstawie wstępnych rozważań zawartych w niniejszym rozdziale można stwierdzić, że wykorzystanie sztucznych sieci neuronowych do predykcji wybranych cech betonu o niskim stosunku wodno-spoiwowym może okazać się przydatne do opracowania nowej, analityczno-doświadczalnej metody projektowania składu betonów wysokowartościowych i innych nowoczesnych kompozytów cementowych. W niniejszym rozdziale przedstawiono możliwości zastosowania tego narzędzia do predykcji, np. wytrzymałości betonów wysokowartościowych o niskim stosunku wodno-spoiwowym. W dalszych rozważaniach wytrzymałość betonu na ściskanie może być definiowana jako zmienna wejściowa, na podstawie której projektant określać będzie skład mieszanki betonowej. Wymaga to przede wszystkim obszernych badań laboratoryjnych, które będą wykonywane w ramach dalszych rozważań niniejszej pracy. Stwo-

rzenie bazy danych pozwoli na budowę konkretnej sieci neuronowej, możliwej do zastosowania w przemyśle. Dane wejściowe tworzonej macierzy danych stanowiąc będą zmienne o charakterze ilościowym i jakościowym, natomiast wyjściową, podlegającą predykcji stanowiąc będzie zmienna zawierająca parametry betonu (wytrzymałość betonu na ściskanie).

Niniejsza praca ma na celu uwzględnienie podstawowych aspektów sztucznej sieci neuronowej do rozwiązywania złożonych problemów nieliniowych w przewidywaniu właściwości mechanicznych betonu pod względem jego wytrzymałości. Ta metodologia jest bardziej ekonomiczna i wygodniejsza niż opracowywanie betonu za pomocą eksperymentów laboratoryjnych [300]. Ponadto może być z powodzeniem wykorzystana przez wytwórnie do projektowania i dozowania mieszanek.

#### **4. PRZEDMIOT, CEL, TEZY BADAWCZE I ZAKRES PRACY**

Przedmiotem pracy jest beton o niskim stosunku wodno-spoiwowym, a w szczególności predykcja wytrzymałości na ściskanie tego betonu z użyciem sieci neuronowych. Niski stosunek w/s umożliwia uzyskanie betonu wysokiej wytrzymałości (BWW) i taki beton jest analizowany w pracy.

Celem pracy jest opracowanie i wstępne wdrożenie efektywnej i dostatecznie dokładnej metody projektowania (predykcji) betonu o niskim stosunku wodno-spoiwowym przy wykorzystaniu sztucznej inteligencji (SSN).

Sformułowano następującą tezę badawczą skorelowaną z celem pracy:

***Istnieje możliwość bardziej efektywnego wykorzystania sztucznych sieci neuronowych do predykcji betonu o niskim stosunku wodno-spoiwowym.***

W zakres pracy wchodzi następująca problematyka:

- studia literaturowe dotyczące betonów o niskim stosunku wodno-spoiwowym oraz wykorzystania sieci neuronowych do predykcji cech takich betonów;
- badania laboratoryjne betonów o niskim stosunku w/s w celu uzyskania bazy danych do trenowania (nauki) sieci neuronowych oraz weryfikacji predykcji betonu zaprojektowanego przy użyciu sieci neuronowych;
- walidacja zaprojektowanych sieci neuronowych do predykcji wytrzymałości betonu na ściskanie;
- analizy i wnioski końcowe.

## 5. BADANIA LABORATORYJNE MIESZANEK BETONOWYCH

### 5.1. Cel, zakres i metodyka badań laboratoryjnych

Celem badań laboratoryjnych było utworzenie bazy danych do predykcji wytrzymałości betonu na ściskanie przy użyciu sztucznej sieci neuronowej. Dane dotyczące zaprojektowanych mieszanek betonowych, z których tworzone będą grupy jakościowe, posłużą jako podstawa do utworzenia matrycy danych. Będzie ona zdefiniowana poprzez dane wejściowe (stanowiące grupę informacji o materiale łącznie z danymi jakościowymi i ilościowymi) oraz dane wyjściowe (dotyczące właściwości mechanicznych betonu, tj. wytrzymałości betonu na ściskanie). Wyraźnie podkreśla się, że na tym etapie badania laboratoryjne mieszanek betonowych i betonu prowadzą do uzyskania bazy danych służącej do trenowania (nauki) sieci neuronowych. Ponadto badania laboratoryjne mają na celu określenie stopnia pozytywnego oddziaływania zastosowanych dodatków oraz domieszek. Aby zrealizować cel pracy zaplanowano i przeprowadzono szeroki zakres badań laboratoryjnych dla dziewięciu różnych stosunków w/s (przedstawiony w tabeli 5.1), do których wykorzystano:

- cementy Lafarge klas wytrzymałości powszechnego użytku według PN-EN 197-1:2012, tj. klas 32,5; 42,5 oraz 52,5:
  - CEM I 42,5 R to cement portlandzki o wysokiej wczesnej wytrzymałości;
  - CEM II/A-M (S-LL) 52,5 N to cement portlandzki wieloskładnikowy o normalnej wytrzymałości wczesnej, zawierający w swoim składzie dodatek w postaci kamienia wapiennego oraz mielonego żużla wielkopiecowego;
  - CEM IV/B(V) 32,5 R-LH/NA to cement pucolanowy o wysokiej wytrzymałości wczesnej. Charakteryzuje się niskim ciepłem hydratacji, jest niskoalkaliczny, zawiera dodatek w postaci popiołu lotnego krzemionkowego;

Cement CEM I 42,5 R stanowi swoistą podstawę, gdyż nie zawiera w swoim składzie żadnych dodatków mineralnych. Cement ten często stanowi punkt odniesienia do porównań z innymi rodzajami cementu, bowiem wyniki uzyskane w efekcie badań (w porównaniu do innych cementów zawierających dodatki mineralne) są powtarzalne i charakteryzują się mniejszym rozrzutem końcowym. Cementy CEM II oraz CEM IV przyjęto do badań ze względu na powszechne stosowanie w przemyśle, dostępność i zróżnicowanie wodożądności.

- dwa rodzaje domieszek:
  - uplastyczniająca „Nr 1” w ilości 0,5% (wytwarzana na bazie zmodyfikowanych lignosulfonianów; poprzez efekt smarny powoduje zmniejszenie ilości wody zarobowej przy stałej konsystencji oraz zwiększenie ciekłości mieszanki betonowej przy zachowaniu stałej wartości stosunku w/s) – CHRYSO Plast 209;
  - upłynniająca „Nr 2” ilościach 0,3; 0,8 (wartość zalecana) oraz 3% (domieszka chemiczna nowej generacji, która wytwarzana jest na bazie modyfikowanych polikarboksylanów; poprzez efekt steryczny oraz smarny powoduje redukcję ilości wody zarobowej i generuje dezagregację ziaren

- spoiwa, co umożliwi wykonywanie mieszanek betonowych o niskim stosunku wodno-spoiwowym) – CHRYSO Fluid Premia 380;
- pył krzemionkowy (pochodzący z Huty Łaziska) w ilościach granicznych 5 i 15% masy cementu, zastosowany w celu zwiększenia szczelności betonu;
  - dwa rodzaje kruszywa: otoczkowe i łamane, ze względu na dostępność oraz powszechne użytkowanie w przemyśle;
  - wodę pitną wodociągową spełniającą wymagania norm.

Dla każdego rodzaju cementu oraz kruszywa, przy dziewięciu stosunkach wodno-spoiwowych: 0,21; 0,24; 0,27; 0,30; 0,33; 0,36; 0,40; 0,45 i 0,50 wykonano następujący zakres badań:

Tabela 5.1. Zestawienie badań wykonanych w ramach eksperymentu

Lp.	Oznaczenie	Rodzaj próbek
1	Klasa wytrzymałościowa	bez domieszek
		domieszka upłynniająca „Nr 2”
		domieszka uplastyczniająca „Nr 1”
		mikrokrzemionka 5%
		mikrokrzemionka 15%
2	Wodozjadność normowa i czas wiązania	bez domieszek
		domieszka upłynniająca „Nr 2”
		domieszka uplastyczniająca „Nr 1”
		mikrokrzemionka 5%
		mikrokrzemionka 15%
3	Gęstość pozorna zaczynu	bez domieszek
		domieszka upłynniająca „Nr 2”
		domieszka uplastyczniająca „Nr 1”
5	Badanie właściwości mechanicznych zaprawy	domieszka upłynniająca „Nr 2”
		mikrokrzemionka 5%
		mikrokrzemionka 15%
6	Badanie właściwości mechanicznych betonu	bez domieszek
		domieszka upłynniająca „Nr 2”
		mikrokrzemionka 5%
		mikrokrzemionka 15%

Badania wykonano według obowiązujących norm, zgodnie z metodyką przedstawioną w kolejnej części niniejszego rozdziału. Zostały one zrealizowane w szerszym zakresie aniżeli wymagany jest do przeprowadzenia predykcji wytrzymałości betonu na ściskanie – tak, aby końcowo uzyskać zestaw kompletnych wyników. Poszerzony zakres badań pozwolił na eliminację domieszki Nr.1 przy badaniu wytrzymałości na ściskanie.

Badanie klasy wytrzymałościowej cementu wykonano w oparciu o normę PN-EN 196-1: „Metody badania cementu – Część 1: Oznaczanie wytrzymałości”. Badanie to zostało przeprowadzone w celu weryfikacji klasy wytrzymałościowej deklarowanej przez producenta. Otrzymane wyniki wykorzystane zostały do porównania wytrzymałości uzyskanych z przyjętych do badań zapraw: bez domieszek i dodatku oraz z domieszkami i dodatkiem. W celu przeprowadzenia badania sporządzono mieszanekę (o stosunku wodno-spoiwowym 0,5), z której następnie uformowano beleczki (rys. 5.1). Wykonane zostały zaprawy: bez domieszek i dodatku, z domieszkami (uplastyczniającą „nr 1” w ilości 0,5% oraz upłynniającą „nr 2” w ilości 0,8%) i dodatkiem (pył krzemionkowy w ilości 5% oraz 15% masy cementu). Badanie wytrzymałości przeprowadzono na 12 beleczkach (dla każdej z zapraw) po upływie 7 i 28 dni. Łącznie z 90 wytworzonych próbek uzyskano 180 wyników.

a)



b)



Rysunek 5.1. Widok beleczek: a) gotowe beleczki; b) złamane beleczki

Badanie wodożądności normowej wykonano w oparciu o normę PN-EN 196-3: „Metody badania cementu – Część 2: Oznaczanie czasów wiązania i stałości objętości”. Badanie umożliwiło ocenę regulacji uzyskanej przy zastosowaniu domieszek (w szczególności w odniesieniu do niskich stosunków w/s). Wykonano próbki: bez domieszek i dodatku, z domieszkami (uplastyczniającą „Nr 1” w ilości 0,5%, upłynniającą „Nr 2” w ilościach 0,8% oraz 3%) i dodatkiem (pył krzemionkowy w ilości 5% oraz 15% masy cementu).

Badanie czas wiązania wykonano w oparciu o normę PN-EN 196-3: „Metody badania cementu – Część 3: Oznaczanie czasów wiązania i stałości objętości”. Badanie przeprowadzono w celu określenia wpływu dodatku pyłu krzemionkowego oraz domieszki upłynniającej i uplastyczniającej na długość czasu wiązania. Do badania wykonano próbki: bez domieszek i dodatku, z domieszkami (uplastyczniającą „Nr 1” w ilości 0,5%, upłynniającą „Nr 2” w ilościach 0,8% oraz 3%) i dodatkiem (pył krzemionkowy w ilości 5 oraz 15% masy cementu).




Rysunek 5.2. Widok próbki przygotowanej do badania

Badanie gęstości objętościowej mieszanki betonowej wykonano w oparciu o normę PN-EN 12350-6:2009 „Badanie mieszanki betonowej. Część 6. Gęstość” w celu ustalenia zawartości powietrza w zaczynie. Badanie polegało na pomiarze i ważeniu pojemników o znanej masie i objętości. Do badania wykorzystano plastikowe kubki o objętości 208,07 ml. Wykonano zaczyny: bez domieszek i dodatku, z domieszkami (uplastyczniającą „Nr 1” w ilości 0,5% oraz upłynniającą „Nr 2” w ilościach 0,8% ;3% oraz 6% - tylko dla CEM I). Zostały wykonane po dwie próbki dla wszystkich dziewięciu zapla-



nowanych stosunków w/s. Dodatkowe próbki zostały wykonane dla stosunków w/s 0,15 i 0,18. Zaczyny (rys. 5.3) w ilości 102 próbek dla CEM I oraz po 80 dla CEM II i CEM IV zważono po wykonaniu i upływie 28 dni. Gęstość pozorna została obliczona jako iloraz masy i znanej objętości pojemnika.



Rysunek 5.3. Widok próbek wykonanych w celu oznaczenia gęstości pozornej zaczynu

Badanie wytrzymałości na ściskanie zaprawy wykonano w oparciu o normę PN-EN 196-1: „Metody badania cementu - Część 1: Oznaczanie wytrzymałości”. Do badań wykonano beleczki referencyjne o wymiarach 40 mm x 40 mm x 160 mm, które następnie niszczone po upływie 28 dni od ich wytworzenia. Otrzymane rezultaty umożliwiły ocenę wpływu domieszek i dodatku na parametry wytrzymałościowe zaprawy. Przebadano próbki: bez domieszek i dodatku, z domieszką (upłynniającą „Nr 2” w ilościach 0,8% i 3%) oraz dodatkiem (pył krzemionkowy w ilościach 5% oraz 15% masy cementu). Wytworzone zostały 135 próbek (co dało 270 wyników) dla jednego rodzaju cementu (łącznie uzyskano zatem 810 wyników).



Rysunek 5.4. Widok próbek

Badanie wytrzymałości betonu na ściskanie wykonano w oparciu o normę PN-EN 12390-3: „Badania betonu. Część 3: Wytrzymałość na ściskanie próbek do badań” niszcząc wykonane wcześniej kostki sześciennie o wymiarach 100 mm x 100 mm x 100 mm (rys. 5.5). Próbkę poddawano niszczeniu po upływie 28 dni od ich wytworzenia (wykonano je i pielęgnowano w oparciu o normy PN-EN 12390-1: „Badania betonu. Część 1: Kształt, wymiary i inne wymagania dotyczące próbek do badań i form” oraz PN-EN 12390-2: „Badania betonu. Część 2: Wykonywanie i pielęgnacja próbek do badań wytrzymałościowych”). Przeprowadzone badania umożliwiły utworzenie matrycy danych, która została wykorzystana do predykcji (znajdującej się w rozdziale 6). W obrębie każdego rodzaju cementu i dwóch rodzajów kruszywa grubego (otczakowego oraz łamanego) zostały wykonane próbki: bez domieszek i dodatku, z domieszką (upłynniającą „Nr 2” w ilościach 1% oraz 3%) i dodatkiem (pył krzemionkowy w ilościach 5% oraz 15% masy cementu). Łącznie przebadano 815 próbek.



Rysunek 5.5. Widok zniszczonej w maszynie wytrzymałościowej próbki

Badanie składu ziarnowego kruszywa wykonano metodą przesiewania w oparciu o normę PN-EN 933-1: „Badania geometrycznych właściwości kruszyw – Oznaczanie składu ziarnowego – Metoda przesiewania”. Wykorzystując odpowiedni zestaw sit przesiano materiał i rozdzielono go na odpowiednie frakcje ziarnowe.

## **5.2. Wyniki badań laboratoryjnych wybranych właściwości zaczynów, mieszanek i betonów z analizą**

### **5.2.1. Klasa wytrzymałościowa spoiwa**

Wytrzymałość na ściskanie została obliczona według wyrażenia:

(5.1)

$$R_c = \frac{F_c}{1600} \quad [MPa]$$

gdzie:

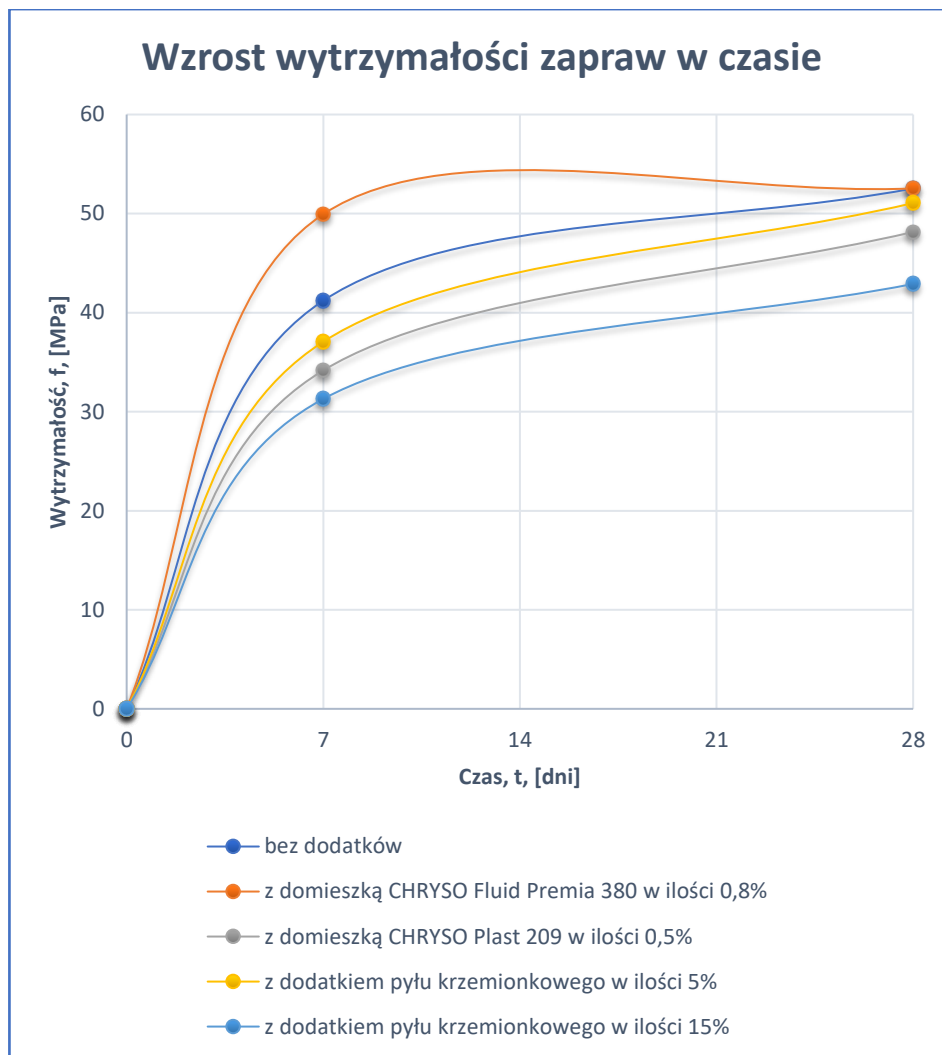
 $R_c$  – wytrzymałość na ściskanie [MPa] $F_c$  – najwyższa siła przy zgnieciu próbki [N]1600 – powierzchnia płytek (40 mm x 40 mm) [mm<sup>2</sup>]

Uzyskane wyniki zostały zaokrąglone do 0,1 MPa. W tabeli 5.2 podano średnią arytmetyczną z sześciu pojedynczych oznaczeń.

Tabela 5.2. Wyniki oznaczenia klasy wytrzymałościowej spoiwa


Lp.	Rodzaj zaprawy	CEM I		CEM II		CEM IV	
		7 dni	28 dni	7 dni	28 dni	7 dni	28 dni
		[MPa]	[MPa]	[MPa]	[MPa]	[MPa]	[MPa]
1	bez dodatków	41,2	52,5	40,4	55,4	28,7	36,3
2	z domieszką Nr 2 w ilości 0,8%	49,9	52,5	44,4	61,3	29,0	37,9
3	z domieszką Nr 1 w ilości 0,5%	34,1	48,1	34,0	50,9	28,2	39,1
4	z dodatkiem mikrokrzemionki w ilości 5%	37,1	51,1	36,3	51,9	27,0	37,1
5	z dodatkiem mikrokrzemionki w ilości 15%	31,3	42,9	32,9	47,1	24,3	33,8

Przeprowadzone badania wykazały, iż cementy spełniają zadeklarowane przez producenta parametry dotyczące wytrzymałości. Na rysunkach 5.6 ÷ 5.8 porównano średnie wytrzymałości na ściskanie uzyskane po 7 i 28 dniach dla badanej zaprawy bez dodatków oraz dla zapraw z domieszkami i dodatkiem.




Rysunek 5.6. Porównanie wytrzymałości na ściskanie zapraw CEM I o stosunku w/s = 0,5 z danymi domieszkami i dodatkiem

Na powyższym rysunku dla zaprawy z domieszką Nr 2 w ilości 0,8% następuje wzrost wytrzymałości na ściskanie pomiędzy 7 a 28 dniem.



Rysunek 5.7. Porównanie wytrzymałości na ściskanie zapraw CEM II o stosunku w/s = 0,5 z danymi domieszkami i dodatkiem



Rysunek 5.8. Porównanie wytrzymałości na ściskanie zapraw CEM IV o stosunku w/s = 0,5 z danymi domieszkami i dodatkiem

Wszystkie wyniki odniesiono do tych, które otrzymano z badania beleczek referencyjnych (bez domieszek i dodatków – oznaczono je na rysunkach kolorem niebieskim). Większą wytrzymałością wczesną cechuje się tylko zaprawa z domieszką CHRYSO Fluid Premia 380 w ilości 0,8% (przy wszystkich pozostałych zaprawach z domieszkami i dodatkiem wytrzymałość wczesna jest niższa). Zaobserwowano wzrost wytrzymałości wczesnej dla wszystkich badanych rodzajów cementu (CEM I, CEM II, CEM IV) z tą domieszką upłynniającą. Analizując uzyskane wyniki można wyciągnąć wniosek, że dzięki zastosowaniu domieszki CHRYSO Fluid Premia 380 w ilości zalecanej przez producenta możliwe jest szybsze rozformowanie elementów betonowych, co może przynieść konkretne korzyści technologiczne. W przypadku zaprawy CEM I z domiesz-

ką upłynniającą „Nr 2” w ilości 0,8% wytrzymałość po upływie 28 dni jest identyczna z tą uzyskaną dla zaprawy bez dodatków. W tym przypadku zaprawa z domieszką charakteryzuje się tylko zwiększoną wytrzymałością wczesną. Dla zapraw CEM II i CEM IV, poza wzrostem wytrzymałości wczesnej, zaobserwowano także nieznaczny wzrost wytrzymałości na ściskanie po upływie 28 dni (w porównaniu do zaprawy bez domieszek i dodatku). Dla zaprawy z domieszką CHRYSO Plast 209 (dla wszystkich badanych rodzajów cementu) zaobserwować można obniżenie wytrzymałości wczesnej (jest to typowe przy zastosowaniu domieszek z grupy lignosulfonianów). Wytrzymałość 28-dniowa kształtuje się na podobnym poziomie w porównaniu do tej uzyskanej dla zaprawy bez domieszek i dodatku. W przypadku zaprawy z dodatkiem pyłu krzemionkowego w ilości 5% wytrzymałość 7-dniowa dla wszystkich badanych rodzajów cementu jest niższa (dla CEM I i CEM II o ok. 4 MPa, dla CEM IV o ok. 2 MPa). Wytrzymałość 28-dniowa zapraw z mikrokrzemionką w ilości 5% jest porównywalna z zaprawami bez domieszek i dodatku. Dodatek pyłu krzemionkowego w ilości 15% w stosunku do masy cementu, pomimo powszechnie znanego pozytywnego wpływu tego dodatku, znacznie pogarsza wytrzymałość na ściskanie zarówno po upływie 7, jak i 28 dni. Przyczyną takiego stanu rzeczy należy upatrywać w pogorszeniu urabialności zaprawy.

### 5.2.2. Wodożądność normowa i czas wiązania


W celu oznaczenia czasu wiązania wykonane zostały po dwie próbki dla każdego z badanych rodzajów cementu. W tabeli 5.3 zaprezentowano uzyskane wyniki (przedstawiono średnią arytmetyczną z dwóch próbek). Oprócz wyników zawartych w tabeli, dodatkowo dla domieszki upłynniającej „Nr 2” oznaczono wodożądność normową spoiwa na poziomie 0,213 dla CEM I.

Tabela 5.3. Wyniki oznaczenia wodożądności oraz czasu wiązania

Lp.	Rodzaj zaprawy	CEM I		CEM II		CEM IV	
		w/s	początek czasu wiązania	w/s	początek czasu wiązania	w/s	początek czasu wiązania
		[-]	[min]	[-]	[min]	[-]	[min]
1	bez dodatków	0,294	194	0,310	188	0,300	218
2	z domieszką Nr 2 w ilości 0,8%	0,229	192	0,240	210	0,216	311
3	z domieszką Nr 1 w ilości 0,5%	0,274	234	0,286	239	0,276	445
4	z dodatkiem mikrokrzemionki w ilości 5%	0,300	195	0,320	171	0,304	257
5	z dodatkiem mikrokrzemionki w ilości 15%	0,336	189	0,363	138	0,312	258

Wodożądność normowa cementu CEM I podana przez producenta wynosi od 26 do 29%. Do badania cementu bez domieszek wykonano zaczyn, który charakteryzował się wodożądnością przekraczającą wskazania producenta o 0,4% (wskazane było zastosowanie 2 g wody więcej). Uzyskane wyniki badań wodożądności normowej dla cementów CEM II oraz CEM IV mieszczą się w wartościach zadeklarowanych przez producenta (tj. odpowiednio dla CEM II – 29-31% oraz CEM IV – 28-32%). Po zastosowaniu

plastyfikatora (CHRYSO Plast 209) w ilości 0,5% i superplastyfikatora (CHRYSO Fluid Premia 380) 0,8% w stosunku do masy cementu osiągnięto niższą – nawet o 8,1% wodożądność. Związane jest to z uplastyczniającym lub upłynniającym działaniem tych domieszek. Badane zaprawy z dodatkiem pyłu krzemionkowego wymagają zastosowania większej ilości wody (w porównaniu do zapraw bez dodatków oraz tych z domieszkami). Po dodaniu mikrokrzemionki w ilości 5% masy cementu wodożądność rośnie. Trend ten utrzymuje się po zwiększeniu zawartości pyłu krzemionkowego do 15%.



Rysunek 5.9. Porównanie czasów wiązania dla poszczególnych cementów

Początek czasu wiązania cementów spełnia wartości założone przez normę PN-EN 197-1:2012 „Cement- Część 1: Skład, wymagania i kryteria zgodności dotyczące cementów powszechnego użytku” w obrębie poszczególnych, badanych typów cementów (bez domieszek i dodatku). W wyniku zastosowania domieszek i dodatku skraca się czas wiązania zapraw (wyjątek stanowi zaprawa CEM IV z domieszką CHRYSO Plast 209 w ilości 0,5%, dla której czas wiązania jest dłuższy niż ten oznaczony dla zaprawy bez domieszek i dodatku). Dodatek mikrokrzemionki wyraźnie przyspiesza wiązanie zapraw, szczególnie w przypadku cementów CEM I i CEM II.

### 5.2.3. Gęstość pozorna zaczynu

Gęstość pozorną obliczono według wyrażenia:

$$\rho_p = \frac{m}{V} \quad (5.2)$$

$\rho_p$  – gęstość objętościowa  $\left[\frac{\text{kg}}{\text{m}^3}\right]$

$m$  – masa próbki [kg]

$V$  – objętość próbki wraz z porami [ $\text{m}^3$ ]



Tabela 5.4. Wyniki badań gęstości pozornej zaczynów

w/s	Gęstość pozorna zaczynów [kg/m <sup>3</sup> ]													
	teore- tyczna	CEM I					CEM II				CEM IV			
		BD	Nr 1 0,5 %	Nr 2 0,8 %	Nr 2 3 %	Nr 2 6 %	BD	Nr 1 0,5 %	Nr 2 0,8 %	Nr 2 3 %	BD	Nr 1 0,5 %	Nr 2 0,8 %	Nr 2 3 %
0,15	2,43	-	-	1,88	2,06	2,29	-	-	1,75	2,08	-	-	1,69	2,04
0,18	2,35	-	-	1,86	1,99	2,31	-	-	2,07	2,32	-	-	1,98	2,19
0,21	2,27	1,28	1,42	1,75	2,14	2,16	1,30	1,31	2,16	2,18	1,17	1,09	2,00	2,02
0,24	2,20	1,42	2,08	2,11	2,04	2,11	1,89	2,04	2,15	2,07	1,96	1,27	1,97	1,95
0,27	2,14	2,08	2,04	2,14	2,08	2,06	2,17	2,11	2,13	2,07	1,96	1,93	1,92	1,89
0,3	2,09	2,07	2,04	2,03	2,00	1,99	2,11	2,08	2,07	2,00	1,93	1,91	1,88	1,84
0,33	2,04	2,02	2,02	1,93	1,94	1,97	2,05	2,03	1,98	1,94	1,87	1,87	1,86	1,85
0,36	1,99	2,00	1,95	1,97	1,87	1,86	2,00	1,98	1,93	1,88	1,85	1,84	1,80	1,78
0,4	1,94	1,96	1,90	1,87	1,83	1,84	1,95	1,95	1,87	1,83	1,78	1,81	1,78	1,74
0,45	1,88	1,87	1,79	1,84	1,77	1,79	1,90	1,86	1,80	1,73	1,76	1,75	1,71	1,66
0,5	1,82	1,80	1,77	1,78	1,71	1,73	1,83	1,83	1,75	1,76	1,67	1,70	1,68	1,61

BD oznacza zaczyn bez domieszek


Nr 1 0,5% oznacza zaczyn z domieszką „Nr 1” w dozowaniu 0,5%

Nr 2 0,8% oznacza zaczyn z domieszką „Nr 2” w dozowaniu 0,8%


Nr 2 3% oznacza zaczyn z domieszką „Nr 2” w dozowaniu 3%

Nr 2 6% oznacza zaczyn z domieszką „Nr 2” w dozowaniu 6%


Na poniższych rysunkach porównano otrzymane wyniki gęstości pozornych zaczynów bez domieszek z wynikami gęstości zaczynów z domieszką CHRYSO Fluid Premia 380 w ilościach: 0,8%, 3% i 6% oraz domieszką CHRYSO Plast 209 w ilości 0,5%.




Rysunek 5.10. Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Fluid Premia 380 dla CEM I




Rysunek 5.11. Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Plast 209 dla CEM I




Rysunek 5.12. Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Fluid Premia 380 dla CEM IV



Rysunek 5.13. Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Plast 209 dla CEM IV



Rysunek 5.14. Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Fluid Premia 380 dla CEM II



Rysunek 5.15. Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Plast 209 dla CEM II

Oznaczenia na rysunkach 5.9 ÷ 5.14:

$\rho_{teor}$  oznacza gęstość teoretyczną

$\rho_{BD}$  oznacza zaczyn bez dodatków

$\rho_{0,5\%}$  oznacza zaczyn z domieszką „Nr 1” w dozowaniu 0,5%

$\rho_{0,8\%}$  oznacza zaczyn z domieszką „Nr 2” w dozowaniu 0,8%

$\rho_{3\%}$  oznacza zaczyn z domieszką „Nr 2” w dozowaniu 3%

$\rho_{6\%}$  oznacza zaczyn z domieszką „Nr 2” w dozowaniu 6%

Przy niskim stosunku w/s gęstości dla poszczególnych zaczynów przedstawiają się tak jak przypuszczano, tzn. przy zmniejszaniu ilości domieszki w zaczynie znajduje się więcej powietrza. Najbardziej porowatym zaczynem jest ten bez domieszek. W przypadku zaczynów z domieszką CHRYSO Fluid Premia 380 w ilości 6% (badanie wykonane dla CEM I) gęstości są najbardziej zbliżone do teoretycznych, co oznacza najmniejszą ilość powietrza w zaczynie. Porowatość struktury ma bezpośredni wpływ na cechy fizyczne i mechaniczne betonu. Im objętość porów w kompozycie jest większa, tym więcej wody może się w nim znaleźć. Związek porowatości betonu z jego wytrzymałością można oszacować ze wzoru Kingery'ego [32]:

$$f_{por.} = f_{por=0} \cdot (1 - \rho)^6 \quad (5.3)$$

gdzie:

$f_{por.}$  – wytrzymałość porowatego betonu, [-]

$f_{por=0}$  – wytrzymałość betonu bez porów [-]

$\rho$  – porowatość betonu [%]

Tabela 5.5. Porowatość zaczynów

Porowatość [%]													
w/s	CEM I					CEM II				CEM IV			
	BD	Nr 1 0,5 %	Nr 2 0,8 %	Nr 2 3 %	Nr 2 6 %	BD	Nr 1 0,5 %	Nr 2 0,8 %	Nr 2 3 %	BD	Nr 1 0,5 %	Nr 2 0,8 %	Nr 2 3 %
0,15	-	-	22,63	15,23	5,76	-	-	27,98	14,40	-	-	30,45	16,05
0,18	-	-	20,85	15,32	1,70	-	-	11,91	1,28	-	-	15,74	6,81
0,21	43,61	37,44	22,91	5,73	4,85	42,73	42,29	4,85	3,96	48,46	51,98	11,89	11,01
0,24	35,45	5,45	4,09	7,27	4,09	14,09	7,27	2,27	5,91	10,91	42,27	10,45	11,36
0,27	2,80	4,67	0,00	2,80	3,74	0	1,40	0,47	3,27	8,41	9,81	10,28	11,68
0,30	0,96	2,39	2,87	4,31	4,78	0	0,48	0,96	4,31	7,66	8,61	10,05	11,96
0,33	0,98	0,98	5,39	4,90	3,43	0	0,49	2,94	4,90	8,33	8,33	8,82	9,31
0,36	0	2,01	1,01	6,03	6,53	0	0,50	3,02	5,53	7,04	7,54	9,55	10,55
0,40	0	2,06	3,61	5,67	5,15	0	0	3,61	5,67	8,25	6,70	8,25	10,31
0,45	0,53	4,79	2,13	5,85	4,79	0	1,06	4,26	7,98	6,38	6,91	9,04	11,70
0,50	1,10	2,75	6,04	6,04	4,95	0	0	3,85	3,30	8,24	6,59	7,69	11,54

BD oznacza zaczyn bez domieszek

Nr 1 0,5% oznacza zaczyn z domieszką „Nr 1” w dozowaniu 0,5%

Nr 2 0,8% oznacza zaczyn z domieszką „Nr 2” w dozowaniu 0,8%

Nr 3 3% oznacza zaczyn z domieszką „Nr 2” w dozowaniu 3%

Nr 2 6% oznacza zaczyn z domieszką „Nr 2” w dozowaniu 6%

Znając gęstości każdego z zaczynów obliczono ich porowatość (tab. 5.5). Dla stosunku w/s niższego niż 0,24 porowatość zaczynu bez domieszek jest kilkakrotnie większa niż zaczynów z domieszką CHRYSO Fluid Premia 380. Oznacza to, że przy niskim stosunku wodno-spoiwowym obecność domieszki znacznie poprawia właściwości zaczynu (dzięki zmniejszeniu porowatości). Natomiast od stosunku w/s wyższego niż 0,27 udział domieszki nie poprawia już jego właściwości. Dążąc do zmniejszenia porowatości zaczynu oraz betonu warto stosować zbadane domieszki, które są szczególnie korzystne dla niskich wartości stosunku wodno-spoiwowego (od 0,15 do 0,24).

#### 5.2.4. Wytrzymałość zaprawy na ściskanie

Do obliczenia wytrzymałości zaprawy na ściskanie wykorzystano zaprezentowane wcześniej wyrażenie 5.1. Uzyskane rezultaty zostały przedstawione w formie średniej arytmetycznej z sześciu oznaczeń. Dla uzyskanych danych sporządzone zostały także wykresy, na których zaprezentowano linie trenu dla poszczególnych oznaczeń (rysunki 5.15 ÷ 5.17).

Tabela 5.6. Wyniki oznaczenia wytrzymałości zaprawy na ściskanie

w/s	Wytrzymałość zaprawy na ściskanie [MPa]														
	CEM I					CEM II					CEM IV				
	BD	Nr 2 0,8 %	Nr 2 3 %	M 5 %	M 15 %	BD	Nr 2 0,8 %	Nr 2 3 %	M 5 %	M 15 %	BD	Nr 2 0,8 %	Nr 2 3 %	M 5 %	M 15 %
0,21	5,4	19,5	15,1	5,7	2,8	2,7	18,0	82,2	3,3	2,7	5,2	52,0	86,3	3,3	9,6
0,24	7,9	62,2	45,7	5,7	2,4	10,9	75,3	87,2	6,6	6,4	7,6	78,8	78,2	4,6	10,1
0,27	9,9	63,0	67,4	10,3	2,1	12,6	80,7	91,6	7,7	3,7	13,3	69,1	74,8	8,9	8,7
0,30	13,3	75,7	67,1	10,1	4,3	18,8	76,6	80,5	14,7	10,8	15,2	59,1	68,4	15,1	13,3
0,33	22,5	70,1	61,9	14,6	7,5	15,7	74,9	71,5	29,3	17,6	28,0	67,4	56,3	23,0	14,8
0,36	29,5	67,0	58,8	18,5	9,4	50,0	65,0	63,5	40,4	39,6	46,1	50,8	48,5	37,3	16,8
0,40	32,2	58,2	54,4	33,5	14,3	43,9	41,7	56,8	40,3	38,1	31,6	43,2	42,6	40,9	36,4
0,45	48,1	49,0	50,1	30,6	17,1	41,7	47,1	45,5	56,4	40,6	35,3	36,5	31,3	37,8	35,7
0,50	42,2	43,3	48,6	43,8	17,6	43,3	39,8	36,3	43,7	40,7	31,6	28,3	33,5	27,6	21,9


BD oznacza zaprawę bez domieszki i dodatku

Nr 2 0,8% oznacza zaprawę z domieszką „Nr 2” w dozowaniu 0,8%


Nr 2 3% oznacza zaprawę z domieszką „Nr 2” w dozowaniu 3%

M 5% oznacza zaprawę z dodatkiem mikrokrzemionki w dozowaniu 5%


M 15% oznacza zaprawę z dodatkiem mikrokrzemionki w dozowaniu 15%



Rysunek 5.16. Porównanie wytrzymałości na ściskanie zaprawy bez domieszki i dodatku oraz zaprawy z domieszką i dodatkiem dla CEM I




a)



b)

Rysunek 5.17. Porównanie wytrzymałości na ściskanie zaprawy bez domieszki i dodatku oraz zaprawy z domieszką i dodatkiem dla CEM II a) dla wszystkich wyników b) po odrzuceniu wyniku 18 MPa dla w/s 0,21





Rysunek 5.18. Porównanie wytrzymałości na ściskanie zaprawy bez domieszki i dodatku oraz zaprawy z domieszką i dodatkiem dla CEM IV

Zaprawa bez domieszki i dodatku przy niskim stosunku w/s charakteryzuje się niewielką wytrzymałością na ściskanie. Maksymalne wytrzymałości tej zaprawy zostały uzyskane przy stosunku w/s 0,45 (48,1 MPa) dla CEM I, stosunku w/s 0,36 (50 MPa) dla CEM II oraz stosunku w/s 0,36 (46,1 MPa) dla CEM IV. Porównano poszczególne wytrzymałości zapraw bez domieszki i dodatku z wynikami uzyskanymi dla zapraw z domieszką i dodatkiem pyłu krzemionkowego. Według zaleceń producenta domieszkę CHRYSO Fluid Premia 380 należy stosować w ilości 0,8% w stosunku do masy cementu, natomiast zastosowanie jej w ilości 3% stanowi wartość graniczną. Zaprawy z tym superplastyfikatorem charakteryzują się wyraźnie wyższą wytrzymałością (w szczególności przy stosunku w/s niższym niż 0,40) w porównaniu do zapraw bez domieszki i dodatku oraz zapraw z dodatkiem mikrokrzemionki. Przy stosunku w/s 0,45 i 0,50 zaprawy bez dodatku i domieszki oraz te z domieszką mają zbliżoną wytrzymałość. Maksymalne wytrzymałości na ściskanie uzyskano: dla CEM I (75,7 MPa) przy stosunku w/s 0,30 dla zaprawy z domieszką w ilości 0,8%, dla CEM II (91,6 MPa) przy stosunku w/s 0,27 dla zaprawy z domieszką w ilości 3% oraz CEM IV (86,3 MPa) przy stosunku w/s 0,21 dla zaprawy z domieszką w ilości 3%. Na podstawie uzyskanych wyników ciężko jednoznacznie określić wpływ dodatku pyłu krzemionkowego na wytrzymałość zaprawy (pomimo tego, iż oczekiwania wskazywałyby na wzrost wytrzymałości). Niskie wytrzymałości na ściskanie zapraw z dodatkiem pyłu krzemionkowego mogły zostać spowodowane problemami z urabialnością tych zapraw (mogło zostać wprowadzone do zaprawy niepożądane powietrze), dlatego w badaniu betonu z tym dodatkiem zdecydowano się także zastosować superplastyfikator w ilości pozwalającej na uniknięcie problemów z urabialnością.

### 5.2.5. Wytrzymałość betonu na ściskanie

Wytrzymałość betonu na ściskanie została obliczona według wyrażenia 5.1 (znajdującego się w rozdziale 5.2.1 – klasa wytrzymałościowa spoiwa). Uzyskane wyniki zostały zaokrąglone do 0,1 MPa. W tabelach 5.7 oraz 5.8 podano średnią arytmetyczną z trzech pojedynczych oznaczeń (receptura z kruszywem otoczkowym – tab. 5.7, receptura z kruszywem łamanym – tab. 5.8). Dla tych danych sporządzone zostały wykresy, na których zaprezentowano linie trenu dla poszczególnych oznaczeń (rysunki 5.18 ÷ 5.23).

Tabela 5.7. Wyniki oznaczenia wytrzymałości betonu na ściskanie (żwir)

w/s	Wytrzymałość betonu na ściskanie [MPa]														
	CEM I					CEM II					CEM IV				
	BD	Nr 2 1 %	Nr 2 3 %	M 5 %	M 15 %	BD	Nr 2 1 %	Nr 2 3 %	M 5 %	M 15 %	BD	Nr 2 1 %	Nr 2 3 %	M 5 %	M 15 %
0,21	8,9	9,9	72,1	0,5	0,1	10,9	7,9	88,8	0,8	0,1	5,5	6,1	60,8	1,3	0,5
0,24	23,9	70,8	79,3	1,6	1,0	60,3	25,4	85,3	1,3	0,4	18,5	76,8	69,9	1,7	0,8
0,27	49,1	80,1	82,3	81,3	3,3	74,8	77,9	92,3	77,7	12,3	43,0	73,0	68,2	66,3	62,7
0,30	48,2	77,4	86,3	82,0	83,5	73,8	75,8	94,2	73,9	67,4	43,6	69,0	87,7	66,8	64,1
0,33	68,4	77,4	79,6	85,2	83,2	72,4	73,9	80,3	74,0	75,0	56,6	65,4	63,5	65,1	69,7
0,36	66,4	74,9	75,9	78,9	74,5	90,7	75,8	71,2	73,6	78,6	54,3	58,7	53,6	64,3	60,8
0,40	63,7	64,4	60,0	68,3	67,8	84,2	69,4	67,6	70,2	71,4	44,5	44,0	52,1	55,7	54,9
0,45	52,8	53,7	47,4	57,3	56,7	52,0	54,1	54,2	58,6	63,3	36,8	42,9	64,4	46,6	45,7
0,50	42,5	40,7	39,9	45,6	43,4	48,7	41,2	44,0	50,8	51,9	20,3	34,0	43,2	31,1	36,6


BD oznacza beton bez domieszki i dodatku

Nr 2 1% oznacza beton z domieszką „Nr 2” w dozowaniu 1%


Nr 2 3% oznacza beton z domieszką „Nr 2” w dozowaniu 3%

M 5% oznacza beton z dodatkiem mikrokrzemionki w dozowaniu 5% oraz domieszką „Nr 2” w dozowaniu 3%

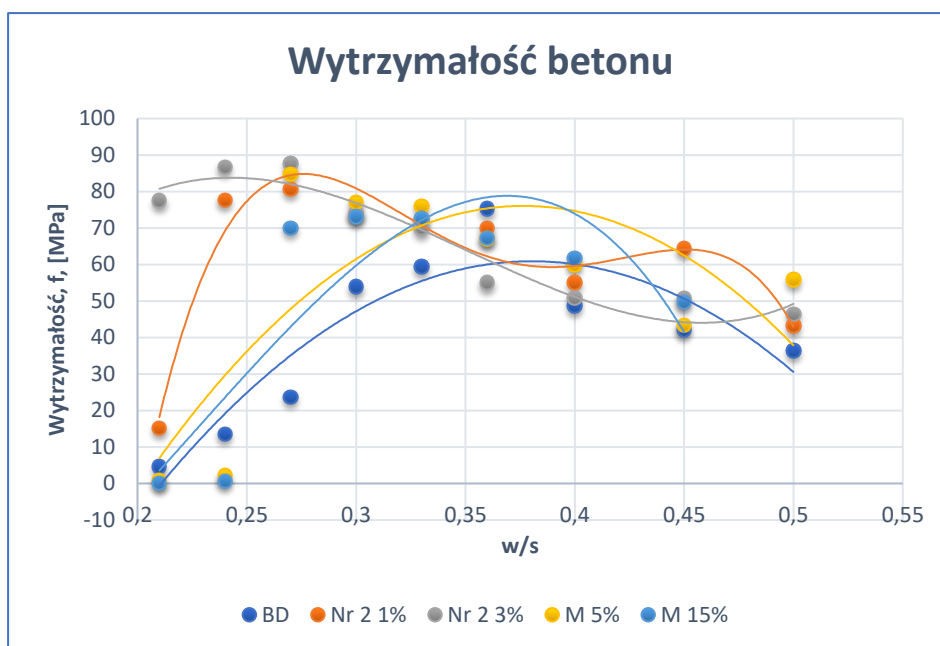
M 15% oznacza beton z dodatkiem mikrokrzemionki w dozowaniu 15% oraz domieszką „Nr 2” w dozowaniu 3%



Rysunek 5.19. Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM I (kruszywo otoczkowe)



Rysunek 5.20. Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM II (kruszywo otoczkowe)



Rysunek 5.21. Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM IV (kruszywo otoczkowe)

Tabela 5.8. Wyniki oznaczenia wytrzymałości betonu na ściskanie (grys)

w/s	Wytrzymałość betonu na ściskanie [MPa]														
	CEM I					CEM II					CEM IV				
	BD	Nr 2 1 %	Nr 2 3 %	M 5 %	M 15 %	BD	Nr 2 1 %	Nr 2 3 %	M 5 %	M 15 %	BD	Nr 2 1 %	Nr 2 3 %	M 5 %	M 15 %
0,21	6,0	14,7	96,3	0,8	0,1	15,4	15,1	91,1	0,9	0,8	4,6	15,2	77,4	0,8	0,1
0,24	20,7	97,0	105,1	1,5	1,3	8,5	76,3	107,5	2,8	1,0	13,5	77,6	86,6	2,2	0,6
0,27	25,2	98,5	102,0	93,9	42,7	86,1	94,6	101,3	94,1	68,8	23,7	80,7	87,6	84,7	70,0
0,30	54,2	85,1	94,7	80,9	92,2	93,1	89,0	90,9	97,0	81,2	53,8	74,0	74,1	77,1	73,1
0,33	74,7	84,2	84,5	81,6	91,5	93,8	89,6	94,0	95,5	89,6	59,4	72,3	69,9	75,9	72,6
0,36	89,2	78,6	81,7	69,0	77,6	86,4	85,7	74,5	84,4	85,6	75,2	69,9	55,0	67,1	67,3
0,40	84,6	75,1	61,8	70,6	76,5	75,2	63,8	70,4	78,3	81,2	48,7	55,0	50,8	60,0	61,7
0,45	73,1	68,4	48,5	40,4	40,8	69,8	61,4	61,0	53,5	72,7	42,2	64,4	50,8	43,3	49,6
0,50	56,1	45,0	22,1	32,9	52,9	52,8	51,8	32,0	40,0	60,9	36,4	43,2	46,4	55,8	44,6


BD oznacza beton bez domieszki i dodatku

Nr 2 1% oznacza beton z domieszką „Nr 2” w dozowaniu 1%


Nr 2 3% oznacza beton z domieszką „Nr 2” w dozowaniu 3%

M 5% oznacza beton z dodatkiem mikrokrzemionki w dozowaniu 5% oraz domieszką „Nr 2” w dozowaniu 3%


M 15% oznacza beton z dodatkiem mikrokrzemionki w dozowaniu 15% oraz domieszką „Nr 2” w dozowaniu 3%



Rysunek 5.22. Porównanie wytrzymałości betonu na ściskanie bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM I (kruszywo łamane)



Rysunek 5.23. Porównanie wytrzymałości betonu na ściskanie bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM II (kruszywo łamane)




Rysunek 5.24. Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM IV (kruszywo łamane)

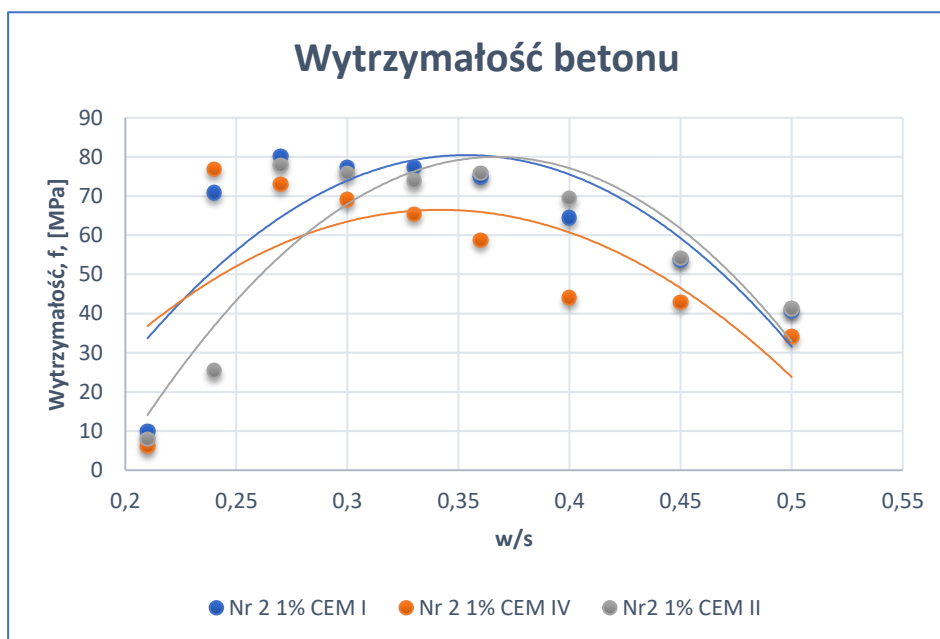
Największe uzyskane podczas badań wytrzymałości na ściskanie betonu bez domieszki i dodatku wyniosły odpowiednio: dla betonu z kruszywem otoczkowym 68,4 MPa przy stosunku w/s 0,33 dla CEM I, 90,7 MPa przy stosunku w/s 0,36 dla CEM II, 56,6 MPa przy stosunku w/s 0,33 dla CEM IV oraz dla kruszywa łamanego 89,2 MPa przy stosunku w/s 0,36 dla CEM I, 93,9 MPa przy stosunku w/s 0,33 dla CEM II, 75,2 MPa przy stosunku w/s 0,36 dla CEM IV. Wyższe wytrzymałości na ściskanie dla betonów z grysem wynikają z bardziej rozwiniętej powierzchni ziaren kruszyw łamanych (w porównaniu do kruszyw otoczkowych) oraz z wyższej wytrzymałości kruszywa łamanego. Wpływa to korzystnie na wytrzymałość strefy kontaktowej na styku zaczynu i kruszywa, a z drugiej strony niekorzystnie przekłada się na urabialność mieszanki betonowej. Zauważyć można, że najwyższe wytrzymałości otrzymano dla niskich stosunków w/s. Obecność domieszki CHRYSO Fluid Premia 380 (zarówno w ilości 1, jak i 3%) zasadniczo wpłynęła pozytywnie na wytrzymałość betonu (szczególnie w przypadku niskiego stosunku w/s). Najwyższą wytrzymałość na ściskanie betonu z domieszką, tak jak w przypadku betonu bez domieszki i dodatku, uzyskano przy niskim stosunku w/s. Najwyższe wartości wyniosły odpowiednio: dla betonu z kruszywem otoczkowym – 86,3 MPa (CEM I); 94,2 MPa (CEM II); 87,7 MPa (CEM IV) przy stosunku w/s 0,30 oraz z domieszką w ilości 3%, dla betonu z kruszywem łamanym – 105,1 MPa (CEM I); 107,5 MPa (CEM II) przy stosunku w/s 0,24; 87,6 MPa (CEM IV) przy stosunku w/s 0,27 oraz z domieszką w ilości 3%, czyli powyżej wartości zalecanej. Uzyskany wynik dla CEM II (107,5 MPa) stanowi najwyższą wytrzymałość na ściskanie jaką uzyskano ze wszystkich próbek różnych składów betonu. Maksymalne wyniki (dla wszystkich badanych rodzajów cementu) wytrzymałości betonu na ściskanie

z domieszką przekroczyły wartości uzyskane z badania betonu bez domieszki. Dodatek pyłu krzemionkowego do betonu znacznie pogarsza urabialność mieszanki betonowej, dlatego zdecydowano się, aby dołożyć (do składu betonu z mikrokrzemionką) superplastyfikator w ilości umożliwiającej wykonanie próbek (maksymalnie 3%). Pomimo dodatkowej obecności superplastyfikatora, wykonanie próbek z udziałem obu kruszyw przy dodatku 5% mikrokrzemionki dla stosunku w/s 0,21 oraz 0,24, a także dodatku 15% mikrokrzemionki dla stosunku w/s 0,27 było problematyczne. Uzyskane próbki kruszyły się przy rozformowywaniu i przenoszeniu do maszyny wytrzymałościowej. Otrzymano podobne do siebie wyniki przy różnej ilości mikrokrzemionki, jednak największą wytrzymałość betonu na ściskanie uzyskiwano najczęściej przy dodatku 5% pyłu krzemionkowego. Osiągnięte najwyższe wyniki wytrzymałości na ściskanie, tj. 107,5 MPa betonu z domieszką CHRYSO Fluid Premia 380 w ilości 3% przy stosunku w/s 0,24 oraz 97 MPa betonu z dodatkiem pyłu krzemionkowego w ilości 5% przy stosunku w/s 0,30 (w obu przypadkach z kruszywem łamanym) pozwalają stwierdzić, że wzbogacony skład mieszanki w celu zwiększenia najważniejszej właściwości betonu spełnia swoją rolę. Dzięki zastosowaniu pyłu krzemionkowego oraz superplastyfikatora uszczelniono strukturę betonu i poprawiono urabialność mieszanki betonowej. Wyniki obrazują pozytywny wpływ domieszki oraz dodatku w postaci pyłu krzemionkowego (z domieszką upłynniającą) na wytrzymałość betonu. Niskie wartości wytrzymałości na ściskanie betonu z dodatkiem pyłu krzemionkowego (przy stosunku w/s 0,21 oraz 0,24) związane są z nieefektywną metodą zagęszczania dla betonów o niskim stosunku w/s - stolik wibracyjny.

Dokonano także porównania wytrzymałości na ściskanie betonów wykonanych na bazie poszczególnych cementów (CEM I, CEM II oraz CEM IV), przy jednakowej ilości domieszki i dodatków. Sporządzono wykresy dla betonów bez domieszki i dodatku, z domieszką CHRYSO Fluid Premia 380 w ilości 1 i 3% oraz dodatkiem mikrokrzemionki w ilości 5 i 15%. Na wykresach zaprezentowano linie trendu dla poszczególnych oznaczeń (rysunki 5.24 ÷ 5.33).




Rysunek 5.25. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu bez domieszki i dodatku (kruszywo otoczkowe)




Rysunek 5.26. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 1% (kruszywo otoczkowe)







Rysunek 5.27. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 3% (kruszywo otoczkowe)




Rysunek 5.28. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 5% (kruszywo otoczkowe)




Rysunek 5.29. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 15% (kruszywo otoczkowe)




Rysunek 5.30. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu bez domieszki i dodatku (kruszywo łamane)




Rysunek 5.31. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 1% (kruszywo łamane)



Rysunek 5.32. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 3% (kruszywo łamane)



Rysunek 5.33. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 5% (kruszywo łamane)



Rysunek 5.34. Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 15% (kruszywo łamane)

Rysunki 5.24 ÷ 5.33 obrazują, iż zgodnie z przewidywaniami najwyższą wytrzymałość na ściskanie w grupie próbek bez dodatków i domieszek uzyskano dla CEM II, zarówno dla kruszywa otoczkowego jak i łamanego. Przy zastosowaniu domieszki CHRYSO Fluid Premia 380 linie trendu dla CEM I i CEM II zbliżają się do siebie przy jednoczesnym obniżeniu wodożądności (ekstremum funkcji przesuwa się w lewo, ku niższym stosunkom wodno-spoiwowym). Przy zastosowaniu mikrokrzemionki w udziale 5 i 15% dla betonu na kruszywie otoczkowym uzyskuje się zbliżone wartości dla CEM I i CEM II (przy czym dla CEM I próbki lokalnie mają wyższą wytrzymałość). Natomiast w przypadku betonu wykonywanego na kruszywie łamanym zauważalny jest wyraźny wzrost wytrzymałości betonów otrzymywanych przy użyciu CEM II.

### 5.3. Podsumowanie

W niniejszym rozdziale zaprezentowano opracowane wyniki badań laboratoryjnych, które zostały przeprowadzone w celu uzyskania matrycy danych. Cały założony zakres badań został zrealizowany, a dokładne i kompletne wyniki zostały zamieszczone w załączniku nr 1 do rozprawy doktorskiej. Przeanalizowano wyniki badań klasy wytrzymałościowej spoiwa, wodożądności normowej, czasu wiązania i gęstości pozornej zaczynu, wytrzymałości na ściskanie zaprawy i betonu, określono także dla jakich stosunków wodno-spoiwowych otrzymywano najwyższe wartości. Zidentyfikowano ponadto maksymalne możliwe do uzyskania wartości gęstości pozornej i wytrzymałości dla konkretnego rodzaju i udziału domieszki. Domieszkę CHRYSO Plast 209 wykorzystano do badania klasy wytrzymałościowej zaprawy, czasu wiązania oraz gęstości pozornej. Nie przeprowadzono pozostałych badań (wytrzymałościowych betonu) z tą domieszką ze względu na nieefektywność plastyfikatora [301,302]. Jedyne znaczące różnice w wynikach badań między mieszanką betonową z oraz bez domieszki CHRYSO Plast 209 otrzymano w wodożądności normowej - plastyfikator ten obniżył wodożądność. Dodatek pyłu krzemionkowego spowodował znaczne problemy z urabialnością mieszanki betonowej, zwłaszcza przy niskich stosunkach wodno-spoiwowych. Problemy te wpłynęły na obniżenie wytrzymałości zapraw, dlatego do próbek betonu zdecydowano się dodatkowo zastosować także superplastyfikator w ilości pozwalającej na poprawienie urabialności, jednocześnie nie przekraczającej wartości granicznej wskazanej przez producenta - 3% masy cementu. Dzięki takiemu połączeniu otrzymano wzrost wytrzymałości betonu o niecałe 25% w porównaniu z betonem bez domieszki i dodatku przy stosunku w/s 0,33. Najwyższe wytrzymałości osiągnęto przy zastosowaniu domieszki CHRYSO Fluid Premia 380, która pozwoliła na przesunięcie krzywej wytrzymałości przy niższym współczynniku wodno-spoiwowym. Zauważono, że maksymalne wartości osiągnięto przy dozowaniu w ilości zalecanej przez producenta, tj. 0,8% masy cementu. Maksymalna wytrzymałość w porównaniu z betonem bez domieszki wzrosła o ok. 21%. Najwyższą otrzymaną wartością jest wytrzymałość rzędu 107,5 MPa dla stosunku wodno-spoiwowego wynoszącego zaledwie 0,24.

Do dalszych rozważań wykorzystane zostaną dane dotyczące wytrzymałości betonu na ściskanie wraz ze składami ilościowymi. Tak przygotowana matryca danych pozwoli na zrealizowanie celu niniejszej pracy, tj. wykonanie predykcji wytrzymałości betonu.

## 6. TRENOWANIE SIECI NEURONOWYCH DO PREDYKCJI WYTRZYMAŁOŚCI BETONU

### 6.1. Rozważany problem

Celem rozważań na tym etapie pracy jest trenowanie sieci neuronowych (nauka). Aby osiągnąć założony cel niniejszej dysertacji, na podstawie rozważań zawartych w rozdziale 3, wybrano do trenowania perceptron wielowarstwowy (ang. *Multilayer Perceptron*, *MLP*) – jednokierunkowe sieci wielowarstwowe oparte na algorytmie wstecznej propagacji błędu, ze względu na:

- aproksymację globalną sieci MLP;
- proces uczenia oparty na algorytmie wstecznej propagacji błędu (wyższa efektywność procesu uczenia, algorytm wyznacza kierunek i modyfikuje wagi tak aby zmniejszyć błąd popełniany przez sieć);
- dostępność w programie Statistica.

Cechą charakterystyczną sieci MLP jest przede wszystkim to, że narzucona jest liczba danych wejściowych (narzucono liczbę 10), a dopiero potem w sieci wylosowana zostaje liczba neuronów w warstwie ukrytej (z przedziału 5-15).

Głównym celem uczenia jest uzyskanie takich wartości wyjściowych (wyników), które będą zbliżone (z wysoką dokładnością) do wartości rzeczywistych, uzyskanych w wyniku badań laboratoryjnych. Poprawianie stopnia dokładności odbywa się na drodze procesu uczenia sieci (etapy uczenia nazywa się epokami). W ramach rozważanego problemu trenowanie sieci polega na następujących działaniach:

- wprowadzenie do sieci danych wejściowych dotyczących kruszywa, cementu, wody, dodatków, domieszek, stosunku wodno-spoiwowego;
- obliczenia z użyciem sieci MLP, prowadzące do uzyskania neuronów ukrytych i dalej do wyników końcowych, czyli wartości wyjściowych, tj. np. wytrzymałości betonu na ściskanie;
- weryfikacja wyników końcowych ze znanymi rzeczywistymi wynikami np. z badań laboratoryjnych betonu; weryfikacja, czyli minimalizacja błędów odbywa się w sieci MLP automatycznie. Jest to proces przypominający iterację; proces iteracji zostaje przerwany, gdy w kolejnych epokach wyniki obliczeń (neuronów ukrytych) nie zmieniają się co oznacza, że funkcja błędu w toku obliczeń nie ulega zmianie. W tym momencie można uznać, że uzyskano największy możliwy stopień zgodności.

Miarę zgodności wyników uzyskanych z sieci MLP z wynikami rzeczywistymi (faktycznie pomierzonymi) zdefiniowano następująco:

- błąd bezwzględny

(6.1)

$$\Delta X = |X - X_p|$$

gdzie:

$X$  jest wartością uzyskaną z sieci MLP, a  $X_p$  jest wartością rzeczywistą, np. w przypadku obliczania wytrzymałości na ściskanie – wielkości te wyrażane będą w Pascalach (Pa)

- błąd względny

$$\varepsilon = \frac{\Delta X}{X_p} \quad (6.2)$$

- stopień zgodności

$$\varepsilon' = 1 - \varepsilon \quad (6.3)$$

Błąd względny  $\varepsilon$ , jak też stopień zgodności  $\varepsilon'$  mogą być wyrażane w procentach.

## 6.2. Przyjęcie i klasyfikacja danych oraz projektowanie zbioru uczącego

Dane zostały przygotowane zgodnie z opisem metodologii zawartej w rozdziale 5. Stworzono adekwatne tablice, które umożliwiły symulację komputerową w programie Statistica. Dane zostały zamieszczone w załączniku 2. Bazę danych zbudowano na podstawie danych pochodzących z badań eksperymentalnych, stanowiących zestawienie odpowiednio opisanych i zaszeregowanych grup mieszanek betonowych, które zostały poddane badaniu wytrzymałości na ściskanie. W efekcie podjętych rozważań przygotowano sieć do rozwiązania następujących zadań (ograniczonych poprzez matrycę danych):

- Zadanie 1: zastosowanie do istniejącej mieszanki betonowej, w celu predykcji wytrzymałości betonu na ściskanie.
- Zadanie 2: uzyskanie składu mieszanki betonowej w zakresie ilościowym, na podstawie podanych danych ilościowych oraz jakościowych.

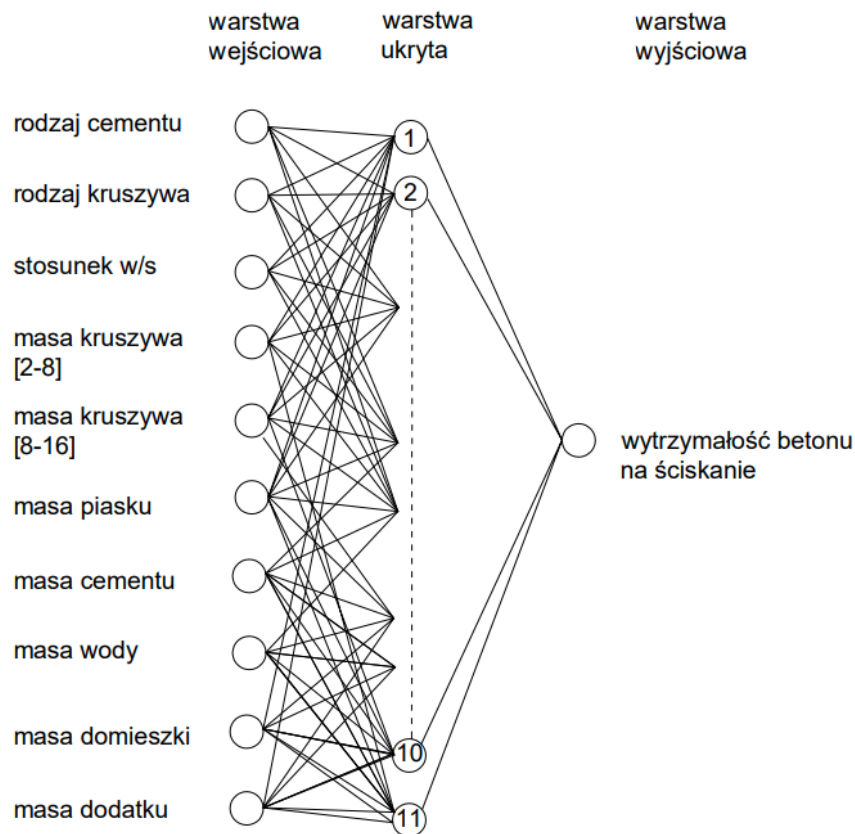
Dane wejściowe dla zadania 1 stanowią:

- zmienne o charakterze ilościowym (stosunek w/s, masa: wody, cementu, domieszek, dodatków i kruszywa);
- zmienne o charakterze jakościowym (klasa cementu, wodożądność, rodzaj kruszywa).

Daną wyjściową dla zadania 1 stanowić będzie:

- wytrzymałość betonu na ściskanie.

Architektura modelu sieci na rysunku poniżej (rys. 6.1). pokazuje, że warstwa wejściowa składa się z 10 węzłów, warstwa ukryta ma 5-15 (np. 11) 11 węzłów i jedna warstwa wyjściowa odpowiada wytrzymałości na ściskanie.



Rysunek 6.1. Architektura sieci zastosowana dla zadania 1

Dane wejściowe dla zadania 2 stanowić będą:


- wytrzymałość betonu na ściskanie;
- zmienne o charakterze jakościowym (np. stosunek w/s, klasa cementu, rodzaj kruszywa).

Dane wyjściowe dla zadania 2 stanowią:

- zmienne o charakterze ilościowym (masa: wody, cementu, domieszek, dodatków i kruszywa).

Architektura modelu sieci na rysunku poniżej (rys. 6.2) pokazuje, że warstwa wejściowa składa się z 4 węzłów, warstwa ukryta ma 5-15 (np. 11) węzłów, a warstwa wyjściowa odpowiada komponentom ilościowym składu mieszanki.





Rysunek 6.2. Architektura sieci zastosowana dla zadania 2

### 6.2.1. Rozmiar zbioru uczącego

Rozmiar zbioru uczącego ma istotne znaczenie w procesie uczenia sieci neuronowej. Nie ma konkretnie określonej liczby przypadków, z której ma się składać zbiór uczący. Jego wielkość determinowana jest przez złożoność zależności funkcyjnej, która będzie poddawana modelowaniu. Przy nieodpowiednim doborze wielkości zbioru uczącego (zbyt mały zbiór) istnieje ryzyko wystąpienia nieprawidłowości w procesie uczenia (na skutek przypadkowych błędów w danych uczących). Wymagane jest spełnienie dwóch podstawowych warunków, aby sieć neuronowa mogła działać efektywnie [102,104,105]:

- zbiór uczący powinien zawierać każdą grupę zmiennych (dane uczące zwykle są podzielone na kilka podgrup). Podgrupy określane są przez konkretne wzorce; wszystkie te wzorce powinny uczestniczyć w procesie uczenia;

- każda grupa zmiennych powinna wykazywać zmienność statystyczną (zbiór uczący powinien wykazywać się odpowiednią różnorodnością).

Problem pojawia się także w przypadku, gdy rozmiar zbioru uczącego jest zbyt duży. Wraz z powiększaniem się jego wielkości proporcjonalnie (liniowo) wzrasta ilość czasu potrzebna do przeprowadzenia pełnego procesu uczenia. Z tego względu nie należy tworzyć zbyt dużego zbioru uczącego (powinien być optymalnie dobrany do modelu sieci w taki sposób, aby uczenie przebiegało możliwie najszybciej). Zbiór uczący w ramach niniejszej rozprawy składa się z 815 wyników badań niszczenia betonu.

### 6.2.2. Błędy przypadkowe

Istotnym zagadnieniem są nieścisłości (zakłócenia) w danych wejściowych, determinujące naukę sieci na zakłóconych wzorcach. Dochodzi wówczas do nieprawidłowej identyfikacji wzorców na skutek przeprowadzenia procesu nauki na niewłaściwym zbiorze. Taka sytuacja może być powodowana m.in. zbyt małym rozmiarem zbioru uczącego, dlatego przy prawdopodobieństwie wystąpienia takich błędów należy zwiększyć ilość danych wchodzących do zbioru uczącego.

### 6.2.3. Dobór rozmiaru sieci do wielkości zbioru uczącego

Rozmiar zbioru uczącego w istotny sposób rzutuje na architekturę sieci neuronowej. Duży zbiór danych wejściowych determinuje większy rozmiar sieci, a zbyt dopasowana sieć do zbioru uczącego prowadzić może do zjawiska nadmiernego dopasowania (tzw. *Overfitting*). Liczba wag sieci powinna być co najmniej dwukrotnie mniejsza aniżeli liczba wprowadzonych próbek. Dlatego zbiór danych w niniejszej dysertacji należy uznać za dobrany prawidłowo.

### 6.2.4. Reguły uczenia

Reguły uczenia sztucznych sieci neuronowych można sklasyfikować w dwóch grupach [104]. Pierwsza z nich obejmuje reguły, gdzie proces uczenia przebiega bez obecności nauczyciela (na wejściu sieci podawane są tylko dane wejściowe). Reprezentatywną regułą uczenia z tej grupy jest reguła Hebba. Druga z grup obejmuje reguły wymagające obecności nauczyciela, gdzie sieć otrzymuje ciąg uczący i uczy się na jego podstawie wzorca. Podstawową regułą uczenia z tej grupy jest reguła Delta (analizowana w pracy), realizowana dla ciągłych funkcji aktywacji. W oparciu o tą regułę neuron otrzymujący sygnały wejściowe (dotyczyć to może neuronów zarówno z warstwy wejściowej, jak i sygnałów z wcześniejszej warstwy) przetwarza je w określony sposób, tj. korzystając z ustalonych wag wytwarza sygnał wyjściowy. Następnie wartość sygnału wyjściowego konfrontowana jest z tą podaną przez nauczyciela (wzorcową), a różnica określana jako sygnał błędu  $\delta$  (od czego pochodzi nazwa metody) wykorzystywana jest do korygowania wag na wejściach poszczególnych neuronów. Zgodnie z tą zasadą zmiana wag może przebiegać następująco:

- im został wykryty większy błąd tym zmiana wag następuje w większym zakresie;
- proporcjonalnie do mocy sygnałów wejściowych, tj. sygnał korygowany jest adekwatnie do wartości sygnałów wejściowych (dla niewielkiej wartości wy-

stępuje znikomy zakres modyfikacji, a dla większej korekta przyjmuje znaczną wartość).

Znana wartość błędu umożliwia przewidywanie korekty wag. W kolejnych okresach uczenia sieć minimalizuje błąd i końcowo przerywa proces uczenia (korekty wag przyjmują infinitesimalne wartości) [303]. Metoda ta stosowana jest łącznie ze wspomnianym w rozdziale 3 algorytmem wstecznej propagacji błędu, a poszukiwaną wartością jest minimum błędu średniokwadratowego  $Q$ , określonego wyrażeniem 6.4.

$$Q = 0,5 \sum_{j=1}^N (z^j - y^j)^2 = \sum_{j=1}^N Q^j \quad (6.4)$$

$$Q^j = 0,5\delta^j{}^2 \quad (6.5)$$

Wagi ulegają korekcie według następującego wyrażenia:

$$\Delta w_i = \eta \delta^j \cdot f'(e^j) \cdot x_i^j \quad (6.6)$$

gdzie:

$f'$  – pochodna funkcji aktywacji

Jeśli funkcja aktywacji jest sigmoidalna wówczas wyrażenie 6.6 można zastąpić:

$$\Delta w_i = \eta \delta^j \cdot (1 - y^j) y^j \cdot x_i^j \quad (6.7)$$

### 6.3. Architektura i nauka sieci neuronowych

W rozpatrywanym przypadku, korzystając ze sztucznych sieci neuronowych, dane poddawane analizie dzielone są na następujące zbiory noszące nazwy:


- zbiór uczący (ok. 70% liczebności przypadków),
- zbiór testowy (ok. 15% liczebności przypadków),
- zbiór walidacyjny (ok. 15% liczebności przypadków).

Przez taki podział sieć neuronowa może wylosować 85% danych, na których przeprowadzany jest proces uczenia oraz poprawa wag dla danych wejściowych. (np. stosunek wodno-spoiwowy, kruszywa). Zbiór danych pozwala na przewidywanie określonych wartości, np. umożliwia ocenę wytrzymałości z wartościami, których program nie testował ani się nie uczył.

Po zakończeniu budowy bazy danych można zacząć określać topologię sieci neuronowej. Określa się m.in. ilości danych wejściowych i wyjściowych, ustala organizację neuronów w poszczególnych warstwach, określa funkcję aktywizacji oraz błędu. SSN zostaną wykorzystane jako aparat do zaprojektowania betonu o niskim stosunku wodno-spoiwowym. Betony zostały poddane badaniom, a składniki będą się zmieniać w stosunkowo niewielkim zakresie. Ta mała zmiana, np. stosunku wodno-spoiwowego, będzie miała duży wpływ na przebieg zmian fazowych w zaczynie cementowym (zaczyn, w którym ilość wody wynika z wodożądności normowej spoiwa jest miejscem, gdzie osiągnięto maksymalną szczelność ułożenia ziaren fazy stałej. W tej sytuacji wypełnia

się cała przestrzeń międzyziarnową wodą. Grubość warstwy wodnej otoczki osiąga minimalną wartość na ziarnach. Wynika to z oddziaływania siły elektrostatycznej).

Przebieg nauki realizowany będzie za pośrednictwem algorytmu wstecznej propagacji błędu (opisanego w rozdziale 4) według schematu:



Rysunek 6.3. Schemat działania algorytmu wstecznej propagacji błędu [303]


Zgodnie z rysunkiem 6.3 dane pochodzące z wejść  $x_1 \dots x_n$  działają równocześnie na sztuczny neuron poprzez pobudzenie w postaci wag  $w_{0k}, w_{1k} \dots w_{nk}$ . Właściwa pozostaje jedynie konfiguracja pobudzająca w danym momencie, powodująca reakcję neuronu  $f$  i przetworzenie sygnału z użyciem funkcji aktywacji (jej wartość zależna jest od aktualnej sumy wag). Perceptron o liczbie wejść  $n$  dokonuje podziału przestrzeni wektorów wejściowych  $x$  za pomocą prostej prostopadłej do wektora wag (rys. 6.4). Półpłaszczyzny oddzielone zostają hiperpłaszczyzną o  $n-1$  wymiarach, opisaną wyrażeniem 6.8.

(6.8)

$$\sum_{k=1}^n w_k x_k + \theta$$

gdzie:

$\theta$  – oznacza próg aktywacji neuronu



Rysunek 6.4. Podział przestrzeni wektorów wag [303]

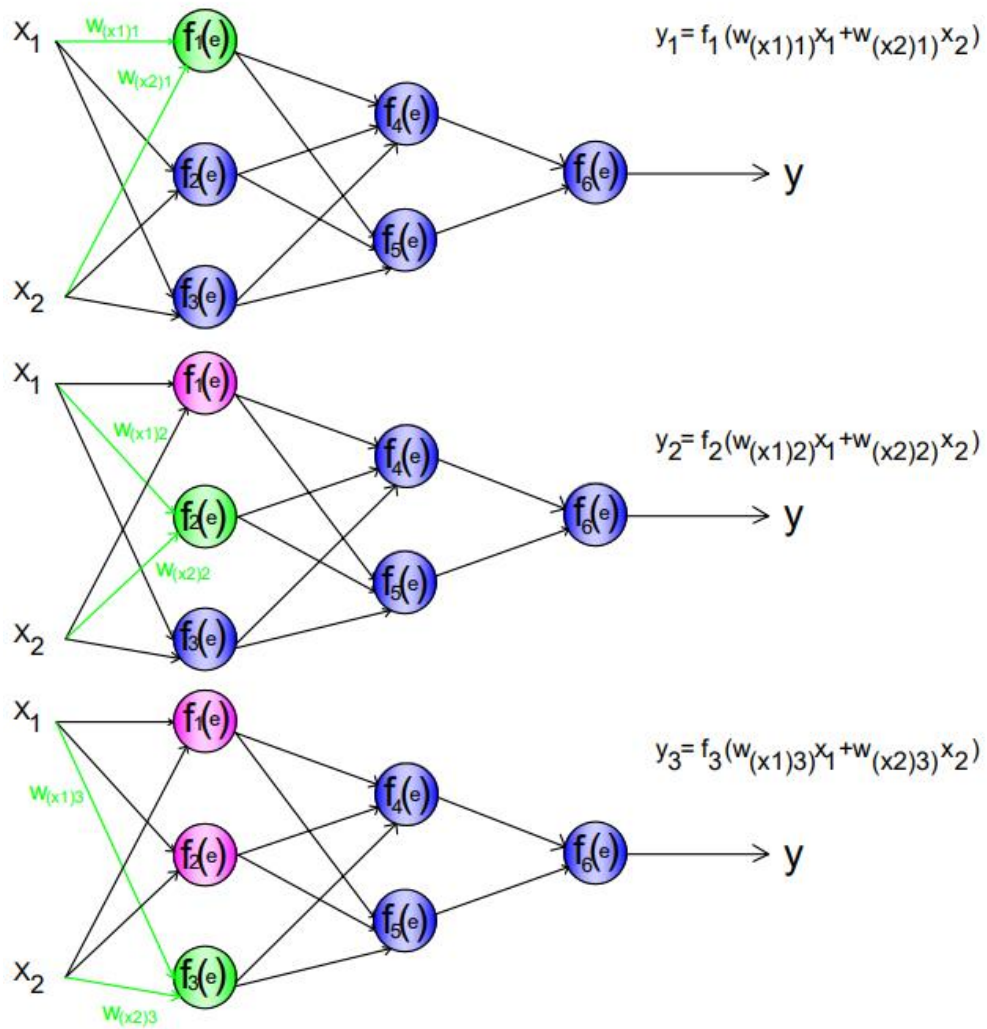
Zbiór określony poprzez pary wektorów uczących  $x$  oraz  $d(x)$  (wartość wyjścia wyuczona przez nauczyciela) zdefiniowany jest poprzez następującą sekwencję czynności:

- losowy wybór wagi dla początkowej wartości perceptronu  $w_i$ ;
- definicja wektora uczącego  $x$  określana na wejściu perceptronu;
- obliczenie zmiennej wyjściowej perceptronu  $y(x)$  co do wartości;
- konfrontacja obliczonej wartości wyjściowej  $y(x)$  z tą podaną przez nauczyciela dla wektora  $x$  (wartość wzorcowa);
- dokonanie modyfikacji wag uzależniając  $y(x)$  oraz  $d(x)$ , czyli przy założeniu, że  $y(x) \neq d(x)$  wówczas  $\theta = \theta + d(x)$  a  $w_i = w_i + d(x) \cdot x_i$  (założenie zmiany wagi neuronu – jeśli nie następuje wówczas wartość wagi pozostaje bez zmian);
- obliczenie średniego błędu dla wektorów wzorców uczących (następuje przerwanie algorytmu, jeśli wartość osiągniętego błędu jest mniejsza od wartości założonej bądź osiągnięto maksymalną ilość powtórzeń zbioru).


Uczenie realizowane jest za pomocą wspomnianej wcześniej metody wstecznej propagacji błędów (*backpropation algorithm*), umożliwiającej naukę sieci poprzez implementację reguły Delta. Uzyskiwana jest średniokwadratowa funkcja błędów (opisana wcześniej wyrażeniem 6.4) dla której poszukiwane jest minimum w odniesieniu do wektora wag  $w$ . Proces uczenia realizowany jest poprzez naprzemienne fazy, tj.:

- propagację sygnałów pochodzących od wejść (czyli wektora  $x$ ) do wyjścia;
- wsteczną propagację błędów od wyjścia sieci  $y$  w kierunku wejść sieci.


Na kolejnych rysunkach (6.5 ÷ 6.10) przedstawiono graficznie przebieg procesu nauki.



Rysunek 6.5. Przebieg procesu nauki [303]

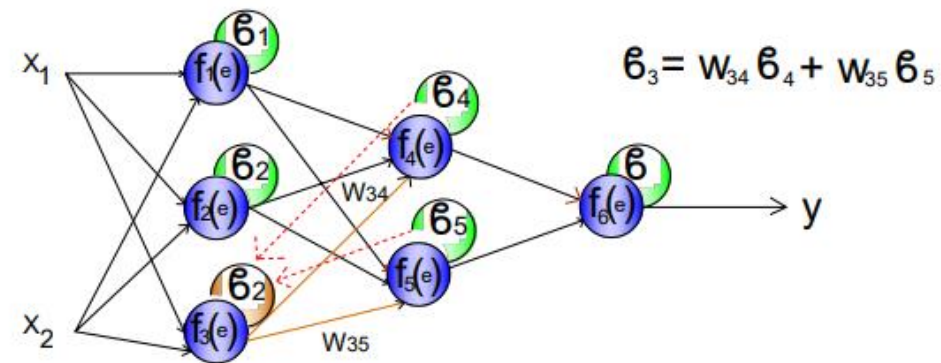




Rysunek 6.6. Przebieg procesu nauki [303]






Rysunek 6.7. Przebieg procesu nauki [303]






Rysunek 6.8. Przebieg procesu nauki [303]



Rysunek 6.9. Przebieg procesu nauki [303]



Rysunek 6.10. Przebieg procesu nauki [303]

Sieć wielowarstwowa pobudzana jest sygnałami wejściowymi  $x_1, x_2$  kolejnych warstw neuronów. Pobudzenie neuronów w pierwszej warstwie powoduje obliczenie wartości wejściowej  $y_1, y_2$  oraz  $y_3$ . Kolejna – druga warstwa neuronów pobudzana jest za pomocą tych sygnałów, co jest podstawą obliczenia wartości wyjściowej dla tej właśnie warstwy, tzn.  $y_4$  i  $y_5$ . Wyznaczone wartości wykorzystywane są jako pobudzenie neuronów ostatniej trzeciej warstwy (wyjściowej, w rozważanym przypadku zawierającej jeden neuron), na podstawie czego wyznaczana jest wartość wyjściowa  $y_6$ . Jest ona przyrównywana do wartości wzorcowej ( $z$ ), pochodzącej ze zbioru uczącego przedstawionego przez nauczyciela. Różnica pomiędzy tymi dwoma wartościami przyjmuje postać: ( $\delta = z - y$ ). Na podstawie obliczonego błędu zostaje dokonana propagacja sygnału wstecz (uzależniona od wag połączeń neuronów), a następnie sumowana odpowiednio dla każdego z neuronów w celu ustalenia błędu dla każdego z nich rozdzielnie. Proces propagacji następuje do poprzedniej warstwy neuronów (np. z trzeciej do drugiej), a wartość błędu jest zdeterminowana w tym przypadku przez aktualną wartość wagi zdefiniowanej dla neuronów trzeciej i drugiej warstwy (dokonywane jest sumowanie sygnałów błędów z warstwy trzeciej). Przy założeniu występowania jednego neuronu na warstwie wyjściowej (trzeciej) suma taka przybiera postać:

$$\delta_i = \sum_{j=1}^k w_{ji} \delta_j \quad (6.9)$$

np.

$$\begin{aligned} \delta_4 &= w_{46} \delta_6 \\ \delta_5 &= w_{56} \delta_6 \end{aligned}$$

Propagując błąd z warstwy drugiej do pierwszej błędy  $\delta_4$  i  $\delta_5$  zostają obliczone względem drugiej warstwy (w zależności od aktualnej wartości wag dla połączeń neuronów warstwy drugiej i pierwszej), a następnie ulegają sumowaniu według wzoru:

$$\delta_i = \sum_{j=1}^k w_{ji} \delta_j \quad (6.10)$$

Dokonanie korekty wag sieci ma na celu zmniejszenie wartości błędu średniokwadratowego wyznaczonego dla wyjścia sieci. Zabieg taki wykonywany jest przy wykorzystaniu reguły Delta, a mianowicie z zastosowaniem pochodnej cząstkowej funkcji aktywacji  $df_i(e) / de$ . Wyznaczenie jej zależy od rodzaju funkcji aktywacji  $f$  (przykładowe funkcje aktywacji określono wyrażeniami 6.11 – sigmoidalna i 6.12 – tangensa hiperbolicznego).

(6.11)

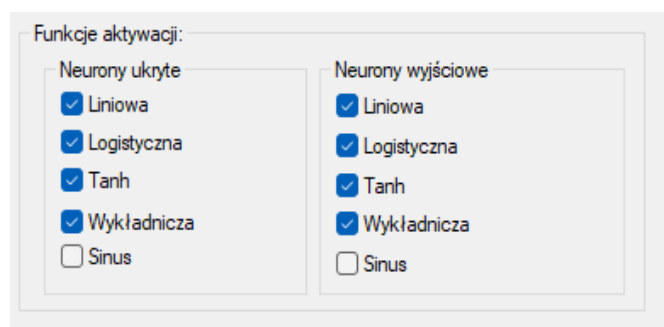
$$\begin{aligned} f(x) &= \frac{1}{1 + e^{-\beta \cdot x}} \\ f'(x) &= \beta \cdot f(x) \cdot (1 - f(x)) = \beta \cdot y \cdot (1 - y) \end{aligned}$$

tangensa hiperbolicznego:

(6.12)

$$f(x) = \operatorname{tgh}(\beta \cdot x)$$
$$f'(x) = \beta \cdot (1 - \operatorname{tgh}^2(\beta \cdot x)) = \beta \cdot y(1 - y^2)$$

Dostępne w programie Statistica funkcje aktywacji przedstawiono na poniższym rysunku.



Rysunek 6.11. Funkcje aktywacji dostępne w programie Statistica (gdzie logistyczna oznacza funkcję sigmoidalną)

#### 6.4. Predykcja wybranych cech betonu – wytrzymałości na ściskanie

Sieć, którą zbudowano do prognozowania wytrzymałości betonu wysokowartościowego (**zadanie 1 – definicja zmiennej wyjściowej w postaci wytrzymałości betonu na ściskanie**), na potrzeby rozpatrywanego problemu ma następującą topologię:

- charakterystyka problemu: regresyjny;
- liczba danych wejściowych – 10 (9) (przy czym masa piasku nie została włączona do symulacji ze względu na to, iż jest stała);
- typ sieci – perceptron wielowarstwowy (jednokierunkowe sieci wielowarstwowe, sieci MLP);
- algorytm uczenia – BFGS (wstecznej propagacji błędu);
- liczba neuronów w warstwie ukrytej –  $5 \div 15$ ;
- funkcja błędu – suma kwadratów;
- funkcja aktywacji oraz wyjścia – liniowa, sigmoidalna, tangens hiperboliczny lub wykładnicza (program dobiera automatycznie).

Należy zwrócić uwagę na liczbę danych poddawanych analizie, która wynosi 815 próbek. Na rysunku poniżej przedstawiono widok okna wyboru wektora wejścia oraz wyjścia.



Rysunek 6.12. Wybór wektora wejścia oraz wyjścia


Przy rozwiązywaniu problemów regresyjnych zmienna objaśniana (wytrzymałość betonu na ściskanie) ma charakter ilościowy, natomiast zmienne wyjściowe, objaśniające mogą mieć charakter ilościowy (stosunek wodno-spoiwowy, masa: wody, cementu, domieszki, dodatku oraz kruszywa) lub/i jakościowy (rodzaj kruszywa grubego, klasa cementu). Symulacja wykonana przy użyciu SSN pozwala prognozować wytrzymałość betonu na ściskanie – na podstawie wyników badań laboratoryjnych, które wykonano na potrzeby niniejszej pracy. Dla rozważanych przypadków (predykcji wytrzymałości na ściskanie oraz predykcji składu mieszanki) definiuje się problem polegający na określaniu związku pomiędzy składem mieszanki, a wytrzymałością betonu wysokowartościowego. Zróżnicowaniu podlegają zmienne wyjściowe i wejściowe.

Wyniki badań laboratoryjnych poddane zostały odpowiedniej analizie do zdefiniowanej topologii sieci. Rezultaty uzyskane w wyniku działania sieci wyjaśniają zadany problem z dużą dokładnością, gdyż stopień zgodności (jakość prognozowania, rozumiana jako porównanie wartości prognozowanej z wartościami ze zbioru walidacyjnego, czyli takiego, na którym program się nie uczył ani nie testował) wynosił 95,6%, co należy uznać za wynik poprawny na tym poziomie tworzenia sieci neuronowych. Stopień zgodności określono na podstawie wyrażenia 6.3. Przykładowe wyniki predykcji (dla pojedynczych sieci oraz zespołu sieci) wytrzymałości na ściskanie dla betonów zestawiono w tabeli 6.1 oraz przedstawiono graficznie na rysunku 6.13.

Tabela 6.1. Predykcja wytrzymałości betonu na ściskanie

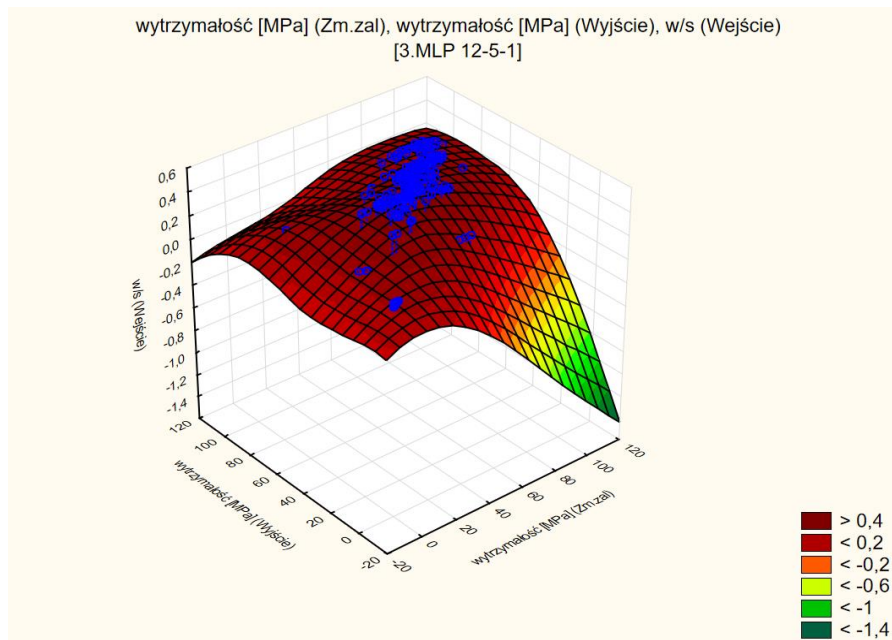
L.p.	Wytrzymałość betonu na ściskanie [MPa]	Predykcja [MPa]				Stopień zgodności [%]
		3. MLP 12-5-1	5. MLP 12-12-1	11. MLP 12-11-1	Zespół sieci	
1	71,57	68,59	63,65	72,99	68,41	95,58
2	68,53	68,59	63,65	72,99	68,41	99,83
3	80,95	70,08	74,54	78,09	74,24	91,70
4	78,41	70,08	74,54	78,09	74,24	94,68
5	79,56	76,35	78,42	80,18	78,32	98,43
6	74,28	76,35	78,42	80,18	78,32	94,57
7	78,33	76,35	78,42	80,18	78,32	99,98
8	77,30	75,54	78,93	75,87	76,78	99,33
9	80,28	75,54	78,93	75,87	76,78	95,64
10	74,52	75,54	78,93	75,87	76,78	96,98
11	75,24	73,73	76,91	72,46	74,37	98,84
12	74,66	73,73	76,91	72,46	74,37	99,62
13	74,86	73,73	76,91	72,46	74,37	99,35
14	65,75	66,34	67,93	65,24	66,50	98,85
15	63,34	66,34	67,93	65,24	66,50	95,00
16	53,02	51,85	57,15	52,11	53,70	98,71
17	40,43	46,41	42,95	39,13	42,83	94,06
18	41,59	46,41	42,95	39,13	42,83	97,03
19	16,16	17,17	8,24	12,84	12,75	78,90
20	96,76	100,49	101,81	97,18	99,83	96,83
21	98,85	100,49	101,81	97,18	99,83	99,01
22	95,50	100,49	101,81	97,18	99,83	95,47
23	94,58	85,30	87,53	90,93	87,92	92,96
24	97,17	85,30	87,53	90,93	87,92	90,49
25	100,06	85,30	87,53	90,93	87,92	87,87
26	87,72	79,66	85,66	85,09	83,47	95,16
27	83,58	79,66	85,66	85,09	83,47	99,87
28	87,22	76,75	86,57	81,08	81,47	93,41
29	85,49	76,75	86,57	81,08	81,47	95,30
30	83,42	75,66	85,37	79,06	80,03	95,94

W tabeli 6.1 zawarto wyniki predykcji wykonane za pomocą pojedynczych sieci (S3, S5, S11) oraz zespołu sieci (S). Poszczególne sieci oznaczono następującym schematem: np. S3 (MLP 12-5-1), gdzie MLP oznacza perceptron wielowarstwowy, 12 liczbę danych wejściowych, 5 liczbę neuronów w warstwie ukrytej, a 1 to liczba danych wyjściowych. Program tworzy dodatkowe sztuczne zmienne wejściowe, aby zdefiniować w sposób liczbowy dane jakościowe. Wyniki predykcji są w 95,6% zbieżne z rezultatami badań eksperymentalnych, co wskazuje na prawidłowość zastosowanej metody.




Rysunek 6.13. Graficzna prezentacja wyników sieci







Rysunek 6.14. Graficzna prezentacja wyników sieci, gdzie: wytrzymałość betonu otrzymana z badań (Zm. zal), wytrzymałość otrzymana na wyjściu z predykcji (wyjście), w/s – stosunek wodno-spoiwowy wprowadzany na wejściu



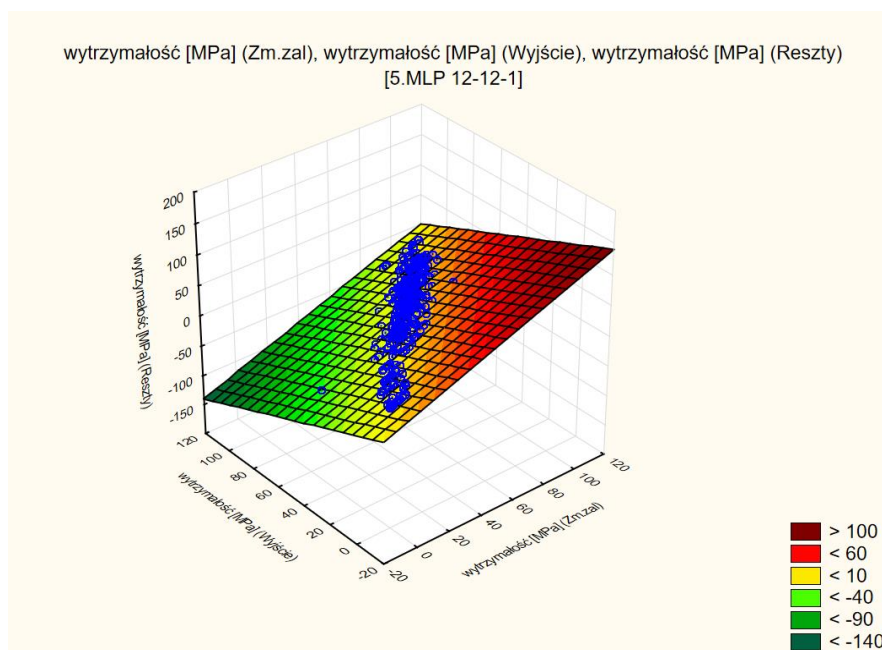
Rysunek 6.15. Graficzna prezentacja wyników sieci, gdzie: wytrzymałość betonu otrzymana z badań (Zm. zal), wytrzymałość otrzymana na wyjściu z predykcji (wyjście), w/s – stosunek wodno-spoiwowy wprowadzany na wejściu




Rysunek 6.16. Graficzna prezentacja wyników sieci, gdzie: wytrzymałość betonu otrzymana z badań (Zm. zal), wytrzymałość otrzymana na wyjściu z predykcji (wyjście), w/s – stosunek wodno-spoiwowy wprowadzany na wejściu



Rysunek 6.17. Graficzna prezentacja wyników sieci, gdzie: wytrzymałość betonu otrzymana z badań (Zm. zal), wytrzymałość otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)

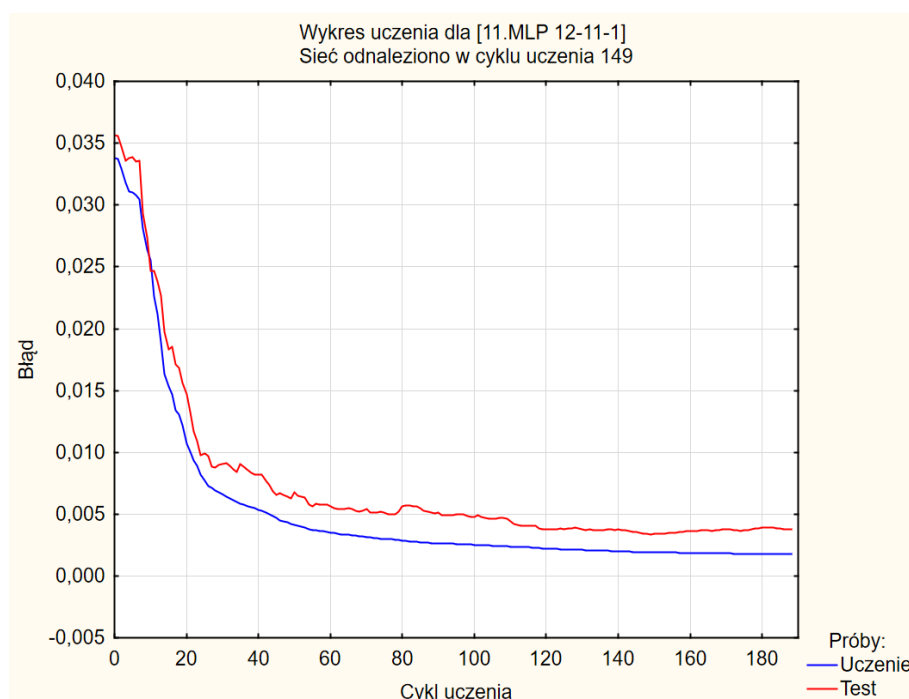


Rysunek 6.18. Graficzna prezentacja wyników sieci, gdzie: wytrzymałość betonu otrzymana z badań (Zm. zal), wytrzymałość otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)



Rysunek 6.19. Graficzna prezentacja wyników sieci, gdzie: wytrzymałość betonu otrzymana z badań (Zm. zal), wytrzymałość otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)

Wykresy przedstawione na rysunkach 6.13 oraz 6.14 ÷ 6.19 prezentują dopasowanie wyników, uzyskane na skutek działania sieci. Na osi odciętej zaprezentowano zmienną wyjściową (wytrzymałość betonu na ściskanie uzyskaną z badań laboratoryjnych), natomiast rzędna określa wartości otrzymane w efekcie predykcji programu. Dokonując analizy stwierdzić można, iż następuje dobre dopasowanie sieci do analizowanego problemu. Wykres uczenia sieci (przedstawiony na rysunku 6.20) nie wskazuje na występowanie znaczących błędów.



Rysunek 6.20. Wykres błęd dla próby uczącej i testowej

Analizując powyższy wykres można zauważyć, że błąd (liczony przez sieć jako funkcja sumy kwadratów) dla obydwu prób osiąga swoje minimum w ok. 150 cyklu uczenia. Kolejne epoki (kroki, podczas których wyznaczane są przybliżenia optymalnych wartości parametrów) nie zmieniały poziomu błędów sieci.

Wygenerowano z programu statystyki dotyczące sieci i przedstawiono je w tabeli 6.2.

Tabela 6.2. Podsumowanie sieci

L.p.	Posumowanie sieci			
	Id sieci	3	5	11
1	Nazwa sieci	MLP 12-5-1	MLP 12-12-1	MLP 12-11-1
2	Jakość (uczenie)	0,936	0,975	0,971
3	Jakość (testowanie)	0,921	0,941	0,954
4	Jakość (walidacja)	0,939	0,961	0,955
5	Błąd (uczenie)	49,091	20,173	22,754
6	Błąd (testowanie)	65,089	49,618	39,703
7	Błąd (walidacja)	46,774	30,640	34,571
8	Algorytm uczenia	BFGS 152	BFGS 188	BFGS 149
9	Funkcja błędu	SOS	SOS	SOS
10	Aktywacja (ukryte)	Logistyczna	Tanh	Tanh
11	Aktywacja (wyjściowe)	Logistyczna	Logistyczna	Logistyczna

Dla zadanej macierzy danych wygenerowano wagi dobierane w procesie uczenia (przedstawiono je w załączniku 3, w tabelach 1.1; 1.2; 1.3). W tabeli 6.3 zaprezentowano statystyki predykcji.

Tabela 6.3. Statystyki predykcji

<b>Id sieci</b>	<b>3</b>	<b>5</b>	<b>11</b>
Nazwa sieci	MLP 12-5-1	MLP 12-12-1	MLP 12-11-1
Minimum przewidywanych (uczenie)	0,0099	0,0099	0,0099
Maksimum przewidywanych (uczenie)	100,4929	108,5618	105,4754
Minimum przewidywanych (test)	0,0099	0,0099	0,0099
Maksimum przewidywanych (test)	97,3882	98,8605	99,1237
Minimum przewidywanych (walidacja)	0,0099	0,0099	0,0099
Maksimum przewidywanych (walidacja)	98,9721	108,5618	100,8991
Minimum reszt (uczenie)	-74,6945	-51,0617	-47,1561
Maksimum reszt (uczenie)	40,9817	30,9994	34,9050
Minimum reszt (test)	-74,7045	-51,0717	-47,1661
Maksimum reszt (test)	30,2872	62,7375	49,4151
Minimum reszt (walidacja)	-30,7570	-16,4062	-30,8161
Maksimum reszt (walidacja)	31,0718	44,2559	28,7838
Minimum standaryzowanych reszt (uczenie)	-10,6607	-11,3687	-9,8857
Maksimum standaryzowanych reszt (uczenie)	5,8491	6,9019	7,3174
Minimum standaryzowanych reszt (test)	-9,2596	-7,2503	-7,4854
Maksimum standaryzowanych reszt (test)	3,7541	8,9065	7,8424
Minimum standaryzowanych reszt (walidacja)	-4,4972	-2,9639	-5,2411
Maksimum standaryzowanych reszt (walidacja)	4,5432	7,9951	4,8954

Tabela 6.4. Analiza wrażliwości

Dane	Sieci			
	3.MLP 12-5-1	5.MLP 12-12-1	11.MLP 12-11-1	Średnia
Masa kruszywa frakcji [2-8 mm]	17,44	75,06	45,43	45,98
Masa wody	15,56	73,54	43,51	44,20
w/s	12,68	40,18	21,27	24,71
Masa kruszywa frakcji [8-16 mm]	4,94	45,51	14,06	21,50
Masa cementu	13,25	21,39	18,59	17,74
Masa domieszki	4,37	11,20	12,25	9,27
Masa mikrokrzemionki	3,43	11,71	12,53	9,22
Rodzaj cementu	2,76	7,03	6,05	5,28
Rodzaj kruszywa grubego	1,00	1,00	1,00	1,00

W tabeli 6.4 przedstawiono analizę wrażliwości sieci. Wykazała ona, iż sieci wykazują silną wrażliwość dla danych znaczących, tj. masy kruszywa frakcji 2-8 mm oraz masy wody.

### 6.5. Predykcja składu ilościowego mieszanki betonowej

Sieć, którą zbudowano do prognozowania wytrzymałości betonu wysokowartościowego (**zadanie 2 – definicja zmiennych wyjściowych w postaci składu ilościowego mieszanki**), na potrzeby rozpatrywanego problemu ma następującą topologię:

- charakterystyka problemu: regresyjny;
- liczba danych wejściowych – 4;
- liczba danych wyjściowych – 6;
- typ sieci - perceptron wielowarstwowy (jednokierunkowe sieci wielowarstwowe, sieci MLP);
- algorytm uczenia – BFGS (wstecznej propagacji błędu);
- liczba neuronów w warstwie ukrytej –  $5 \div 15$ ;
- funkcja błędu – suma kwadratów;
- funkcja aktywacji oraz wyjścia – liniowa, sigmoidalna, tangens hiperboliczny lub wykładnicza (program dobiera automatycznie).

Liczba danych poddawana analizie tak jak w poprzednim zadaniu wynosi 815 próbek. Na rysunku poniżej przedstawiono widok okna wyboru wektora wejścia oraz wyjścia.



Rysunek 6.21. Wybór wektora wejścia oraz wyjścia

Zdefiniowano, iż ten typ zadania należy klasyfikować jako regresyjny – zmienna objaśniana (skład mieszanki betonowej) ma charakter ilościowy, natomiast zmienne wyjściowe, objaśniające mogą mieć charakter ilościowy (stosunek wodno-spoiwowy, wytrzymałość betonu na ściskanie) i jakościowy (rodzaj kruszywa grubego, klasa cementu). Symulacja wykonana przy użyciu SSN wykonywana jest w celu predykcji składu mieszanki betonowej. Dla rozważanego przypadku (predykcji składu mieszanki) definiuje się problem polegający na określaniu związku pomiędzy składem mieszanki, a wytrzymałością betonu wysokowartościowego (tak jak dla zadania pierwszego), natomiast zróżnicowaniu podlegają zmienne wyjściowe i wejściowe.

Wyniki badań laboratoryjnych poddane zostały odpowiedniej analizie do zdefiniowanej topologii sieci. Rezultaty uzyskane w wyniku działania sieci wyjaśniają zadany problem z 80% (dostatecznie zadowalającą) dokładnością, gdyż właśnie tyle wynosi stopień zgodności (jakość prognozowania, rozumiana jako porównanie wartości prognozowanej z wartościami ze zbioru walidacyjnego, czyli takiego, na którym program się nie uczył ani nie testował). Przykładowe wyniki predykcji (dla pojedynczych sieci oraz zespołu sieci) wartości składników ilościowych mieszanki zestawiono w tabelach 6.5 ÷ 6.10 oraz przedstawiono graficznie na rysunkach 6.22 ÷ 6.27. Stopień zgodności określono na podstawie wyrażenia 6.3.



Tabela 6.5. Predykcja masy cementu

L.p.	Masa cementu [kg]	Predykcja [kg]				Stopień zgodności [%]
		3. MLP 7-13-6	5. MLP 7-9-6	9. MLP 7-10-6	Zespół	
1	2,27	2,27	2,26	2,27	2,27	99,91
2	2,27	2,27	2,26	2,28	2,27	100,00
3	2,27	2,26	2,26	2,26	2,26	99,54
4	2,15	2,12	2,14	2,12	2,13	99,06
5	2,15	2,13	2,14	2,13	2,13	99,22
6	2,04	2,00	1,98	1,97	1,98	97,08
7	2,04	2,00	1,97	1,96	1,98	96,86
8	1,85	1,79	1,79	1,79	1,79	96,59
9	1,85	1,79	1,79	1,79	1,79	96,61
10	1,85	1,79	1,79	1,79	1,79	96,59
11	1,77	1,71	1,71	1,71	1,71	96,46
12	1,77	1,71	1,71	1,71	1,71	96,42
13	1,77	1,71	1,71	1,71	1,71	96,42
14	1,57	1,51	1,49	1,50	1,50	95,84
15	1,57	1,50	1,48	1,49	1,49	95,13
16	1,47	1,40	1,39	1,39	1,39	94,74
17	1,47	1,39	1,39	1,38	1,39	94,35
18	2,27	2,26	2,25	2,21	2,24	98,73
19	2,27	2,25	2,25	2,20	2,23	98,44
20	2,27	2,27	2,26	2,27	2,27	99,91
21	2,27	2,27	2,26	2,28	2,27	100,00
22	2,27	2,26	2,26	2,26	2,26	99,54
23	2,15	2,12	2,14	2,12	2,13	99,06
24	2,15	2,13	2,14	2,13	2,13	99,22
25	2,04	2,00	1,98	1,97	1,98	97,08
26	2,04	2,00	1,97	1,96	1,98	96,86
27	1,85	1,79	1,79	1,79	1,79	96,59
28	1,85	1,79	1,79	1,79	1,79	96,61
29	1,85	1,79	1,79	1,79	1,79	96,59
30	1,77	1,71	1,71	1,71	1,71	96,46

Tabela 6.6. Predykcja masy wody

L.p.	Masa wody [kg]	Predykcja [kg]				Stopień zgodności [%]
		3. MLP 7-13-6	5. MLP 7-9-6	9. MLP 7-10-6	Zespół	
1	0,48	0,48	0,48	0,47	0,48	99,87
2	0,48	0,48	0,48	0,47	0,48	99,83
3	0,48	0,48	0,48	0,47	0,48	99,86
4	0,52	0,52	0,51	0,52	0,52	99,88
5	0,52	0,52	0,51	0,52	0,52	99,86
6	0,55	0,55	0,55	0,55	0,55	99,82
7	0,55	0,55	0,55	0,55	0,55	99,69
8	0,61	0,61	0,61	0,61	0,61	99,83
9	0,61	0,61	0,61	0,61	0,61	99,83
10	0,61	0,61	0,61	0,61	0,61	99,83
11	0,64	0,64	0,63	0,64	0,64	99,68
12	0,64	0,64	0,63	0,64	0,64	99,69
13	0,64	0,64	0,63	0,64	0,64	99,69
14	0,70	0,70	0,71	0,70	0,70	99,94
15	0,70	0,70	0,71	0,70	0,71	99,83
16	0,74	0,74	0,73	0,74	0,73	99,72
17	0,74	0,74	0,73	0,74	0,73	99,77
18	0,48	0,48	0,48	0,48	0,48	99,28
19	0,48	0,48	0,48	0,48	0,48	99,30
20	0,48	0,48	0,48	0,48	0,48	99,28
21	0,52	0,48	0,48	0,48	0,48	93,12
22	0,52	0,52	0,52	0,52	0,52	99,24
23	0,55	0,56	0,56	0,56	0,56	98,72
24	0,55	0,56	0,56	0,56	0,56	98,67
25	0,58	0,59	0,59	0,59	0,59	99,35
26	0,58	0,59	0,59	0,59	0,59	99,35
27	0,61	0,61	0,61	0,61	0,61	99,83
28	0,64	0,64	0,64	0,64	0,64	99,78
29	0,64	0,64	0,64	0,64	0,64	99,80
30	0,67	0,67	0,67	0,67	0,67	99,95

Tabela 6.7. Predykcja masy kruszywa frakcji 2-8 mm

L.p.	Masa kruszywa frakcji 2-8 mm [kg]	Predykcja [kg]				Stopień zgodności [%]
		3. MLP 7-13-6	5. MLP 7-9-6	9. MLP 7-10-6	Zespól	
1	2,34	2,34	2,34	2,33	2,34	99,95
2	2,34	2,34	2,34	2,33	2,34	99,94
3	2,34	2,34	2,34	2,33	2,34	99,94
4	2,34	2,34	2,34	2,33	2,34	99,87
5	2,34	2,34	2,34	2,33	2,34	99,86
6	2,34	2,33	2,34	2,33	2,34	99,84
7	2,34	2,33	2,34	2,33	2,34	99,82
8	2,34	2,33	2,34	2,33	2,34	99,85
9	2,34	2,34	2,34	2,33	2,34	99,87
10	2,34	2,34	2,34	2,33	2,34	99,85
11	2,34	2,33	2,34	2,33	2,34	99,85
12	2,34	2,34	2,34	2,34	2,34	99,88
13	2,34	2,34	2,34	2,34	2,34	99,88
14	2,34	2,34	2,34	2,34	2,34	99,93
15	2,34	2,34	2,34	2,34	2,34	99,96
16	2,34	2,35	2,34	2,35	2,34	99,84
17	2,34	2,35	2,34	2,35	2,35	99,79
18	2,83	2,83	2,83	2,82	2,82	99,90
19	2,83	2,83	2,83	2,82	2,82	99,90
20	2,83	2,83	2,83	2,82	2,82	99,90
21	2,83	2,83	2,83	2,82	2,82	99,89
22	2,83	2,83	2,83	2,82	2,83	99,96
23	2,83	2,83	2,83	2,83	2,83	99,94
24	2,83	2,83	2,83	2,83	2,83	99,96
25	2,83	2,83	2,83	2,83	2,83	99,94
26	2,83	2,83	2,83	2,83	2,83	99,94
27	2,83	2,83	2,83	2,83	2,83	99,98
28	2,83	2,82	2,83	2,83	2,83	99,97
29	2,83	2,82	2,83	2,83	2,83	99,97
30	2,83	2,82	2,83	2,83	2,83	99,98

Tabela 6.8. Predykcja masy kruszywa frakcji 8-16 mm

L.p.	Masa kruszywa frakcji 8-16 mm [kg]	Predykcja [kg]				Stopień zgodności [%]
		3. MLP 7-13-6	5. MLP 7-9-6	9. MLP 7-10-6	Zespół	
1	2,34	2,34	2,34	2,33	2,34	99,99
2	2,34	2,34	2,34	2,33	2,34	99,98
3	2,34	2,34	2,34	2,33	2,34	99,99
4	2,34	2,34	2,34	2,33	2,34	99,90
5	2,34	2,34	2,34	2,33	2,34	99,89
6	2,34	2,33	2,34	2,33	2,34	99,84
7	2,34	2,33	2,34	2,33	2,34	99,83
8	2,34	2,33	2,34	2,33	2,34	99,87
9	2,34	2,34	2,34	2,33	2,34	99,88
10	2,34	2,33	2,34	2,33	2,34	99,87
11	2,34	2,33	2,34	2,34	2,34	99,87
12	2,34	2,34	2,34	2,34	2,34	99,89
13	2,34	2,34	2,34	2,34	2,34	99,89
14	2,34	2,33	2,34	2,34	2,34	99,94
15	2,34	2,34	2,34	2,34	2,34	99,94
16	2,34	2,34	2,34	2,35	2,34	99,82
17	2,34	2,34	2,34	2,35	2,35	99,77
18	2,83	2,83	2,83	2,82	2,83	99,98
19	2,83	2,83	2,83	2,82	2,83	99,98
20	2,83	2,83	2,83	2,82	2,83	99,98
21	2,83	2,83	2,83	2,82	2,83	99,98
22	2,83	2,83	2,83	2,83	2,83	99,91
23	2,83	2,83	2,83	2,83	2,83	99,90
24	2,83	2,83	2,83	2,83	2,83	99,91
25	2,83	2,83	2,83	2,83	2,83	99,93
26	2,83	2,83	2,83	2,83	2,83	99,93
27	2,83	2,82	2,83	2,83	2,83	99,97
28	2,83	2,82	2,83	2,82	2,82	99,94
29	2,83	2,82	2,83	2,82	2,82	99,94
30	2,83	2,82	2,83	2,82	2,82	99,94

Tabela 6.9. Predykcja masy domieszki

L.p.	Masa domieszki [kg]	Predykcja [kg]				Stopień zgodności [%]
		3. MLP 7-13-6	5. MLP 7-9-6	9. MLP 7-10-6	Zespół	
1	0,02	0,02	0,02	0,02	0,02	89,70
2	0,02	0,02	0,03	0,02	0,02	73,13
3	0,02	0,01	0,02	0,01	0,02	83,94
4	0,02	0,01	0,02	0,01	0,01	83,61
5	0,02	0,01	0,02	0,01	0,02	91,03
6	0,02	0,01	0,02	0,00	0,01	69,46
7	0,02	0,01	0,03	0,01	0,02	99,21
8	0,02	0,01	0,03	0,01	0,02	98,18
9	0,07	0,05	0,05	0,06	0,05	75,71
10	0,07	0,05	0,04	0,06	0,05	72,15
11	0,07	0,05	0,04	0,05	0,05	71,11
12	0,06	0,05	0,06	0,05	0,05	82,46
13	0,06	0,05	0,05	0,05	0,05	75,33
14	0,06	0,04	0,05	0,05	0,05	75,26
15	0,06	0,04	0,05	0,05	0,05	77,37
16	0,06	0,04	0,04	0,04	0,04	72,71
17	0,06	0,04	0,04	0,04	0,04	70,75
18	0,06	0,04	0,04	0,04	0,04	71,76
19	0,05	0,04	0,03	0,04	0,04	71,41
20	0,05	0,04	0,03	0,04	0,04	69,85
21	0,05	0,04	0,03	0,04	0,04	72,66
22	0,05	0,03	0,03	0,04	0,03	63,78
23	0,05	0,03	0,03	0,04	0,03	64,45
24	0,05	0,03	0,03	0,03	0,03	63,79
25	0,05	0,03	0,03	0,03	0,03	67,91
26	0,04	0,03	0,04	0,04	0,04	82,20
27	0,07	0,06	0,05	0,08	0,06	88,78
28	0,07	0,05	0,05	0,07	0,06	86,24
29	0,07	0,05	0,05	0,07	0,06	86,18
30	0,06	0,05	0,07	0,06	0,06	93,05


Tabela 6.10. Predykcja masy dodatku

L.p.	Masa dodatku [kg]	Predykcja [kg]				Stopień zgodności [%]
		3. MLP 7-13-6	5. MLP 7-9-6	9. MLP 7-10-6	Zespól	
1	0,10	0,05	0,06	0,04	0,05	51,38
2	0,09	0,06	0,06	0,04	0,05	58,67
3	0,09	0,07	0,07	0,05	0,06	64,45
4	0,09	0,06	0,06	0,04	0,06	59,90
5	0,09	0,08	0,07	0,06	0,07	78,60
6	0,09	0,08	0,07	0,06	0,07	78,67
7	0,09	0,08	0,07	0,06	0,07	78,46
8	0,08	0,08	0,08	0,07	0,08	92,34
9	0,08	0,08	0,09	0,09	0,09	89,10
10	0,07	0,08	0,10	0,09	0,09	75,76
11	0,07	0,08	0,10	0,09	0,09	74,24
12	0,10	0,08	0,09	0,09	0,09	90,13
13	0,10	0,09	0,09	0,09	0,09	94,35
14	0,10	0,08	0,09	0,09	0,09	89,44
15	0,09	0,08	0,09	0,09	0,08	90,93
16	0,09	0,08	0,08	0,08	0,08	84,87
17	0,09	0,07	0,08	0,08	0,08	84,99
18	0,09	0,07	0,08	0,08	0,07	83,88
19	0,08	0,05	0,06	0,06	0,06	70,25
20	0,10	0,06	0,07	0,07	0,07	70,13
21	0,10	0,06	0,07	0,07	0,06	67,00
22	0,09	0,08	0,07	0,07	0,07	77,01
23	0,09	0,08	0,07	0,07	0,07	78,09
24	0,09	0,08	0,07	0,07	0,07	77,41
25	0,09	0,08	0,08	0,07	0,08	86,19
26	0,09	0,09	0,07	0,07	0,08	86,14
27	0,08	0,09	0,08	0,08	0,08	98,95
28	0,08	0,09	0,08	0,08	0,08	98,42
29	0,08	0,09	0,08	0,08	0,08	96,71
30	0,08	0,08	0,09	0,08	0,09	90,81


W tabelach 6.5 ÷ 6.10 zawarto wniki predykcji wykonane za pomocą pojedynczych sieci (S3, S5, S9) oraz zespołu sieci (S). Poszczególne sieci oznaczono następującym schematem: np. S3 (MLP 7-13-1), gdzie MLP oznacza perceptron wielowarstwowy, 7 liczbę danych wejściowych, 13 liczbę neuronów w warstwie ukrytej, a 1 to liczba danych wyjściowych. Program tworzy dodatkowe sztuczne zmienne wejściowe, aby zdefiniować w sposób liczbowy dane jakościowe. Stopień zgodności (liczony wg. wyrażenia 6.3) (średni) dla kolejnych danych ilościowych wynosi odpowiednio:

- dla masy cementu 96,34 %;
- dla masy wody 99,41 %;
- dla masy kruszywa frakcji 2-8 mm 99,91 %;
- dla masy kruszywa frakcji 8-16 mm 99,90 %;
- dla masy domieszki 78,11 %;
- dla masy dodatku 80,58 %.

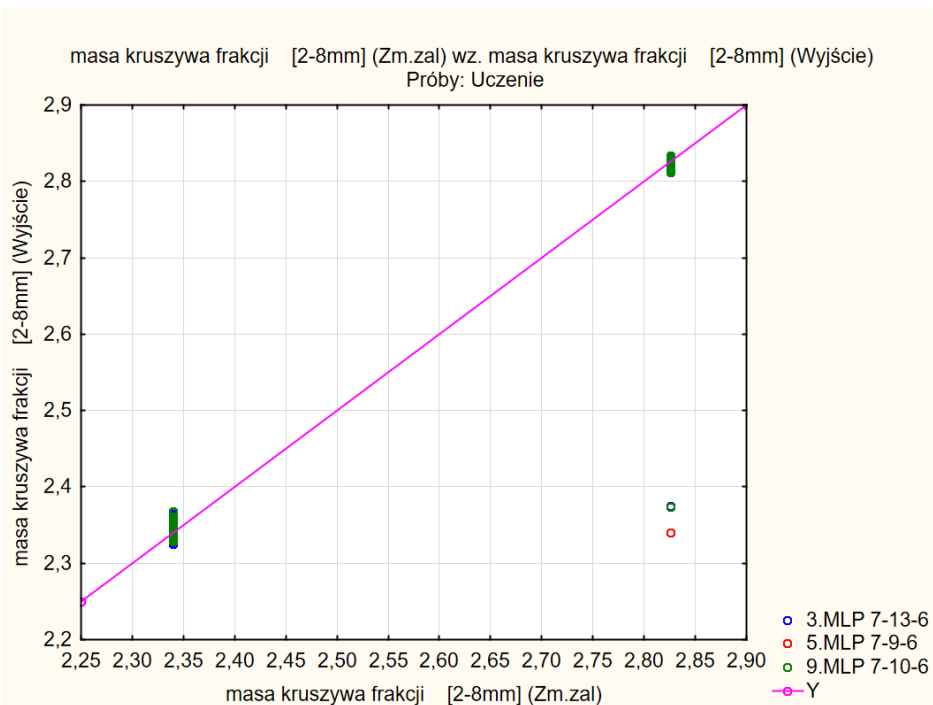
Widoczne są zatem zakłócenia przy prognozowaniu masy domieszki oraz dodatku. Wynikać może to ze zbyt małego zbioru danych (zbyt mała liczba próbek w których wykorzystywano domieszkę oraz dodatek). Wskazuje to na konieczność poszerzenia macierzy danych o większą liczbę przypadków, w celu uzyskania lepszej generalizacji (stąd jakość walidacji wynosi około 80 %).



Rysunek 6.22. Graficzna prezentacja wyników sieci dla masy cementu




Rysunek 6.23. Graficzna prezentacja wyników sieci dla masy wody




Rysunek 6.24. Graficzna prezentacja wyników sieci dla masy kruszywa frakcji 2-8 mm






Rysunek 6.25. Graficzna prezentacja wyników sieci dla masy domieszki




Rysunek 6.26. Graficzna prezentacja wyników sieci dla masy mikrokrzemionki


Wykresy płaszczyznowe przedstawiono dla sieci 9. MLP 7-10-6 (dla każdej zmiennej podlegającej predykcji można by wygenerować wykresy trzech rozważanych sieci – analogicznie do zadania pierwszego). Dla kruszywa frakcji 2-8 oraz 8-16 program nie generował płaszczyzn zbieżności.




Rysunek 6.27. Graficzna prezentacja wyników sieci, gdzie: masa cementu wg. receptury (Zm.zal), masa cementu otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)




Rysunek 6.28. Graficzna prezentacja wyników sieci, gdzie: masa wody wg. receptury (Zm.zal), masa wody otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)




Rysunek 6.29. Graficzna prezentacja wyników sieci, gdzie: masa domieszki wg. receptury (Zm.zal), masa domieszki otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)




Rysunek 6.30. Graficzna prezentacja wyników sieci, gdzie: masa dodatku wg. receptury (Zm.zal), masa dodatku otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)




Rysunek 6.31. Graficzna prezentacja wyników sieci, gdzie: masa cementu wg. receptury (Zm. zal), masa cementu otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)



Rysunek 6.32. Graficzna prezentacja wyników sieci, gdzie: masa wody wg. receptury (Zm. zal), masa wody otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)

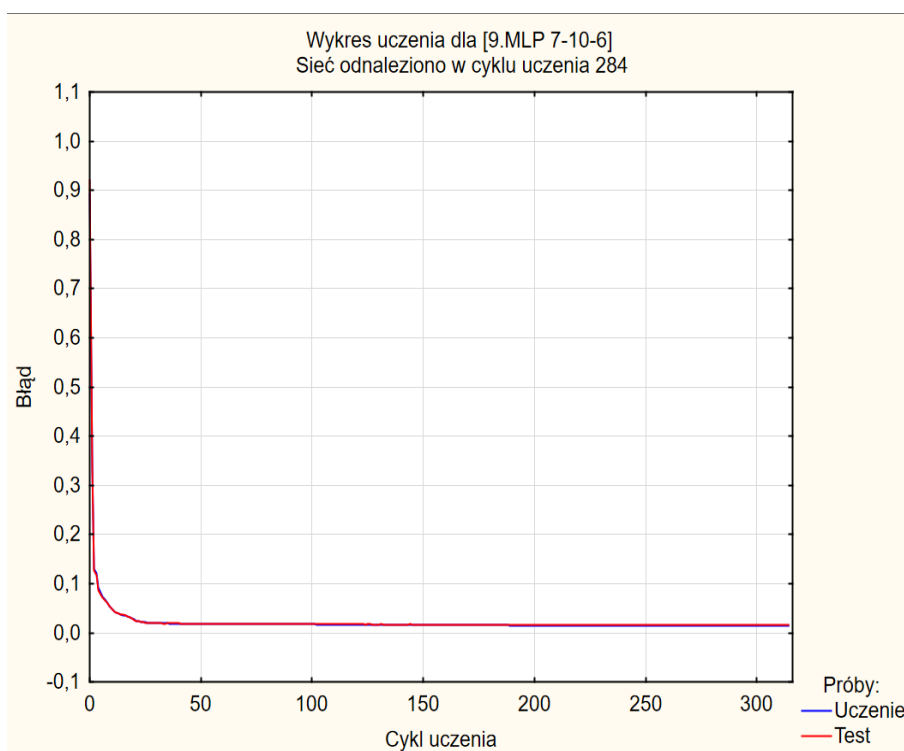


Rysunek 6.33. Graficzna prezentacja wyników sieci, gdzie: masa domieszki wg receptury (Zm.zal), domieszki otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)



Rysunek 6.34. Graficzna prezentacja wyników sieci, gdzie: masa dodatku wg. receptury (Zm.zal), dodatku otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)

Wykresy przedstawione na rysunkach 6.22 ÷ 6.35 prezentują dopasowanie wyników uzyskane na skutek działania sieci. Na osi odciętej zaprezentowano zmienną wyjściową (wytrzymałość betonu na ściskanie uzyskaną z badań laboratoryjnych), natomiast rzędna określa wartości otrzymane w efekcie predykcji programu. Analizując powyższy wynik można zauważyć dobre dopasowanie sieci dla masy cementu, wody, kruszywa frakcji 2-8 i 8-16 mm, a gorsze dla masy domieszki i dodatku. Dodatkowo wygenerowano wykres uczenia sieci (przedstawiony na rysunku 6.36).



Rysunek 6.35. Wykres błędu dla próby uczącej i testowej

Analizując powyższy wykres można zauważyć, że błąd (liczony przez sieć jako funkcja sumy kwadratów) dla obydwu prób osiąga swoje minimum w ok. 280 cyklu uczenia. Kolejne epoki (kroki, podczas których wyznaczane są przybliżenia optymalnych wartości parametrów) nie zmieniały poziomu błędu sieci.

Wygenerowano z programu statystyki dotyczące sieci i przedstawiono je w tabeli 6.11.

Tabela 6.11. Podsumowanie sieci

L.p.	Posumowanie sieci			
	Id sieci	3	5	9
1	Nazwa sieci	MLP 7-13-6	MLP 7-9-6	MLP 7-10-6
2	Jakość (uczenie)	0,803	0,786	0,804
3	Jakość (testowanie)	0,815	0,804	0,805
4	Jakość (walidacja)	0,805	0,800	0,802
5	Błąd (uczenie)	0,010	0,010	0,010
6	Błąd (testowanie)	0,013	0,013	0,013
7	Błąd (walidacja)	0,015	0,015	0,015
8	Algorytm uczenia	BFGS 238	BFGS 109	BFGS 284
9	Funkcja błędu	SOS	SOS	SOS
10	Aktywacja (ukryte)	Tanh	Tanh	Tanh
11	Aktywacja (wyjściowe)	Liniowa	Logistyczna	Liniowa

Dla zadanej macierzy danych wygenerowano wagi dobierane w procesie uczenia (przedstawiono je w załączniku 3, w tabelach 2.1; 2.2; 2,3). W tabeli 6.12 zaprezentowano statystyki predykcji.

Tabela 6.12. Statystyki predykcji

<b>Id sieci</b>	<b>3</b>	<b>5</b>	<b>9</b>
Nazwa sieci	MLP 7-13-6	MLP 7-9-6	MLP 7-10-6
Minimum przewidywanych (uczenie)	-0,0540	0,0001	-0,0612
Maksimum przewidywanych (uczenie)	0,3076	0,3997	0,2703
Minimum przewidywanych (test)	-0,0456	0,0002	-0,0299
Maksimum przewidywanych (test)	0,3259	0,4220	0,2598
Minimum przewidywanych (walidacja)	-0,0446	0,0012	-0,0291
Maksimum przewidywanych (walidacja)	0,3144	0,3975	0,2553
Minimum reszt (uczenie)	-0,1567	-0,1519	-0,1545
Maksimum reszt (uczenie)	0,7943	0,7923	0,7934
Minimum reszt (test)	-0,1524	-0,1877	-0,1297
Maksimum reszt (test)	0,7966	0,7951	0,7959
Minimum reszt (walidacja)	-0,1359	-0,1154	-0,1738
Maksimum reszt (walidacja)	0,7944	0,7924	0,7934
Minimum standaryzowanych reszt (uczenie)	-1,5645	-1,5278	-1,5424
Maksimum standaryzowanych reszt (uczenie)	7,9294	7,9717	7,9211
Minimum standaryzowanych reszt (test)	-1,3578	-1,6462	-1,1433
Maksimum standaryzowanych reszt (test)	7,0960	6,9727	7,0146
Minimum standaryzowanych reszt (walidacja)	-1,1218	-0,9549	-1,4149
Maksimum standaryzowanych reszt (walidacja)	6,5573	6,5554	6,4587



Tabela 6.13. Analiza wrażliwości

Dane	Sieci			
	3.MLP 7-13-6	5.MLP 7-9-6	9.MLP 7-10-6	Średnia
w/s	6,24	4,80	5,31	5,44
Wytrzymałość [MPa]	1,37	1,46	1,41	1,41
Rodzaj cementu	1,03	1,02	1,07	1,04
Rodzaj kruszywa grubego	1,00	1,00	1,00	1,00

W tabeli 6.13 przedstawiono analizę wrażliwości sieci. Wykazała ona, iż sieci wykazują silną wrażliwość dla danych znaczących, tj. stosunek wodno-spoiwowy.

## 6.6. Program (algorytm) do predykcji składu mieszanki betonowej

Algorytm (kod programu) wygenerowano z programu Statistica i zamieszczono w załączniku 4 (dla zadania pierwszego oraz drugiego).

## 6.7. Podsumowanie

Sieci neuronowe umożliwiają dokładną analizę rozpatrywanego zjawiska, pozwalają na interpolację wyników (w obszarze danych), jak i przystosowanie modeli do innych warunków (np. założenie innej matrycy danych aniżeli ta przyjęta do modelowania, prognozowanie mrozoodporności). Niezwykle ważny jest zbiór danych, który będzie wykorzystywany do nauki sieci. W stworzonym na potrzeby pracy zbiorze uczącym zawarte są dane uzyskane z rzeczywistych pomiarów, które zostały odpowiednio przygotowane (oczyszczone) do implementacji w programie (usunięto rekord 172 – wytrzymałość ok. 1MPa, który zakłócał działanie sieci oraz klasyfikatora). Nie można wymagać od algorytmu właściwego prognozowania wytrzymałości dla danych znacząco innych od tych, dla których były stworzone (np. znacząco odbiegające warunki dojrzewania od tych występujących w laboratorium). Nie jest zatem możliwa właściwa predykcja dla nieznanymi wcześniej parametrów.

Istotne w procesie uczenia są wagi wejść przyporządkowane do poszczególnych neuronów. Neuron charakteryzuje się wieloma wejściami, które służą do odbierania sygnałów (przetworzonych odpowiednio za pomocą wag) pochodzących z wejścia oraz od innych neuronów. Zmiana wartości wagi wiąże się z przyporządkowaniem innej funkcji rozpatrywanemu neuronowi. Celem uczenia jest zatem taki dobór wag, aby neurony wykonywały zadane im funkcje. Rozmiar sieci powoduje, iż nierealne jest przypisanie w sposób arbitralny i jednorazowy wszystkich niezbędnych wag do procesu uczenia. Istniejąca wartości wagi jest korygowana w kolejnych iteracjach. Nauczyciel przedstawia informacje niezbędne do przeprowadzenia procesu uczenia (w przypadku uczenia z nauczycielem), jednak zmiana wag przypisanych do neuronu następuje spontanicznie i niezależnie od niego. Wagi neuronów dla poszczególnych zadań zawarto w załączniku 3.

Wykonanie predykcji objęte niniejszym rozdziałem pozwoliło na rozwiązanie założonych zadań:

- Zadanie 1: zastosowanie sztucznych sieci neuronowych do istniejącej mieszanki betonowej, w celu predykcji wytrzymałości betonu na ściskanie. Dane wejściowe dla zadania 1 stanowiły:

- zmienne o charakterze ilościowym (stosunek w/s, masa: wody, cementu, domieszek, dodatków i kruszywa);
- zmienne o charakterze jakościowym (klasa cementu, wodozadržność, rodzaj kruszywa).

Daną wyjściową dla zadania 1 stanowiła predykcja wytrzymałości betonu na ściskanie.

- Zadanie 2: uzyskanie składu mieszanki betonowej w zakresie ilościowym, na podstawie podanych danych ilościowych oraz jakościowych składników mieszanki betonowej. Dane wejściowe dla zadania 2 stanowiły:

- wytrzymałość betonu na ściskanie;
- zmienne o charakterze jakościowym (stosunek w/s, klasa cementu, rodzaj kruszywa).

Dane wyjściowe dla zadania 2 stanowiły zmienne o charakterze ilościowym (masa: wody, cementu, domieszek, dodatków i kruszywa).


Miarę poprawności określano za podstawie stopnia zgodności (obliczanego zgodnie z równaniem 6.3). Zadanie 1 rozwiązano z 95,6% dokładnością, natomiast dla zadania 2 uzyskano 80%. Dokonano sprawdzenia poprawności predykcji zadania 1 za pomocą klasyfikatora XGBoost (aktualnie powszechnie stosowanego w informatyce). Jest to metoda uczenia zespołowego, która łączy prognozy wielu słabych modeli w celu uzyskania silniejszej prognozy. XGBoost oznacza „*Extreme Gradient Boosting*” i jest jednym z najpopularniejszych i najczęściej używanych algorytmów uczenia maszynowego ze względu na jego zdolność do obsługi dużych zbiorów danych oraz zdolność do osiągnięcia dużej wydajności w wielu zadaniach uczenia maszynowego, takich jak klasyfikacja i regresja. Użyto 80% zbioru do uczenia i walidacji, 20% zbioru do testowania. Parametry klasyfikatora zostały wybrane za pomocą metody GridSearch (popularna metoda strojenia hiperparametrów). Metoda ta polega na zebraniu różnorodnych parametrów, po których następuje tworzenie klasyfikatorów - metoda za każdym razem zmienia tylko jeden element z podanych (w ten sposób uzyskuje się najlepszy zestaw parametrów). Wybrane w wyniku działania GridSearch parametry uczenia klasyfikatora wskazano poniżej (szczegóły implementacyjne):

- `learning_rate = 0.01` (parametr określający jak zmieniać krok w procesie uczenia; miara zapobiegająca przeuczeniu (bardzo mała wartość może jednak wpłynąć na znaczące wydłużenie procesu uczenia));
- `n_estimators = 1000` (liczba drzew);
- `max_depth = 11` (maksymalna głębokość drzewa – im większa głębokość tym bardziej skomplikowany model, tj. wraz ze wzrostem złożoności modelu można zaobserwować jego skłonność do przeuczenia);
- `subsample = 0.5` (wartość z zakresu  $0 \div 1$  określająca jak duża część zbioru jest wykorzystana do konstrukcji drzew w jednym kroku – w jednym kroku wybiera się 50% wierszy do uczenia);
- `colsample_bytree = 0.8` (wartość z zakresu  $0 \div 1$  określająca jak wiele kolumn będzie wykorzystane do budowy drzewa – w kolejnej iteracji wykorzystane będą inne 80% kolumn).

Stała masa piasku została usunięta, podobnie jak w symulacji wykonanej przy pomocy programu Statistica. Dane żwir/grys i cement przedstawiono w formie numerycznej (technika one-hot encoding). F6 przyjmuje wartość 1 dla żwiru i 0 dla grysu, natomiast F7 odwrotnie. Podobnie w przypadku cementów - F10 odzwierciedlono za pomocą 1 dla CEM I, F11 za pomocą 2 dla CEM II i F12 za pomocą 3 dla CEM IV (taki samo proces przebiegał w sposób niejawni w programie Statistica). Na wejściu zatem przyjęto 12 cech (tab. 6.14). Z pliku wygenerowano wykres, który przedstawia wpływ cechy na wynik przewidywania. Uzyskane wyniki są zbieżne z tymi otrzymanymi z programu Statistica – jedną z najistotniejszych cech jest masa wody (rys. 6.36).

Tabela 6.14. Oznaczenia zmiennych przyjętych do klasyfikatora XGBoost

Oznaczenia na rys.	Model XGBoost	Oznaczenia przyjęte w programie Statistica
0	F1	w/s
1	F2	masa cementu
2	F3	masa wody
3	F4	masa kruszywa 2-8
4	F5	masa kruszywa 8-16
5	F6	żwir/grys (1)
6	F7	żwir/grys (2)
7	F8	masa domieszki
8	F9	masa mikrokrzemionki
9	F10	Cement (1)
10	F11	Cement (2)
11	F12	Cement (3)
	RESULT	wytrzymałość



Rysunek 6.36. Analiza wrażliwości wygenerowana z programu XGBoost

Tabela 6.15. Wyniki predykcji wytrzymałości betonu na ściskanie otrzymane za pomocą klasyfikatora XGBoost

L.p.	Wytrzymałość betonu na ściskanie (uzyskana z badań) [MPa]	Predykcja uzyskana z klasyfikatora XGBoost [MPa]	Stopień zgodności [%]
1	84,25	79,93	94,87
2	12,85	11,28	87,76
3	64,95	64,68	99,58
4	77,58	74,81	96,43
5	70,86	71,46	99,14
6	84,14	86,07	97,71
7	99,07	91,01	91,86
8	108,63	103,44	95,22
9	89,91	86,39	96,08
10	39,63	45,41	85,41
11	97,01	91,23	94,05
12	50,81	47,88	94,22
13	1,04	1,14	90,23
14	73,76	71,02	96,28
15	91,20	92,39	98,70
16	72,11	68,89	95,53
17	75,03	77,30	96,99
18	66,65	68,47	97,28
19	69,30	70,36	98,47
20	72,73	74,34	97,77
21	47,06	42,95	91,26
22	74,66	79,30	93,78
23	45,07	45,67	98,66
24	74,25	74,54	99,61
25	71,31	68,25	95,71
26	59,04	65,17	89,61
27	44,92	46,86	95,67
28	74,02	73,60	99,44
29	55,63	55,25	99,32
30	74,86	74,58	99,63

Stopień zgodności wyliczony na podstawie wyrażenia 6.3 wynosi 95,1%. Wyniki predykcji otrzymanej w niniejszym rozdziale zbieżne są ze sprawdzeniem przeprowadzonym za pomocą klasyfikatora XGBoost.

W celu poprawy wyników uzyskanych z predykcji dla zadania 2 niezbędne jest udoskonalenie globalne metody tak, aby uzyskać poprawę stopnia zgodności. Może to przebiegać na drodze powiększania matrycy danych w zakresie danych wejściowych (szczególnie ilości próbek z domieszką i dodatkiem). Ponadto warte uwagi byłoby poszerzenie zbioru o serie betonów wykonywanych z dodatkiem mikrokrzemionki w udziale 15% i większą aniżeli zalecana (3%) ilością domieszki.

Dokonanie oceny poprawności uzyskanych wyników możliwe będzie dopiero po wykonaniu badań dla sytuacji zbliżonych do zadawanych algorytmowi, co stanowi przedmiot rozważań kolejnego rozdziału niniejszej pracy.

## 7. PREDYKCJA WYTRZYMAŁOŚCI BETONU Z UŻYCIEM SIECI NEURONOWYCH WRAZ Z WALIDACJĄ

### 7.1. Rozważany problem (wprowadzenie)

Projekt mieszanki odgrywa dominującą rolę w określaniu właściwości betonu. Kruszywo, udział objętościowy poszczególnych frakcji, wielkość i kształt cząstek, chropowatość kruszyw, zaczyn cementowy, stosunek wodno-spoiwowy, rodzaj i objętość domieszki oraz warunki dojrzewania istotnie wpływają na właściwości produkowanego betonu. Projekt mieszanki można opracować na podstawie prób laboratoryjnych, co okazuje się czasochłonne i pracochłonne. Optymalizacja projektowania mieszanek betonowych jest motywowana stale rosnącym zapotrzebowaniem projektantów i decydentów na dobieranie proporcji mieszanek, które będą spełniały wiele – często konkurujących ze sobą wymagań dotyczących wydajności (w tym kosztów), urabialności, właściwości mechanicznych, trwałości i zrównoważenia środowiskowego. Niniejsze badania mają na celu optymalizację proporcji mieszanki betonowej przy użyciu sieci neuronowych tak, aby zwiększyć wykorzystanie struktury komponentów do najbardziej właściwego ich usytuowania (uzyskania maksymalnej szczelności upakowania). Dlatego w rozdziale 6 podjęto próbę uzyskania programu (algorytmu SSN) do predykcji wytrzymałości betonu na ściskanie oraz projektowania składu ilościowego mieszanki betonowej. W tym rozdziale utworzony algorytm SSN zostanie poddany sprawdzeniu i ocenie. Zostanie wykonana predykcja (przewidywanie) przy wykorzystaniu nowego zestawu parametrów dla zadania pierwszego (predykcja wytrzymałości na ściskanie – pkt. 6.4 pracy) oraz drugiego (predykcja składu mieszanki – pkt. 6.5 pracy). Wyniki otrzymane na drodze predykcji (uzyskane w efekcie nauki wytrenowanych sieci) zostaną porównane do wartości uzyskanych z badań laboratoryjnych. W celu dokonania weryfikacji rozwiązania zadania pierwszego w laboratorium zostały wykonane próbki (o założonym składzie – dla którego wykonana została predykcja wytrzymałości betonu na ściskanie), które poddane zostały niszczeniu. Dane wejściowe do predykcji wytrzymałości betonu na ściskanie będą stanowić: stosunek w/s, masa cementu, masa wody, masa kruszywa frakcji 2-8 mm, masa kruszywa frakcji 8-16 mm, rodzaj kruszywa grubego, masa mikrokrzemionki oraz rodzaj cementu. Obliczenie stopnia zgodności pomiędzy wartościami wytrzymałości uzyskanymi z predykcji oraz badań laboratoryjnych pozwoli na ocenę efektywności metody. Dla zadania drugiego wykonana zostanie predykcja składu mieszanki betonowej przy zestawie danych wejściowych obejmujących: stosunek w/s, wytrzymałość betonu na ściskanie, rodzaj kruszywa grubego, rodzaj cementu. Otrzymany skład mieszanki betonowej posłużył do wykonania próbek w warunkach laboratoryjnych, które następnie zostały zniszczone. Wytrzymałość założona do predykcji oraz otrzymana z badań laboratoryjnych zostaną porównane i ocenione za pomocą stopnia zgodności.

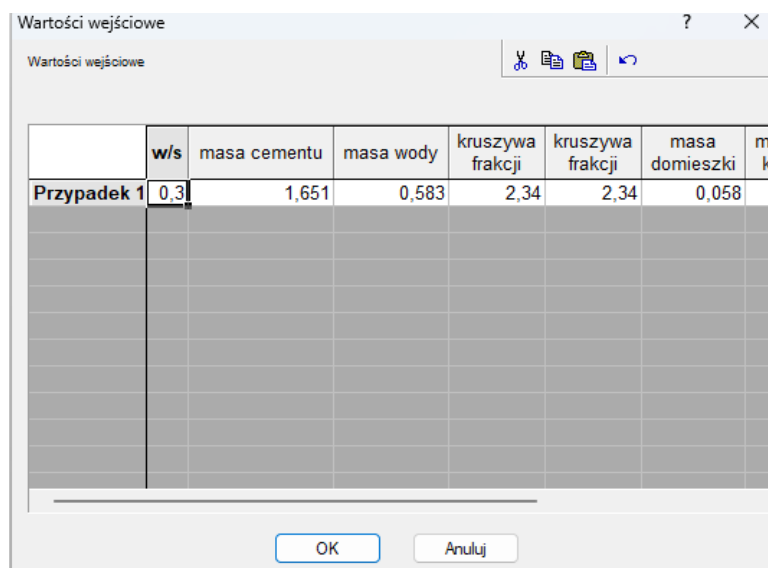
## 7.2. Predykcja wytrzymałości zaprojektowanego betonu (walidacja) z użyciem SSN

W celu predykcji wytrzymałości przyjęto do rozpatrzenia następujący zestaw danych (na jeden laboratoryjny zarób – trzy próbki).

Tabela 7.1. Zmienne wejściowe do predykcji wytrzymałości

Zmienna wejściowa	Wartość
w/s	0,3
masa cementu	1,651
masa wody	0,583
masa piasku	1,656
masa kruszywa frakcji [2-8 mm]	2,34
masa kruszywa frakcji [8-16 mm]	2,34
rodzaj kruszywa grubego	żwir
masa domieszki	0,058
masa mikrokrzemionki	0,291
rodzaj cementu	CEM IV

Następnie w programie Statistica uruchomiono moduł przewidywania dla nowych danych i wprowadzono dane z tabeli 7.1.



Rysunek 7.1. Widok okna służącego do wprowadzania nowych danych

W efekcie otrzymano prognozowaną wytrzymałość na ściskanie:

Przewidywania dla nowych danych (Arkusz23)										
Przyp.	5.wytrzymałość [MPa]_(t)	w/s	masa cementu	masa wody	masa kruszywa frakcji [2-8mm]	masa kruszywa frakcji [8-16mm]	masa domieszki	masa mikro-krzemionki	rodzaj kruszywa grubego	rodzaj cementu
1	61,16757	0,300000	1,651000	0,583000	2,340000	2,340000	0,058000	0,291000	żwir	CEM IV

Rysunek 7.2. Prognoza wytrzymałości dla zadanego przypadku

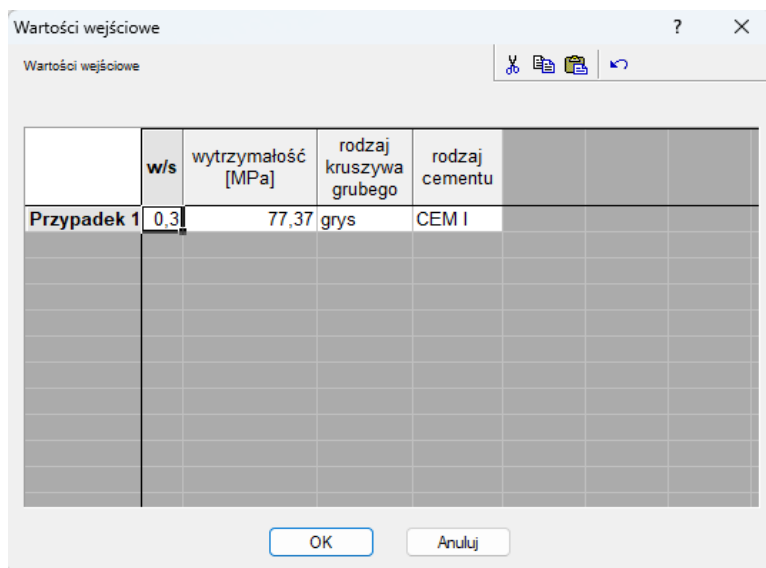
### 7.3. Predykcja składu mieszanki betonowej zaprojektowanego betonu (walidacja) z użyciem SSN

W celu predykcji składu mieszanki betonowej przyjęto do rozpatrzenia następujący zestaw danych (na jeden laboratoryjny zarób – trzy próbki):

Tabela 7.2. Zmienne wejściowe do predykcji wytrzymałości

Zmienna wejściowa	Wartość
w/s	0,3
wytrzymałość [MPa]	77,37
rodzaj kruszywa grubego	grys
rodzaj cementu	CEM I

Przyjęto wytrzymałość jak dla betonu z domieszką nr 2 w ilości 1% (kruszywo łamane) bez dodatków. Następnie w programie Statistica uruchomiono moduł przewidywania dla nowych danych i wprowadzono dane z tabeli 7.2.



Rysunek 7.3. Widok okna służącego do wprowadzania nowych danych



W efekcie otrzymano prognozowany zestaw danych:

Przewidywania dla nowych danych (Arkusz113)										
Przyp.	3.masa cementu_(t)	3.masa wody_(t)	3.masa kruszywa frakcji [2-8mm]_(t)	3.masa kruszywa frakcji [8-16mm]_(t)	3.masa domieszki_(t)	3.masa mikrokrzemionki_(t)	w/s	wytrzymałość [MPa]	rodzaj kruszywa grubego	rodzaj cementu
1	1,866213	0,583990	2,828384	2,826747	0,045289	0,087245	0,300000	77,37000	grys	CEM I

Rysunek 7.4. Prognoza składu ilościowego mieszanki dla zadanego przypadku

#### 7.4. Badania laboratoryjne

Dla założonego w tabeli 7.3 składu mieszanki betonowej przeprowadzono badania laboratoryjne (zgodnie z metodyką zawartą w rozdziale 5). Próbki wykonywane były w jednakowych warunkach, a zatem nie zaistniały przeszkody do ich porównywania. Prognozowana wytrzymałość betonu na ściskanie wyniosła 61,17 MPa (rys. 7.2), a wytrzymałość otrzymana w rezultacie badań to 60,09 MPa.

Tabela 7.3. Wyniki badań laboratoryjnych

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,3	100,18	100,47	10065,08	600,8	59,69	60,09
	100,16	100,48	10064,08	620,8	61,68	
0,30 x1	100,22	101,05	10127,23	596,5	58,9	

Dla założonego w tabeli 7.4 składu mieszanki betonowej przeprowadzono badania laboratoryjne (zgodnie z metodyką zawartą w rozdziale 5). Próbki wykonywane były w jednakowych warunkach, a zatem nie zaistniały przeszkody do ich porównywania. Prognozowana wytrzymałość betonu na ściskanie wyniosła 77,37 MPa (rys. 7.30), a wytrzymałość otrzymana w rezultacie badań to 93,14 MPa.

Tabela 7.4. Wyniki badań laboratoryjnych

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,3	100,73	100,00	10073,00	894,1	88,76	93,14
	99,95	100,45	10039,98	931,9	92,82	
0,30 x1	101,71	102,30	10404,93	1018,0	97,84	

## 7.5. Podsumowanie

Dokonano oceny efektywności zaproponowanej metody porównując wartość otrzymaną na drodze badań laboratoryjnych do wartości otrzymanej z programu (predykcji sieci neuronowych). Jako miarę efektywności przyjęto zgodność uzyskanych wyników. Efektywność obliczono wykorzystując wyrażenie 7.3 (otrzymane na drodze przekształcenia wzoru 6.3):

- błąd bezwzględny

$$\Delta Z = |Z - Z_p| \quad (7.1)$$

gdzie: X jest wartością wytrzymałości uzyskaną z badań laboratoryjnych, a  $Z_p$  jest wartością uzyskaną z predykcji [Pa]

- błąd względny

$$\varepsilon = \frac{\Delta Z}{Z_p} \quad (7.2)$$

- stopień zgodności (rozumiany jako efektywność)

$$E = (1 - \varepsilon) \times 100\% \quad (7.3)$$

Wykorzystując poszczególne wyniki z rozwiązań zadań pierwszego i drugiego możliwe jest porównanie wytrzymałości na ściskanie uzyskanej w wyniku predykcji programu (SSN) oraz tej otrzymanej w rzeczywistym badaniu laboratoryjnym mieszanki. Efekty przedstawiono w tabeli 7.5.

Tabela 7.5. Ocena efektywności

Obliczana wartość	Zadanie 1	Zadanie 2
wartość wytrzymałości betonu na ściskanie otrzymana z predykcji [MPa]	61,17	77,37
wartość wytrzymałości betonu na ściskanie otrzymana z badania [MPa]	60,09	93,14
błąd bezwzględny [-]	1,08	15,77
błąd względny [-]	0,02	0,20
stopień zgodności [%]	98,24	79,62

## 8. ZAKOŃCZENIE

### 8.1. Wprowadzenie

Technologia i projektowanie betonów jest dziedziną, która rozwija się w bardzo szybkim tempie. Poprzez modyfikowanie składu i struktury betonu uzyskuje się poprawę jego parametrów, w tym zwiększoną wytrzymałość na ściskanie. W wyniku procesu kształtowania betonu o wysokiej wytrzymałości zwiększają się także szanse na poprawę innych parametrów (np. mrozoodporności, nasiąkliwości, ścieralności) w porównaniu do betonu zwykłego. Poszukiwanie odpowiedniej kompozycji składu może odbywać się poprzez poszukiwanie takiego stosunku wodno-spoiwowego, przy którym uzyskana zostanie wysoka wytrzymałość na ściskanie, przy jednoczesnej poprawie innych parametrów. Z tego względu w niniejszej pracy skupiono się na betonach wysokowartościowych, wysokowytrzymałościowych o niskim stosunku wodno-spoiwowym.

W przypadku betonów zwykłych wystarczająco dokładne okazują się tradycyjne metody projektowania składu mieszanki. Przy betonach o niskim stosunku wodno-spoiwowym występują dodatkowe problemy (opisane w rozdziale drugim pracy), których zwyczajowo nie bierze się pod uwagę podczas procesu projektowania. Kalibracja modeli teoretycznych mieszanki jest niezbędna przy każdorazowej zmianie parametrów wejściowych, jak również wprowadzeniu nowych zmiennych. Sformułowanie modelu empirycznego w wielowymiarowej przestrzeni parametrów składu i właściwości kompozytu wysokowartościowego może okazać się zbyt skomplikowane. Proces ten zazwyczaj wymaga przeprowadzenia niezbędnych badań laboratoryjnych próbnymi seriami betonów. Te czynności badawcze wymagają najczęściej określonych nakładów czasowych i finansowych, co może zostać istotnie ograniczone dzięki zastosowaniu metody sztucznej inteligencji. Wyniki badań połączone z metodami symulacyjnymi pozwalają na osiągnięcie nowych zastosowań, a w dotychczas stosowanych rozwiązaniach uzyskuje się dodatkowe korzyści. Na podstawie rozważań poczynionych w rozdziale 3 zaimplementowano do rozwiązania powyższych problemów sztuczne sieci neuronowe (SSN).

Przywoływana w pracy literatura zawiera wprowadzenie w problematykę nowoczesnych systemów obliczeniowych. Przedstawiono historię powstania oraz kierunki rozwoju i wykorzystania sztucznych sieci neuronowych na przestrzeni lat. Fundamentalną różnicą pomiędzy metodami określanymi jako komputerowe (standardowe programy komputerowe – sekwencyjne), a sztucznymi sieciami neuronowymi jest sposób generacji zależności pomiędzy informacją wejściową, a informacją wyjściową (pochodząca z predykcji). Oznacza to, że w celu rozwiązania problemu obliczeniowego należy utworzyć algorytm składający się z zadanego ciągu instrukcji. Czynności są wykonywane w określonej kolejności, więc w danym programie należy przewidzieć wszystkie możliwości na jakie program ma reagować. Konieczne jest dobranie optymalnej architektury sieci, której autorka poszukiwała a drodze interakcji. W działaniu sieci neuronowej można wyodrębnić kilka etapów. Pierwszym z nich jest etap nauki, kiedy to sieć gromadzi informacje potrzebne jej do określenia co i w jaki sposób ma robić. Drugim etapem jest normalne działanie, podczas którego, opierając się o wytrenowaną wiedzę, sieć rozwiązuje konkretne zadania. Sztuczne sieci neuronowe mogą być praktycznie wykorzystywane w niezwykle szerokim zakresie, w tym także w dziedzinie budownictwa. Ze względu na tematykę dysertacji skupiono się głównie na ocenie możliwości wykorzy-

stania sieci neuronowych do projektowania składów mieszanek betonowych zwykłych oraz modyfikowanych, a także możliwości predykcji wybranych cech kompozytu cementowego. Wykorzystanie SSN nabiera szczególnego znaczenia w przypadku betonów wysokowartościowych (o niskim stosunku wodno-spoiwowym), gdzie za pomocą tradycyjnych metod (np. metody trzech równań) nie da się stosunkowo dokładnie oszacować wytrzymałości betonu na ściskanie. Ze względu na powyższe, w rozdziale trzecim dysertacji przedstawiono szereg prac z literatury przedmiotu, w których sztuczne sieci neuronowe były z powodzeniem wykorzystywane do modelowania projektów mieszanek betonowych, predykcji i określania parametrów fizycznych betonu, w tym do przewidywania wytrzymałości betonu na ściskanie. Stan aktualny wiedzy uznano za niewystarczający, co przyczyniło się do sformułowania celu badawczego oraz tezy pracy (znajdujących się w rozdziale 4). Na tej podstawie zaplanowano i zrealizowano badania laboratoryjne betonów o niskim stosunku w/s. Wyniki badań przedstawiono w załączniku 1 dołączonym do pracy, a najważniejsze informacje przedstawiono w rozdziale 5. Na podstawie rozważań poczynionych w rozdziale 5 można było sformułować kolejny cel pracy, mianowicie opis właściwości betonu o niskim stosunku w/s w sytuacji, gdy stosunek w/s jest mniejszy od wodożądności normowej. Wymagałoby to wprowadzenia równań determinujących powyższy cel, jego udowodnienia i przeprowadzenia dodatkowych badań. Jest to spowodowane faktem, iż próbki uzyskane dla betonu przy udziale mikrokrzemionki 5% i 15% kruszyły się przy rozformowywaniu, widoczne także były konglomeraty cementu, które nie uległy hydratacji. Zastosowanie domieszki upłynniającej w ilości 3% okazało się niewystarczającym zabiegiem. Dlatego realizację wskazanego dodatkowego celu zawarto jako element do rozważań w ramach dalszych kierunków rozwoju. Uzyskana baza danych posłużyła do trenowania (nauki) sieci neuronowych oraz weryfikacji predykcji betonu zaprojektowanego przy użyciu tych sieci, co przedstawiono w rozdziale 6. Następnie w kolejnym rozdziale pracy wstępnie wdrożono efekty rozważań w zakresie predykcji, poprzez określenie składu ilościowego mieszanki betonowej (predykcja składu mieszanki). Wytworzone na tej podstawie próbki przebadano. Otrzymane wyniki poddano walidacji oraz ocenie efektywności metody (rozdział 7).

## **8.2. O osiągniętym celu pracy i udowodnionej tezie badawczej**

Celem pracy było opracowanie i wstępne wdrożenie efektywnej i dostatecznie dokładnej metody projektowania (predykcji) betonu o niskim stosunku wodno-spoiwowym. Osiągnięcie celu pracy polegało na realizacji zakresu pracy – w szczególności rozdziałów obejmujących badania laboratoryjne (rozdział 5), trenowanie sieci neuronowych (rozdział 6), wykonanie predykcji, walidacji i oceny wytrenowanych sieci neuronowych (rozdział 7). Do realizacji celu niezbędne było przygotowanie matrycy danych na podstawie badań laboratoryjnych. Badania własne przeprowadzono w szerokim zakresie (przedstawione w rozdziale 5). Następnie skonstruowany zestaw danych wykorzystano do rozwiązania postawionych zadań, przy użyciu sieci neuronowych (rozdział 6) – ze względu na to, że inne metody konwencjonalne okazały się niewystarczające. Sformułowano dwa zadania, a ich rozwiązanie wygląda w następujący sposób:

- Zadanie 1: istniejącą matrycę danych zaimplementowano do programu Statistica, w celu predykcji wytrzymałości betonu na ściskanie. Dane wejściowe po-

dzielono na te o charakterze ilościowym (stosunek w/s, masa: wody, cementu, domieszek, dodatków i kruszywa) oraz jakościowym (klasa cementu, rodzaj kruszywa). Daną wyjściową stanowiła wytrzymałość betonu na ściskanie, przy czym w procesie predykcji otrzymano stopień zgodności na poziomie 95,6% (obliczany zgodnie z równaniem 6.3).

- Zadanie 2: macierz danych opracowaną na podstawie rozdziału 5 przekształcono w celu uzyskania składu mieszanki betonowej w zakresie ilościowym, na podstawie podanych danych ilościowych oraz jakościowych. Dane wejściowe stanowiły wytrzymałość betonu na ściskanie oraz zmienne o charakterze jakościowym (np. klasa cementu, wodożądność, rodzaj kruszywa). Dane wyjściowe zdefiniowano jako zmienne o charakterze ilościowym (stosunek w/s, masa: wody, cementu, domieszek, dodatków i kruszywa). Stopień zgodności wyniósł 80%.

Następnie wygenerowany kod programu posłużył do predykcji – wdrożenia algorytmu do projektowania mieszanki betonowej (rozdział 7). Wdrożenia dokonano poprzez wykonanie próbek (badań laboratoryjnych) o składach otrzymanych z predykcji (algorytmów SSN). Skład mieszanki betonowej uzyskany z predykcji został zastosowany przy wykonywaniu próbek, które następnie zostały poddane badaniu niszcącemu. Na podstawie analizy wyników oceniono efektywność prezentowanej metody, która wyniosła dla predykcji wytrzymałości betonu na ściskanie 96% oraz dla predykcji składu ilościowego mieszanki 80%.

Osiągnięcie celu naukowego wynika z:

- opracowania metody predykcji parametrów betonu, tj. predykcji wytrzymałości betonu na ściskanie (w rozdziale 6), której dokładność po wstępnym wdrożeniu (w rozdziale 7) wynosi 95,6%;
- opracowania metody predykcji składu mieszanki betonowej (w rozdziale 6), której dokładność po wstępnym wdrożeniu (w rozdziale 7) wynosi 80%.

Wobec powyższego stwierdza się, że cel naukowy został osiągnięty.

Zakres pracy (przedstawiony w rozdziale 4) został zrealizowany, bowiem:

- Wykonano studia literaturowe dotyczące betonów o niskim stosunku wodno-spoiwowym oraz możliwości wykorzystania sieci neuronowych do predykcji cech takich betonów, co zawarto w rozdziałach 2 i 3 pracy.
- Zrealizowano badania laboratoryjne betonów o niskim stosunku w/s w celu uzyskania bazy danych do trenowania (nauki) sieci neuronowych. Wyniki badań zostały przedstawione w rozdziale 5 pracy oraz załączniku 1, a macierz danych w załączniku 2.
- Dokonano trenowania sieci neuronowych w zakresie predykcji wytrzymałości betonu na ściskanie oraz predykcji składu mieszanki betonowej, co zaprezentowano w rozdziale 6. Kody wygenerowanych programów zostały przedstawione w załączniku 4, a wagi neuronów dla poszczególnych sieci w rozdziale 3.
- Wykonano weryfikację predykcji dla betonu zaprojektowanego przy użyciu sieci neuronowych poprzez ocenę efektywności rozważanej w dysertacji metody. Na podstawie danych otrzymanych z predykcji sporządzono mieszanki betonowe niezbędne do wytworzenia betonu podlegającego niszczeniu. Na tej podstawie dokonano walidacji zaprojektowanych sieci neuronowych do predykcji wytrzymałości betonu na ściskanie oraz sporządzania receptur składu mieszanki betonowej. Całość przedstawiono w rozdziale 7.

- Sporządzono analizy i wnioski końcowe. Analizy i wnioski cząstkowe zostały przedstawione w rozdziałach 5,6 i 7.

Postawiona w dysertacji teza:

**„Istnieje możliwość bardziej efektywnego wykorzystania sztucznych sieci neuronowych do predykcji betonu o niskim stosunku wodno-spoiwowym”**

została udowodniona, ponieważ:

- utworzono matrycę danych (na podstawie badań własnych – w rozdziale 5) służących predykcji wytrzymałości betonu na ściskanie obejmującą 815 wyników;
- wytrenowano sieci neuronowe, które w efektywny sposób, tj. na poziomie 95,6% umożliwiają predykcję wytrzymałości betonu na ściskanie (rozdział 6);
- dokonano walidacji zaprojektowanych sieci, która obejmowała porównanie wartości pochodzących z predykcji z wartościami uzyskanymi na drodze badań laboratoryjnych (rozdział 7).

Istnieje zatem możliwość efektywnego wykorzystania sztucznych sieci neuronowych do predykcji wytrzymałości na ściskanie betonu o niskim stosunku wodno-spoiwowym. Możliwe jest również zaprojektowanie składu mieszanki betonowej na podstawie posiadanych danych jakościowych (tj. klasa cementu, wodożądność, rodzaj kruszywa) przy wykorzystaniu SSN. W efekcie działania algorytmu opartego na oryginalnie dobranej architekturze perceptronu wielowarstwowego sztucznych sieci neuronowych otrzymuje się beton o założonych parametrach. Takie podejście do projektowania mieszanki, a w konsekwencji otrzymania kompozytu cementowego o pożądanym cechach (w tym o oczekiwanej wytrzymałości na ściskanie, z którą skorelowane są także inne cechy kompozytu np. jakość), przyspiesza czas projektowania, minimalizuje koszty a jednocześnie stanowi rozwiązanie dokładne.

### **8.3. Ważne elementy stanowiące wynik przedmiotowej pracy**

Ważnymi elementami pracy są:

1. Przeprowadzenie licznych badań laboratoryjnych (przedstawionych w rozdziale 5) oraz sporządzenie na ich podstawie matryca danych (załączniki 1 i 2 do pracy).  
Wymieniona matryca danych stanowi oryginalny aspekt pracy, bowiem utworzono ją na podstawie kompleksowych badań betonów dla:
  - Dziewięciu różnych stosunków wodno-spoiwowych: 0,21; 0,24; 0,27; 0,30; 0,33; 0,36; 0,40; 0,45 i 0,50.
  - Cementów Lafarge klas wytrzymałości 32,5; 42,5 oraz 52,5:
    - CEM I 42,5 R (cement portlandzki o wysokiej wytrzymałości wczesnej);
    - CEM IV/B(V) 32,5 R-LH/NA (cement pucolanowy o wysokiej wytrzymałości wczesnej, niskim ciepłe hydratacji, niskoalkaliczny z dodatkiem popiołu lotnego krzemionkowego);
    - CEM II/A-M (S-LL) 52,5 N (cement portlandzki wieloskładnikowy normalnej wytrzymałości wczesnej z dodatkiem kamienia wapiennego oraz mielonego żużla wielkopieczowego).

- Domieszki upłynniającej „Nr 2” w ilościach 0,3%, 1% i 3% (domieszka chemiczna nowej generacji, która wytwarzana jest na bazie modyfikowanych polikarboksylanów; poprzez efekt steryczny oraz smarny powoduje redukcję ilości wody zarobowej i generuje dezagregację ziaren spoiwa, co umożliwia wykonywanie mieszanek betonowych o niskim stosunku wodno-spoiwowym) – CHRYSO Fluid Premia 380. Domieszkę uplastyczniającą „Nr 1” w ilości 0,5%–CHRYSO Plast 209 początkowo analizowano, lecz na dalszym etapie prac została wyeliminowana.
- Pyłu krzemionkowego w ilościach granicznych 5 i 15% masy cementu zastosowanego w celu zwiększenia szczelności betonu.
- Dwóch rodzajów kruszywa: otoczkowego i łamanego.

Badania te zostały zaplanowane i zrealizowane w laboratorium Wydziału Budownictwa, Architektury i Inżynierii Środowiska Politechniki Bydgoskiej.

2. Wygenerowanie algorytmów do trenowania sieci neuronowych (rozdział 6 oraz załącznik 4) wraz z wagami neuronów dla poszczególnych sieci (załącznik 3). Zastosowanie aparatu matematycznego w postaci sztucznych sieci neuronowych, do rozwiązywania problemów technologii betonu, nie jest podejściem nowatorskim – co potwierdzono podczas studiów literaturowych w rozdziale trzecim. Jednakże w niniejszej pracy do rozwiązania zadań (pierwszego i drugiego, które zostały postawione w rozdziale 6):
  - dobrano optymalną architekturę sieci (na podstawie literatury przedmiotu);
  - zaimplementowano wytworzoną w drodze badań własnych macierz danych;
  - w efekcie końcowym wygenerowano kody programów.

Zatem opracowana, szeroka baza danych, oparta na znanej metodzie (sztucznych sieci neuronowych) została wykorzystana do rozwiązania szczególnego i ważnego problemu technologii betonu, polegającego na określeniu związku pomiędzy składem mieszanki betonowej, a wybranymi właściwościami betonu w obrębie utworzonej macierzy danych. Ważność wynika zatem z tego, iż przedstawione algorytmy zostały utworzone dla indywidualnego problemu i macierzy danych.

3. Dokonanie walidacji opracowanych algorytmów uzyskanych na drodze trenowania sieci (rozdział 7).

Prezentowana w rozdziale 7 metoda stanowić może przydatne narzędzie dla technologów, tj. cechuje ją daleko idący aspekt praktyczny, mianowicie może być wprost wykorzystana do projektowania składu mieszanki oraz gotowa jest do adaptacji w przemyśle. Metody doświadczalne są kosztowne, czasochłonne, a ta prezentowana w pracy daje szansę dalszego rozwoju przy jednoczesnej redukcji mankamentów metod tradycyjnych oraz większej ekologiczności. Dokonano wstępnego wdrożenia algorytmów przedstawionych w rozdziale 6, co stanowi oryginalny aspekt pracy.

## 8.4. Kierunki dalszych badań

Autorka wyraża opinię, iż istnieje możliwość rozwinięcia tematyki zawartej w niniejszej dysertacji, która będzie prowadzić do zwiększenia efektywności predykcji wytrzymałości betonu na ściskanie (zadanie 1) oraz predykcji składu ilościowego mieszanki betonowej (zadanie 2) – na podstawie której uzyskuje się kompozyt o założonej wytrzymałości. Do działań modyfikujących i optymalizujących mogłyby należeć:

- Postawienie i realizacja kolejnego celu, tj. opisu np. analitycznego właściwości betonu o niskim stosunku w/s w sytuacji, gdy stosunek w/s jest mniejszy od wodożądności normowej.
- Poszerzenie matrycy danych o szerszą liczbę próbek w obrębie jednego stosunku wodno-spoiwowego. Do rozwiązania problemu posłużono się minimalną liczbą próbek, tj. po trzy próbki dla kolejnych dziewięciu stosunków wodno-spoiwowych. Poszerzenie zakresu danych rzutować będzie na wzrost stopnia zgodności wartości otrzymanych z predykcji wyników, w odniesieniu do tych otrzymanych na drodze badań laboratoryjnych. Taki zbiór danych może zatem przyczynić się do lepszej prognozy wytrzymałości betonu na ściskanie, bowiem będzie posiadał zdolność do większej generalizacji.
- Modyfikacja rozważanych danych – prezentowana w pracy matryca może zostać zwiększona o inne grupy cementów oraz zakresy stosowanych ilości domieszek i dodatków, co przyczyni się do poszerzenia obszaru stosowania metody – implementacji SSN do projektowania składu mieszanki betonowej. Ponadto ewentualne rozszerzenie może zostać ekstrapolowane na inną grupę betonów takie jak betony lekkie, zawierające zbrojenie rozproszone, betony z dodatkiem kruszywa recyklingowego.
- Wprowadzenie do matrycy większej ilości danych wejściowych takich jak: konsystencja, zawartość powietrza w świeżej mieszance, mrozoodporność, nasiąkliwość, moduł sprężystości, ścieralność, szacowany projektowy okres użytkowania i inne. Przyczyni się do ściślejszego rozwiązania i uzależniania wytrzymałości na ściskanie betonu od jego pozostałych cech, a nie tylko składu ilościowego i jakościowego.
- Modyfikacja składu dla betonów o ekstremalnie niskim stosunku wodno-spoiwowym, przy zastosowaniu dodatku mikrokrzemionki w ilości 5% i 15% masy cementu. Badania przedstawione w rozdziale 5 oraz załączniku 1 obrazują, iż wytrzymałości betonu na ściskanie uzyskane dla stosunków wodno-spoiwowych 0,21 oraz 0,27 są niezwykle niskie. Uzyskane próbki betonu kruszyły się przy rozformowywaniu, widoczne także były konglomeraty cementu, które nie uległy hydratacji. Zastosowanie domieszki upłynniającej w ilości 3% okazało się niewystarczającym zabiegiem, a zatem wskazane byłoby wykonanie dalszych badań prowadzących do uzyskania matrycy cementowej o lepszych parametrach.
- Wprowadzenie zmian architektury sieci, w tym wektorów uczących oraz kalibracja modelu fenomenologicznego (abstrakcyjnego).
- Implementacja bardziej zaawansowanych metod obliczeniowych, takich jak obliczenia ewolucyjne, systemy neuronowo-rozmyte, systemy eksperckie, hybrydy obliczeniowe, np. oparte o algorytmy genetyczne lub ewolucyjne. Konieczne jest w tym przypadku wdrożenie specjalistycznej wiedzy, głównie z zakresu biocybernetyki oraz logiki rozmytej.



Zakres powyżej wskazanych zaleceń nie wyczerpuje tematu. Podane możliwości mogą pozytywnie wpłynąć na rozwiązanie prezentowanego w dysertacji zagadnienia. Autorka w szczególności chciałaby się skupić na opisie analitycznym właściwości betonu o niskim stosunku w/s w sytuacji, gdy stosunek w/s jest mniejszy od wodożądności normowej. Może odbywać się to na drodze generacji równania na podstawie przedstawionych (w załączniku 4) kodów SSN. Ponadto jako równoległy kierunek badań autorka chciałaby podjąć próbę implementacji logiki rozmytej do dalszego rozwoju prezentowanego w dysertacji celu badawczego.

## LITERATURA

1. Czarnecki, L.; Kurdowski, W. Tendencje Kształtujące Przyszłość Betonu. *Budownictwo, Technologie, Architektura* **2007**, *1*, 50–55.
2. Piestrzyński, P. Dni Betonu 2018. *Nowoczesne Budownictwo Inżynieryjne* **2019**, 20–22.
3. Śliwiński, J. Zasady Projektowania Składu Betonów Wysokowartościowych. *Cement, Wapno, Beton* **2003**, *6/2003*, 317–325.
4. Aïtcin, P.C. The Problems with High Strength and Low w/c Ratio Concretes. *Cement Wapno Beton* **2014**, *2*, 127–137.
5. Ajdiukiewicz, A. Rozwój Badań i Zastosowań Betonów Wysokowartościowych. In Proceedings of the Konferencja „Beton na progu nowego milenium”; Polski Cement: Kraków, **2000**; pp. 414–432.
6. Bentz, D.P.; Contway, J.T. Computer Modeling of the Replacement of “Coarse” Cement Particles by Inert Fillers in Low w/c Ratio Concretes. *Cem Concr Res* **2001**, 503–506.
7. Błaszczński, T. *Międzynarodowe Targi Poznańskie “Budma.”* Poznań **2012**, pp. 1–41.
8. Słowik, W. *Materiały budowlane*. Warszawa **2015**, pp. 49–51.
9. Gołaszewski, J. Betony Nowej Generacji. *Inżynier Budownictwa* **2014**, *3*, 58–60.
10. Czarnecki L.; Justnes, H. Zrównoważony, Trwały Beton. *Cement Wapno Beton* **2012**, *79*, 341–362.
11. Jasiczak, J.; Wdowska, A.; Rudnicki, T. *Betony Ultrawysokowartościowe. Właściwości, Technologie, Zastosowania*; Stowarzyszenie Producentów Cementu: Kraków, **2008**;
12. Kurdowski, W.; Szelaąg, H.; Bochenek, A. Czynniki Wpływające Na Odporność Betonu Na Działanie Mrozu.; XXVI Konferencja Awaryjności Budowlanej: Szczecin, **2013**.
13. Kaszyńska, M. BWW: Możliwości, Cechy, Zastosowania.; XVII Ogólnopolska Konferencja „Warsztat Pracy Projektanta Konstrukcji”: Ustroń, **2002**.
14. Aïtcin, P.C. Trwały Wysokowartościowy Beton – Sztuka i Wiedza. In Proceedings of the Konferencja Dni Betonu – Tradycja i nowoczesność; Szczyrk, **2002**; pp. 7–36.
15. Liew, J.Y.R.; Xiong, D.X. Ultra-High Strength Concrete Filled Composite Columns for Multi-Storey Building Construction. *Advances in Structural Engineering* **2012**, *15*, 1487–1503, doi:10.1260/1369-4332.15.9.1487.
16. Jasiczak, J.; Mikołajczak, P. *Technologia Betonu Modyfikowanego Domieszkami i Dodatkami*; Politechnika Poznańska: Poznań, **2003**;
17. Aïtcin, P.C. Trwały Wysokowartościowy Beton – Sztuka i Wiedza. Konferencja Beton Na Progu Nowego Milenium. In Proceedings of the Konferencja Beton na progu nowego milenium; Wydawnictwo Polski Cement: Kraków, **2000**; pp. 383–413.

18. Pradhan, D.; Dutta, D. Effects of Silica Fume in Conventional Concrete. **2013**, 3, 1307–1310.
19. Deja, J.; Kijowski, P. *ABC Betonu*; Stowarzyszenie Producentów Cementu: Kraków, **2002**;
20. Erdem, T.K.; Tayfur, G.; Kirca, O. Doświadczalne Badania i Modelowanie Wytrzymałości BWW, Wytwarzanego z Dwuskładnikowych i Trójskładnikowych Spoiw. *Cement Wapno Beton* **2011**, 224–237.
21. Jamroży, Z. *Beton i Jego Technologie*; PWN: Warszawa, **2015**;
22. Nocuń-Wczelik, W. *Pył Krzemionkowy - Właściwości i Zastosowanie w Betonie*; Wydawnictwo Polski Cement: Kraków, **2005**;
23. Raczkiewicz, W. Beton – Materiał Budowlany Znany Od Wieków. *Konstrukcje - Elementy - Materiały* **2012**, 10, 13–18.
24. de Abreu, G.B.; Costa, S.M.M.; Gumieri, A.G.; Calixto, J.M.F.; França, F.C.; Silva, C.; Quinões, A.D. Mechanical Properties and Microstructure of High Performance Concrete Containing Stabilized Nano-Silica. *Revista Materia* **2017**, 22, doi:10.1590/S1517-707620170002.0156.
25. Czarnecki, L. Domieszki Do Betonu. *Budownictwo, Technologie, Architektura, Zeszyt specjalny: Domieszki do betonu* **2003**, 4–6.
26. Łażniewska, B. *Materiały Budowlane*. **2012**,.
27. Gołaszewski, J. *Kształtowanie Urabialności Mieszanki Betonowej Superplastyfikatorami*; Wydawnictwo Politechniki Śląskiej: Gliwice, **2003**;
28. Giergiczny, Z. *Cement, Kruszywa, Beton - Rodzaje, Właściwości, Zastosowanie. Beton Wg Normy PN-EN 206*; Wydawnictwo Grupa Górażdże: Chorula, **2016**;
29. Świtoński, A. *Struktura i Wytrzymałość Betonów Wysokowartościowych*; Wydawnictwa Uczelniane Politechniki Koszalińskiej: Koszalin, **2018**;
30. Czaja, P.; Hydzik-Wisniewska, J.; Wałach, D. Ekonomiczne Aspekty Stosowania Betonu Wysokowartościowego w Budownictwie Podziemnym. *Górnictwo i Geoinżynieria* **2009**, 33, 121–130.
31. Hilal, A.A. Microstructure of Concrete. In *High Performance Concrete Technology and Applications*; InTech, **2016**.
32. Neville, A.M. *Właściwości Betonu*; Stowarzyszenie Producentów Cementu: Kraków, **2012**;
33. Tracz, T.; Śliwiński, J. Wpływ Zawartości Zaczynu Cementowego i Wskaźnika w/c Na Nasiąkliwość Betonu Wodą. *Cement Wapno Beton* **2012**, 79, 131–137.
34. Sekhar, N.S.; Raghunath, P.N. Influence of Water Binder Ratio on High Performance Concrete. *The Open Construction and Building Technology Journal* **2014**, 8, 18–21, doi:10.2174/1874836801408010018.
35. Zhou, J.K.; Ge, L.M. Effect of Strain Rate and Water-to-Cement Ratio on Compressive Mechanical Behavior of Cement Mortar. *J Cent South Univ* **2015**, 22, 1087–1095, doi:10.1007/s11771-015-2620-9.
36. Koliass, S.; Georgiou, C. The Effect of Paste Volume and Water Content on the Strength and Water Absorption of Concrete. *Cem Concr Compos* **2005**, 27, 211–216.

37. Piasta, W.; Zarzycki, B. The Effect of Cement Paste Volume and w/c Ratio on Shrinkage Strain, Water Absorption and Compressive Strength of High Performance Concrete. *Constr Build Mater* **2017**, *140*, 395–402, doi:10.1016/j.conbuildmat.2017.02.033.
38. Czarnecki, L.; Łukowski, P. Betony i Zaprawy Samonaprawialne – Krok Ku Inteligentnym Materiałom Naprawczym. *Materiały budowlane* 2008, **2008**.
39. Stryczek, S.; Wiśniowski, R.; Kumala, B. Wpływ Superplastyfikatora Na Parametry Technologiczne Zaczynów Uszczelniających Sporządzonych Na Osnowie Cementów Portlandzko- Popiołowych. *Wiertnictwo Nafta Gaz* **2008**, *25*, 717–731.
40. Appa Rao, G. Role of Water–Binder Ratio on the Strength Development in Mortars Incorporated with Silica Fume. *Cem Concr Res* **2001**, *31*, 443–447.
41. Nocuń-Wczelik, W. Pył Krzemionkowy – Podstawy Stosowania w Technologii Betonu. *Materiały cermaiczne* **2007**, 68–71.
42. Kalaiarasu, M.; Subramanian, K. Strength and Durability of High Performance Concrete Using Artificial Sand. *Journal on Future Engineering and Technology* **2018**, *1*, 88–92, doi:10.26634/jfet.1.3.985.
43. Choudhary, S.; Bajaj, R.; Sharma, R.K. Study Of High Performance Concrete. *Journal of Civil Engineering and Environmental Technology* **2014**, *1*, 109–113, doi:10.1177/0969733011408048.
44. Aïtcin, P.C. *High-Performance Concrete*; E&FN Spon: London, **1998**;
45. Ajdiukiewicz, A. Współczesne Kierunki Badań i Zastosowań Betonów Wysokowartościowych. *Inżynieria i Budownictwo* **2001**, *2*, 67–74.
46. Alsalman, A.; Dang, C.N.; Micah Hale, W. Development of Ultra-High Performance Concrete with Locally Available Materials. *Constr Build Mater* **2017**, *133*, 135–145, doi:10.1016/j.conbuildmat.2016.12.040.
47. Abbas, S.; Nehdi, M.L.; Saleem, M.A. Ultra-High Performance Concrete: Mechanical Performance, Durability, Sustainability and Implementation Challenges. *Int J Concr Struct Mater* **2016**, *10*, 271–295, doi:10.1007/s40069-016-0157-4.
48. Górażdże, G. *Beton Wysokowartościowy (Wysokiej Wytrzymałości)*; Wydawnictwo Grupa Górażdże: Chorula, **2018**;
49. Holland, T.C.; Krysa, A.; Luther, M.D.; Liu, T.C. Use of Silica-Fume Concrete to Repair Abrasion-Erosion Damage in the Kinzua Dam Stilling Basin. *International Concrete Abstracts Portal* **1968**, *65*, 811–882, doi:10.14359/11681.
50. Li, B.; Ke, G.; Zhou, M. Influence of Manufactured Sand Characteristics on Strength and Abrasion Resistance of Pavement Cement Concrete. *Constr Build Mater* **2011**, *25*, 3849–3853, doi:10.1016/j.conbuildmat.2011.04.004.
51. Horszczaruk, E. Odporność Na Ścieranie Betonów Wysokowartościowych Narażonych Na Działanie Erozji Abrazyjnej. *Inżynieria i Budownictwo* **2003**, 278–280.
52. Leenders, H.; Tokarski, Z.; Pietrzak, K.; Kujawski, E. *Magazyn Autostrady*. **2018**, pp. 58–59.

53. Tokarski, Z. Organizacja Budowy Asfaltowych Nawierzchni Drogowych **2012**.
54. Mrozik, Ł.; Grzybowska, A.; Woleń, M. Przyczyny Zmniejszenia Trwałości Elementów Nawierzchni z Betonu Wibroprasowanego. In *Organizacja Przedsięwzięć Budownictwa Drogowego*; Rekol: Bydgoszcz, **2015**; pp. 10–17 ISBN 9781450349185.
55. Malier, Y. *High Performance Concrete*; E&FN Spon: London, **1992**;
56. Błaszczyński, T.; Gwiazdowski, B. Nanocementy i Nanobetony. *Izolacje* **2013**, *10*, 12–18.
57. Denisiewicz, A. Betony z Proszków Reaktywnych i Ich Zastosowanie w Konstrukcjach Zespolonych. *Przegląd budowlany* **2014**, *11*, 18–23.
58. Azmee, N.M.; Shafiq, N. Ultra-High Performance Concrete: From Fundamental to Applications. *Case Studies in Construction Materials* **2018**, *9*, doi:10.1016/j.cscm.2018.e00197.
59. Józwiak, H. Wykonywanie Betonu w Warunkach Obniżonych Temperatur z Zastosowaniem Domieszek Chemicznych. *Prace Instytutu Techniki Budowlanej* **1998**, *1*, 16–26.
60. Kurdowski, W.; Bochenek, A. Trzy Zasady Zapobiegania Korozji Betonu. *Cement Wapno Beton* **2012**, *79*, 434–442.
61. Shahverdi, M.; Czaderski, C.; Annen, P.; Motavalli, M. Strengthening of RC Beams by Iron-Based Shape Memory Alloy Bars Embedded in a Shotcrete Layer. *Eng Struct* **2016**, *117*, 263–273, doi:10.1016/j.engstruct.2016.03.023.
62. De la Fuente, A.; Blanco, A.; Armengou, J.; Aguado, A. Sustainability Based-Approach to Determine the Concrete Type and Reinforcement Configuration of TBM Tunnels Linings. Case Study: Extension Line to Barcelona Airport T1. *Tunnelling and Underground Space Technology* **2017**, *61*, 179–188, doi:10.1016/j.tust.2016.10.008.
63. Jiang, D.; Tan, K.H.; Wang, C.M.; Ong, K.C.G.; Bra, H.; Jin, J.; Kim, M.O. Analysis and Design of Floating Prestressed Concrete Structures in Shallow Waters. *Marine Structures* **2018**, *59*, 301–320, doi:10.1016/j.marstruc.2018.01.006.
64. Sobczak- Piąstka, J.; Podhorecki, A. Niektóre Aspekty Projektowania Betonu Wysokowytrzymałego o Niskim Skurczu Zobacz No. *Materiały budowlane* **2014**, *7*, 36–38.
65. Piasta, J.; Piasta, W. *Beton Zwykły*; Arkady: Warszawa, **1997**;
66. Zajac, B.; Gołębiowska, I. Samoleczenie Betonu. Cz. 1. Metody Naturalne i Chemiczne. *Inżynieria i Aparatura Chemiczna* **2016**, *4*, 160–161.
67. Pedro, D.; de Brito, J.; Evangelista, L. Durability Performance of High-Performance Concrete Made with Recycled Aggregates, Fly Ash and Densified Silica Fume. *Cem Concr Compos* **2018**, *93*, 63–74, doi:10.1016/j.cemconcomp.2018.07.002.
68. Dobiszewska, M.; Schindler, A.K.; Pichór, W. Mechanical Properties and Interfacial Transition Zone Microstructure of Concrete with Waste Basalt Powder Addition. *Constr Build Mater* **2018**, *177*, 222–229.
69. Góra, J. Właściwości Wytrzymałościowe Betonów Wysokowartościowych z Kruszywem Węglanowym. *Budownictwo i Architektura* **2011**, *9*, 69–76.

70. Piasta, W.; Budzyński, W.; Góra, J. Wpływ Rodzaju Kruszywa Grube- go Na Odkształcalność Betonów Zwykłych. **2012**, 35–38.
71. Rucińska, T.; Gul, M. Ocena Wpływu Domieszek i Dodatków Na Wła- ściwości Matrycy Cementowej. **2017**, 50–55.
72. Łukowski, P. *Domieszki Do Zapraw i Betonów*; Stowarzyszenie Produ- centów Cementu: Kraków, **2008**;
73. Stryczek, S. Wpływ Superplastyfikatorów Na Właściwości Reologiczne Zaczynów Cementowych. *Nowoczesne Budownictwo Inżynieryjne* **2011**, 6, 60–63.
74. Kurdowski, W. *Chemia Cementu i Betonu*; Wydawnictwo Polski Ce- ment: Kraków, **2010**;
75. Hydzik, J.; Czaja, P. Archives; Wydawnictwo Instytutu Mechaniki Gó- rotworu PAN: Kraków, **2010**;
76. Kotwica, Ł. Podwójna Warstwa Elektryczna i Jej Znaczenie w Chemii Tworzyw Cementowych. *Materiały ceramiczne* **2019**, 57, 97–94.
77. Mroziak, Ł. *Model Struktury i Wytrzymałość Betonu Wysokowartościo-wego*; Uniwersytet Technologiczno - Przyrodniczy w Bydgoszczy: Bydgoszcz, **2012**;
78. Chen, L.; Li, P.; Liu, G.; Cheng, W.; Liu, Z. Development of Cement Dust Suppression Technology during Shotcrete in Mine of China-A Re- view. *J Loss Prev Process Ind* **2018**, 55, 232–242, doi:10.1016/j.jlp.2018.07.001.
79. Szwabowski, J. Znaczenie Parametrów Struktury Porowatości Samoza- gęszczalnego Betonu, Odpornego Na Mróz. **2008**, 155–165.
80. Flaga, K.; Mierzwa, J. Betony o Dużej Trwałości i Wysokiej Wytrzy- małości (HSC) Jako Realizacja Nowej Materiałowo-Technologicznej Koncepcji Kompozytu Konstruktacyjnego. *Przegląd budowlany* **1992**, 9, 1992.
81. Powers, T.C. The Mechanism of Frost Action in Concrete. *cement Lime and Gravel* **1966**, 41, 143–148.
82. Śliwiński, J. *Beton Zwykły. Projektowanie i Podstawowe Właściwości*; Wydawnictwo Polski Cement: Kraków, **1999**;
83. Franczyk, M.; Prokopski, G. Optymalizacja Składu Betonów Wysoko- wartościowych. *Przegląd budowlany* **2008**, 2, 26–30.
84. Jackiewicz-Rek, W. Konieczna, K.; Zychowicz, J. Inżynieria i Budow- nictwo O Projektowaniu Betonów Wysokich Wytrzymałości Na Kon- strukcje Nośne Budynków Wysokościowych. *Inżynieria i Budownictwo* **2017**, 73, 416–420.
85. Śliwiński, J. Podstawowe Właściwości Betonu i Jego Trwałość. *Ce- ment, Wapno, Beton* **2009**, 29, 245–254.
86. Franczyk, M. Betony Wysokowartościowe- Projektowanie Jakościowe i Ilościowe. *Izolacje* **2011**, 16, 50–53.
87. Gopinath, S.; Murthy, A.; Ramya, D.; Iyer, N. Optimised Mix Design for Normal Strength and High Performance Concrete Using Particle Packing Method. *Archives of Civil Engineering* **2011**, 57, 357–371, doi:10.2478/v.10169-011-0026-0.
88. Świtoński, A.; Mroziak, Ł.; Piekarski, P. Kształtowanie Struktury i Wła- ściwości Betonu Wysokowartościowego. In *Budownictwo Ogólne. Za-*

- gadnienia konstrukcyjne, materiałowe i ciepno-wilgotnościowe w budownictwie*; Wydawnictwa Uczelniane UTP: Bydgoszcz, **2015**; pp. 63–66.
89. Zubelewicz, A. Propozycja Nowego Modelu Strukturalnego Betonu. *Archiwum Inżynierii Lądowej* **1983**, 29.
  90. Majewski, S. *Mechanika Betonu Konstrukcyjnego w Ujęciu Sprężysto-Plastycznym*; Wydawnictwo Politechniki Śląskiej: Gliwice, **2003**;
  91. Fennis, S.A.A.M.; Walraven, J.C. Using Particle Packing Technology for Sustainable Concrete Mixture Design. *Heron* **2012**, 57, 73–101.
  92. Fennis, S.A.A.M.; Walraven, J.C.; Den Uijl, J.A. *The Use of Particle Packing Models to Design Ecological Concrete*; **2009**; Vol. 54;.
  93. Wong, V.; Wai Chan, K.; Kwok Hung Kwan, A. Applying Theories of Particle Packing and Rheology to Concrete for Sustainable Development. *Organization, Technology & Management in Construction: An International Journal* **2013**, 5, 844–851, doi:10.5592/otmcj.2013.2.3.
  94. Marks, M. Wykorzystanie Metod Ucznia Maszynowego Do Rozpoznawania Związków Pomiedzy Składem Betonu Modyfikowanego Dodatkami Popiołowymi a Jego Właściwościami. **2010**, 39–54.
  95. Stawiarski, P. Projektowanie Mieszanek Betonów Wysokowartościowych z Zastosowaniem Sztucznych Sieci Neuronowych. *Cement Wapno Beton* **2001**, 65–67.
  96. Stawiarski, P. Zastosowanie Sztucznej Inteligencji Do Projektowania Składów Mieszanek Betonów Zwykłych i Modyfikowanych. *Przegląd budowlany* **2008**, 39–42.
  97. Ziolkowski, P.; Niedostatkiewicz, M. Machine Learning Techniques in Concrete Mix Design. *Materials* **2019**, 12, 1256, doi:10.3390/ma12081256.
  98. Rutkowska, D. Sieci Rozmyto-Neuronowe Do Klasyfikacji : Architektury Typu RBF i MLP – System NEFCLASS. *Automatyka* **2005**, 9, 689–699.
  99. Jakubowski, M.A. Porównanie Systemów Rozmytych i Sztucznych Sieci Neuronowych. *Postępy Nauki i Techniki* **2010**, 54–64.
  100. Pawlak, M. Rozmyte Sieci Neuronowe Jako Modele Diagnostyczne w Układzie Regulacji Turbiny Kondensacyjnej. *Problemy Eksploatacji* **2006**, 3, 39–50.
  101. Krawiec, K.; Stefanowski, J. *Uczenie Maszynowe i Sieci Neuronowe*; Wydawnictwo Politechniki Poznańskiej: Poznań, **2003**; Vol. 3;.
  102. Duch, W. ;Korbicz, J.; R.L.T.R. *Sieci Nuronowe*; Akademicka Oficyna Wydawnicza EXIT: Warszawa, **2000**;
  103. Tadeusiewicz, R. Sieci Neuronowe. *Postępy Fizyki* **1994**, 45, 215–236.
  104. Tadeusiewicz, R.; Szaleniec, M. *Leksykon Sieci Neuronowych*; Wrocław, **2015**; ISBN 9788363270100.
  105. Tadeusiewicz, R. *Wprowadzenie Do Sieci Neuronowych*; StatSoft Polska: Kraków, **2001**;
  106. McCulloch, W.S.P.W. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematica Biophysics* **1943**, 5, 115–133.

107. Neumann, J. *The Computer and the Brain*; Yale University Press: New Haven, **1958**;
108. Taylor, W.K. *Computers and the Nervous System. Models and Analogues in Biology*; Cambridge University Press: Cambridge, **1960**;
109. Rosenblatt, F. *The Perceptron. A Theory of Statistical Separability in Cognitive System*; Cornell Aeronautical: New York, **1968**;
110. Widrow, B. The Original Adaptive Neural Net Broom-Balancer. In Proceedings of the Proceedings of 1987 IEEE Int. Symp. on Circuits and Systems; PA: Philadelphia, May **1987**; pp. 351–357.
111. Widrow, B. *Adaptive Switching Circuits*; IRE WESCON Convention Record: New York, **1960**;
112. Minsky, M.; Papert, S. *Perceptrons*; MIT Press: Cambridge, **1969**;
113. Anderson, J.A.; Rosenfeld, E. *Neurocomputing – Foundation of Research*; MIT Press: Cambridge, **1988**;
114. McClelland, T.L.; Rumelhart D.E. *Paralell Distributed Processing*; MIT Press: Cambridge, **1986**;
115. Hoła, J.; Bień, J.; Sadowski, Ł.; Schabowicz, K. Non-Destructive and Semi-Destructive Diagnostics of Concrete Structures in Assessment of Their Durability. *Bulletin of the Polish Academy of Sciences Technical Sciences* **2015**, *63*, 87–96, doi:10.1515/bpasts-2015-0010.
116. Hoła, J.; Schabowicz, K. State-of-the-Art Non-Destructive Methods for Diagnostic Testing of Building Structures – Anticipated Development Trends. *Archives of Civil and Mechanical Engineering* **2010**, *10*, 5–18, doi:10.1016/S1644-9665(12)60133-2.
117. PN-76/B-03264 Konstrukcje Betonowe, Żelbetowe i Sprężone. Obliczenia Statyczne i Projektowanie,.
118. Paprocki, B. *Analiza Wydajności Transmisji Danych w Komórkach i Sieciach Neuronowych Metodami Teorii Informacji*; Instytut Podstawowych Problemów Techniki Polskiej Akademii Nauk: Warszawa, **2015**;
119. Osowski, S. Sztuczne Sieci Neuronowe - Podstawowe Struktury Sieciowe i Algorytmy Uczące. *Przegląd Elektrotechniczny* **2009**, *85*, 1–8.
120. Tadeusiewicz, R. O Celowości Zastosowania Sieci Neuronowych w Problemach Związanych z Elektrotechniką. *Przegląd Elektrotechniczny* **2009**, *85*, 200–211.
121. Leśniak, A. Wspomaganie Decyzji Wykonawcy Budowlanego Z Zastosowaniem Sztucznej Inteligencji. *Journal of Civil Engineering, Environment and Architecture* **2017**, *63*, 189–196, doi:10.7862/rb.2016.22.
122. Korbicz, J. Sztuczne Sieci Neuronowe i Ich Zastosowanie w Elektrotechnice i Energetyce. *Przegląd Elektrotechniczny* **2009**, *85*, 194–200.
123. Lewandowski, S. Sztuczne Sieci Neuronowe i Kierunki Ich Zastosowań w Przemysle. Kierunki Zastosowań Sztucznych Sieci Neuronowych We Włókiennictwie Wykorzystywane Przy Klasyfikacji Błędów w Płaskich Wyrobach Włókienniczych i Użytkowaniu Odzieży. *Przegląd Włókienniczy - Włókno, Odzież, Skóra* **2016**, *1*, 34–39, doi:10.15199/60.2016.10.4.



124. Stanek, M. Zastosowanie Sieci Neuronowych Typu Hopfielda W Diagnostyce Nawierzchni Drogowych. *Journal of Civil Engineering, Environment and Architecture* **2017**, *63*, 323–330, doi:10.7862/rb.2016.91.
125. Drobina, R.; Grecka, A.; Lewandowski, S. Sztuczne Sieci Neuronowe i Kierunki Ich Zastosowań w Przemysle. Inspiracje Biologiczne Sztucznych Sieci Neuronowych, Ich Historia Oraz Matematyczny Model Neuronu Do Zastosowań Inżynierskich. *Przegląd Włókienniczy - Włókno, Odzież, Skóra* **2016**, *1*, 21–25, doi:10.15199/60.2016.05.1.
126. Drobina, R.; Grecka, A.; Lewandowski, S. Sztuczne Sieci Neuronowe i Kierunki Ich Zastosowań w Przemysle. Podstawowe Rodzaje Sztucznych Sieci Neuronowych. *Przegląd Włókienniczy - Włókno, Odzież, Skóra* **2016**, *1*, 28–33, doi:10.15199/60.2016.07.3.
127. Zeinali, Y.; Story, B.A. Competitive Probabilistic Neural Network. *Integr Comput Aided Eng* **2017**, *24*, 105–118, doi:10.3233/ICA-170540.
128. Maria, M. *Studium Nad Doborem Metod Inteligencji Numerycznej Do Rozwiązywania Problemów z Geodezji Inżynierskiej*; **2013**;
129. Szarata, M.; Nazarko, P. Analiza Możliwości Zastosowania Sztucznych Sieci Neuronowych Do Kalibracji Modeli Mikrosymulacyjnych. *Journal of Civil Engineering, Environment and Architecture* **2018**, *64*, 25–36, doi:10.7862/rb.2017.78.
130. Adamczak, R. Zastosowanie Sieci Neuronowych Do Klasyfikacji Danych Doświadczalnych. Praca Doktorska Pod Kierunkiem Prof. Włodzisława Duchy Katedra Metod Komputerowych Uniwersytet Mikołaja Kopernika. **2001**, 1–123.
131. Witkowski, M.; Rusek, J. Wykorzystanie Probabilistycznych Sieci Neuronowych Do Wyznaczania Ryzyka Powstania Szkód w Budynkach Poddanych Wstrząsom Górniczym. *Przegląd Górniczy* **2017**, *73*, 44–47.
132. Kobielski, Andrzej; Drapik, Sławomir; Dudzik, Marek; Prusak, J. Wstępne Studium Efektywności Zastosowania Sieci Neuronowych w Badaniach Obciążeń Kolejowych Podstacji Trakcyjnych. *TTS Technika Transportu Szynowego* **2014**, 40–43.
133. Grzybowska, A. Wybrane Problemy Projektowania Betonów o Niskim Stosunku Wodno- Spoiwowym. In *Nauka niejedno ma imię...*; Uniwersytet Technologiczno - Przyrodniczy w Bydgoszczy: Bydgoszcz, **2015**.
134. Kasperkiewicz, J.; Racz, J.; Dubrawski, A. HPC Strength Prediction Using Artificial Neural Network. *Journal of Computing in Civil Engineering* **1995**, *9*, 279–284, doi:10.1061/(ASCE)0887-3801(1995)9:4(279).
135. Kasperkiewicz, J. *Drogi i Mosty*. **2004**, pp. 15–36.
136. Thomassen, H.M. Robert Courland: Concrete Planet. The Strange and Fascinating Story of the World's Most Common Man-Made Material. *Hum Ecol* **2013**, *41*, 333–334, doi:10.1007/s10745-013-9576-x.
137. Bonoli, A.; Zanni, S.; Serrano-Bernardo, F. Sustainability in Building and Construction within the Framework of Circular Cities and European New Green Deal. The Contribution of Concrete Recycling. *Sustainability* **2021**, *13*, 2139, doi:10.3390/su13042139.
138. Bui, D.K.; Nguyen, T.; Chou, J.S.; Nguyen-Xuan, H.; Ngo, T.D. A Modified Firefly Algorithm-Artificial Neural Network Expert System for Predicting Compressive and Tensile Strength of High-Performance

- Concrete. *Constr Build Mater* **2018**, doi:10.1016/j.conbuildmat.2018.05.201.
139. DeRousseau, M.A.; Kasprzyk, J.R.; Srubar, W. v. Computational Design Optimization of Concrete Mixtures: A Review. *Cem Concr Res* **2018**.
  140. DeRousseau, M.A.; Kasprzyk, J.R.; Srubar, W. v. Computational Design Optimization of Concrete Mixtures: A Review. *Cem Concr Res* **2018**, *109*, 42–53.
  141. Ahmad, S.; Alghamdi, S.A. A Statistical Approach to Optimizing Concrete Mixture Design. *The Scientific World Journal* **2014**, *2014*, 1–7, doi:10.1155/2014/561539.
  142. Ji, T.; Yang, Y.; Fu, M.Y.; Chen, B.C.; Wu, H.C. Optimum Design of Reactive Powder Concrete Mixture Proportion Based on Artificial Neural and Harmony Search Algorithm. *ACI Mater J* **2017**, *114*, 41–47, doi:10.14359/51689476.
  143. Yeh, I.C. Computer-Aided Design for Optimum Concrete Mixtures. *Cem Concr Compos* **2007**, *29*, 193–202, doi:10.1016/j.cemconcomp.2006.11.001.
  144. Santosa, S.; Purbo Santosa, Y. Evolutionary Artificial Neural Networks for Concrete Mix Design Modelling. *International Journal Of Computer Application* **2017**, *5*, doi:10.26808/rs.ca.i7v5.06.
  145. Neshat, M.; Adeli, A.; Sepidnam, G.; Sargolzaei, M. Predication of Concrete Mix Design Using Adaptive Neural Fuzzy Inference Systems and Fuzzy Inference Systems. *The International Journal of Advanced Manufacturing Technology* **2012**, *63*, 373–390, doi:10.1007/s00170-012-3914-9.
  146. Nagarajan, D.; Rajagopal, T.; Meyappan, N. A Comparative Study on Prediction Models for Strength Properties of LWA Concrete Using Artificial Neural Network. *Revista de la construcción* **2020**, 103–111, doi:10.7764/rdlc.19.1.103-111.
  147. Chithra, S.; Kumar, S.R.R.S.; Chinnaraju, K.; Alfin Ashmita, F. A Comparative Study on the Compressive Strength Prediction Models for High Performance Concrete Containing Nano Silica and Copper Slag Using Regression Analysis and Artificial Neural Networks. *Constr Build Mater* **2016**, *114*, 528–535, doi:10.1016/j.conbuildmat.2016.03.214.
  148. Abolpour, B.; Abolpour, B.; Abolpour, R.; Bakhshi, H. Estimation of Concrete Compressive Strength by a Fuzzy Logic Model. *Research on Chemical Intermediates* **2013**, *39*, 707–719, doi:10.1007/s11164-012-0591-0.
  149. Chandwani, V.; Agrawal, V.; Nagar, R. Applications of Soft Computing in Civil Engineering: A Review. *Int J Comput Appl* **2013**, *81*, 13–20, doi:10.5120/14047-2210.
  150. Chine, W.-H.; Chen, L.; Hsu, H.-H.; Wang, T.-S.; Chiu, C.-H. Modeling Slump of Concrete Using the Artificial Neural Networks. In Proceedings of the 2010 International Conference on Artificial Intelligence and Computational Intelligence; IEEE, October **2010**; pp. 236–239.

151. Jain, A.; Jha, S.K.; Misra, S. Modeling and Analysis of Concrete Slump Using Artificial Neural Networks. *Journal of Materials in Civil Engineering* **2008**, *20*, 628–633, doi:10.1061/(ASCE)0899-1561(2008)20:9(628).
152. Yeh, I.C. Modeling Slump Flow of Concrete Using Second-Order Regressions and Artificial Neural Networks. *Cem Concr Compos* **2007**, *29*, 474–480, doi:10.1016/j.cemconcomp.2007.02.001.
153. Yeh, I.-C.; Lien, C.-; Peng, C.-H.; Lien, L.-C. Modeling Concrete Strength Using Genetic Operation Trees. In Proceedings of the 2010 International Conference on Machine Learning and Cybernetics; IEEE, July **2010**; pp. 1572–1576.
154. Ghafari, E.; Costa, H.; Júlio, E. Statistical Mixture Design Approach for Eco-Efficient UHPC. *Cem Concr Compos* **2015**, *55*, 17–25, doi:10.1016/j.cemconcomp.2014.07.016.
155. Hammoudi, A.; Moussaceb, K.; Belebchouche, C.; Dahmoune, F. Comparison of Artificial Neural Network (ANN) and Response Surface Methodology (RSM) Prediction in Compressive Strength of Recycled Concrete Aggregates. *Constr Build Mater* **2019**, *209*, 425–436, doi:10.1016/j.conbuildmat.2019.03.119.
156. Zhang, J.; Huang, Y.; Wang, Y.; Ma, G. Multi-Objective Optimization of Concrete Mixture Proportions Using Machine Learning and Metaheuristic Algorithms. *Constr Build Mater* **2020**, *253*, 119208, doi:10.1016/j.conbuildmat.2020.119208.
157. Behnood, A.; Golafshani, E.M. Predicting the Compressive Strength of Silica Fume Concrete Using Hybrid Artificial Neural Network with Multi-Objective Grey Wolves. *J Clean Prod* **2018**, *202*, 54–64, doi:10.1016/j.jclepro.2018.08.065.
158. Khademi, F.; Jamal, S.M.; Deshpande, N.; Londhe, S. Predicting Strength of Recycled Aggregate Concrete Using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression. *International Journal of Sustainable Built Environment* **2016**, *5*, 355–369, doi:10.1016/j.ijjsbe.2016.09.003.
159. Atici, U. Prediction of the Strength of Mineral Admixture Concrete Using Multivariable Regression Analysis and an Artificial Neural Network. *Expert Syst Appl* **2011**, *38*, 9609–9618, doi:10.1016/j.eswa.2011.01.156.
160. Deepa, C.; Researchscholar, M.P. *Prediction of the Compressive Strength of High Performance Concrete Mix Using Tree Based Modeling*; **2010**; Vol. 6;.
161. Sobhani, J.; Najimi, M.; Pourkhorshidi, A.R.; Parhizkar, T. Prediction of the Compressive Strength of No-Slump Concrete: A Comparative Study of Regression, Neural Network and ANFIS Models. *Constr Build Mater* **2010**, *24*, 709–718, doi:10.1016/j.conbuildmat.2009.10.037.
162. Anyaoha, U.; Zaji, A.; Liu, Z. Soft Computing in Estimating the Compressive Strength for High-Performance Concrete via Concrete Composition Appraisal. *Constr Build Mater* **2020**, *257*, 119472, doi:10.1016/j.conbuildmat.2020.119472.

163. Ashrafian, A.; Shokri, F.; Taheri Amiri, M.J.; Yaseen, Z.M.; Rezaie-Balf, M. Compressive Strength of Foamed Cellular Lightweight Concrete Simulation: New Development of Hybrid Artificial Intelligence Model. *Constr Build Mater* **2020**, *230*, 117048, doi:10.1016/j.conbuildmat.2019.117048.
164. Schabowicz, K. Nieniszcząca Identyfikacja Wytrzymałości Na Ściskanie Betonu Wysokowartościowego Przy Wykorzystaniu Sieci Neuro-nowych. *Zeszyty naukowe Politechniki Śląskiej* **2001**, *93*, 417–427.
165. Kim, J.-I.; Kim, D.K.; Feng, M.Q.; Yazdani, F.; Alshihri, M.M.; Azmy, A.M.; El-Bisy, M.S.; Bui, D.-K.; Nguyen, T.; Chou, J.-S.; et al. Application of Neural Networks for Estimation of Concrete Strength. *Constr Build Mater* **2017**, *16*, 320–333, doi:10.23918/eajse.v3i1sip142.
166. Wankhade, M Kambekar, A. Prediction of Compressive Strength of Concrete Using Artificial Neural. *International Journal of Scientific Research and Reviews* **2013**, *2*, 11–26.
167. Naderpour, H.; Rafiean, A.H.; Fakharian, P. Compressive Strength Prediction of Environmentally Friendly Concrete Using Artificial Neural Networks. *Journal of Building Engineering* **2018**, *16*, 213–219, doi:10.1016/j.jobe.2018.01.007.
168. D., N.; G., S. Prediction of Compressive Strength of Concrete Using Artificial Neural Networks. *Res J Pharm Technol* **2017**, *10*, 35–40, doi:10.5958/0974-360X.2017.00009.9.
169. Kim, J.-I.; Kim, D.K.; Feng, M.Q.; Yazdani, F. Application of Neural Networks for Estimation of Concrete Strength. *Journal of Materials in Civil Engineering* **2004**, *16*, 257–264, doi:10.1061/(asce)0899-1561(2004)16:3(257).
170. Yeh, I.C. Design of High-Performance Concrete Mixture Using Neural Networks and Nonlinear Programming. *Journal of Computing in Civil Engineering* **1999**, *13*, 36–42.
171. Ni, H.-G.; Wang, J.-Z. Prediction of Compressive Strength of Concrete by Neural Networks. *Cem Concr Res* **2000**, *30*, 1245–1250, doi:10.1016/S0008-8846(00)00345-8.
172. Chopra, P.; Sharma, R.K.; Kumar, M. Prediction of Compressive Strength of Concrete Using Artificial Neural Network and Genetic Programming. *Advances in Materials Science and Engineering* 2016, **2016**, 1–10, doi:10.1155/2016/7648467.
173. Lee, S.-C. Prediction of Concrete Strength Using Artificial Neural Networks. *Eng Struct* **2003**, *25*, 849–857, doi:10.1016/S0141-0296(03)00004-X.
174. Yadollahi, A.; Nazemi, E.; Zolfaghari, A.; Ajorloo, A.M. Optimization of Thermal Neutron Shield Concrete Mixture Using Artificial Neural Network. *Nuclear Engineering and Design* **2016**, *305*, 146–155, doi:10.1016/j.nucengdes.2016.05.012.
175. Öztaş, A.; Pala, M.; Özbay, E.E.; Kanca, E.E.; Çağlar, N.; Bhatti, M.A.; Çağlar, N.; Bhatti, M.A. Predicting the Compressive Strength and Slump of High Strength Concrete Using Neural Network. *Constr Build Mater* **2006**, *20*, 769–775, doi:10.1016/j.conbuildmat.2005.01.054.

176. Ji, T.; Lin, T.; Lin, X. A Concrete Mix Proportion Design Algorithm Based on Artificial Neural Networks. *Cem Concr Res* **2006**, *36*, 1399–1408, doi:10.1016/j.cemconres.2006.01.009.
177. Jin, R.; Chen, Q.; Soboyejo, A.B.O. Non-Linear and Mixed Regression Models in Predicting Sustainable Concrete Strength. *Constr Build Mater* **2018**, *170*, 142–152, doi:10.1016/j.conbuildmat.2018.03.063.
178. Horszczaruk, E.; Pietruszewicz, E. Zastosowanie Sztucznych Sieci Neuronowych w Modelowaniu Składu Mieszanki Betonów Podwodnych. *Inżynieria i Budownictwo* **2005**, *61*, 248–251.
179. Pala, M.; Özbay, E.; Öztaş, A.; Yuce, M.I. Appraisal of Long-Term Effects of Fly Ash and Silica Fume on Compressive Strength of Concrete by Neural Networks. *Constr Build Mater* **2007**, *21*, 384–394, doi:10.1016/j.conbuildmat.2005.08.009.
180. Ince, R. Prediction of Fracture Parameters of Concrete by Artificial Neural Networks. *Eng Fract Mech* **2004**, *71*, 2143–2159, doi:10.1016/j.engfracmech.2003.12.004.
181. Trtnik, G.; Kavčič, F.; Turk, G. Prediction of Concrete Strength Using Ultrasonic Pulse Velocity and Artificial Neural Networks. *Ultrasonics* **2009**, *49*, 53–60, doi:10.1016/j.ultras.2008.05.001.
182. Topçu, I.B.; Saridemir, M. Prediction of Compressive Strength of Concrete Containing Fly Ash Using Artificial Neural Networks and Fuzzy Logic. *Comput Mater Sci* **2008**, *41*, 305–311, doi:10.1016/j.commatsci.2007.04.009.
183. Yeh, I.-C. Modeling Concrete Strength with Augment-Neuron Networks. *Journal of Materials in Civil Engineering* **2002**, *10*, 263–268.
184. Alshihri, M.M.; Azmy, A.M.; El-Bisy, M.S. Neural Networks for Predicting Compressive Strength of Structural Light Weight Concrete. *Constr Build Mater* **2009**, *23*, 2214–2219, doi:10.1016/j.conbuildmat.2008.12.003.
185. Nehdi, M.; Djebbar, Y.; Khan, A. Neural Network Model for Pre-formed-Foam Cellular Concrete. *ACI Mater J* **2001**, *98*, 402–409.
186. de Franca, C.A.; Gonzaga, A.; Slaets, A.F.F. Classification of Wooden Boards by Neural Networks and Fuzzy Rules. In Proceedings of the Proceedings II Workshop on Cybernetic Vision; IEEE Comput. Soc; pp. 190–195.
187. Khademi, F.; Akbari, M.; Jamal, S.M.; Nikoo, M. Multiple Linear Regression, Artificial Neural Network, and Fuzzy Logic Prediction of 28 Days Compressive Strength of Concrete. *Frontiers of Structural and Civil Engineering* **2017**, *11*, 90–99, doi:10.1007/s11709-016-0363-9.
188. Özcan, F.; Atiş, C.D.; Karahan, O.; Uncuoğlu, E.; Tanyildizi, H.; Uncuoğlu, E.; Tanyildizi, H. Comparison of Artificial Neural Network and Fuzzy Logic Models for Prediction of Long-Term Compressive Strength of Silica Fume Concrete. *Advances in Engineering Software* **2009**, *40*, 856–863, doi:10.1016/j.advengsoft.2009.01.005.
189. Cihan, M.T. Corrigendum to “Prediction of Concrete Compressive Strength and Slump by Machine Learning Methods.” *Advances in Civil Engineering* **2020**, *2020*, 1–1, doi:10.1155/2020/8201734.

190. Chou, J.-S.; Chiu, C.-K.; Farfoura, M.; Al-Taharwa, I. Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques. *Journal of Computing in Civil Engineering* **2011**, *25*, 242–253, doi:10.1061/(ASCE)CP.1943-5487.0000088.
191. Feng, D.-C.; Liu, Z.-T.; Wang, X.-D.; Chen, Y.; Chang, J.-Q.; Wei, D.-F.; Jiang, Z.-M. Machine Learning-Based Compressive Strength Prediction for Concrete: An Adaptive Boosting Approach. *Constr Build Mater* **2020**, *230*, 117000, doi:10.1016/j.conbuildmat.2019.117000.
192. Young, B.A.; Hall, A.; Pilon, L.; Gupta, P.; Sant, G. Can the Compressive Strength of Concrete Be Estimated from Knowledge of the Mixture Proportions?: New Insights from Statistical Analysis and Machine Learning Methods. *Cem Concr Res* **2019**, *115*, 379–388, doi:10.1016/j.cemconres.2018.09.006.
193. Park, J.Y.; Yoon, Y.G.; Oh, T.K. Prediction of Concrete Strength with P-, S-, R-Wave Velocities by Support Vector Machine (SVM) and Artificial Neural Network (ANN). *Applied Sciences* **2019**, *9*, 4053, doi:10.3390/app9194053.
194. Vakharia, V.; Gujar, R. Prediction of Compressive Strength and Portland Cement Composition Using Cross-Validation and Feature Ranking Techniques. *Constr Build Mater* **2019**, *225*, 292–301, doi:10.1016/j.conbuildmat.2019.07.224.
195. Jalal, M.; Grasley, Z.; Gurganus, C.; Bullard, J.W. Experimental Investigation and Comparative Machine-Learning Prediction of Strength Behavior of Optimized Recycled Rubber Concrete. *Constr Build Mater* **2020**, *256*, 119478, doi:10.1016/j.conbuildmat.2020.119478.
196. Correia, S.L.; Partala, T.; Loch, F.C.; Segadães, A.M. Factorial Design Used to Model the Compressive Strength of Mortars Containing Recycled Rubber. *Compos Struct* **2010**, *92*, 2047–2051, doi:10.1016/j.compstruct.2009.11.007.
197. Kandiri, A.; Mohammadi Golafshani, E.; Behnood, A. Estimation of the Compressive Strength of Concretes Containing Ground Granulated Blast Furnace Slag Using Hybridized Multi-Objective ANN and Salp Swarm Algorithm. *Constr Build Mater* **2020**, *248*, 118676, doi:10.1016/j.conbuildmat.2020.118676.
198. Mashhadban, H.; Kutanaei, S.S.; Sayarinejad, M.A. Prediction and Modeling of Mechanical Properties in Fiber Reinforced Self-Compacting Concrete Using Particle Swarm Optimization Algorithm and Artificial Neural Network. *Constr Build Mater* **2016**, *119*, 277–287, doi:10.1016/j.conbuildmat.2016.05.034.
199. Deshpande, N.; Londhe, S.; Kulkarni, S. Modeling Compressive Strength of Recycled Aggregate Concrete by Artificial Neural Network, Model Tree and Non-Linear Regression. *International Journal of Sustainable Built Environment* **2014**, *3*, 187–198, doi:10.1016/j.ijbsbe.2014.12.002.
200. Chopra, P.; Sharma, R.K.; Kumar, M.; Chopra, T. Comparison of Machine Learning Techniques for the Prediction of Compressive Strength

- of Concrete. *Advances in Civil Engineering* **2018**, 2018, 1–9, doi:10.1155/2018/5481705.
201. Deshpande, N.; Londhe, S.; Kulkarni, S. Modeling Compressive Strength of Recycled Aggregate Concrete by Artificial Neural Network, Model Tree and Non-Linear Regression. *International Journal of Sustainable Built Environment* **2014**, 3, 187–198, doi:10.1016/j.ijbsbe.2014.12.002.
  202. Khan, K.; Salami, B.A.; Jamal, A.; Amin, M.N.; Usman, M.; Al-Faiad, M.A.; Abu-Arab, A.M.; Iqbal, M. Prediction Models for Estimating Compressive Strength of Concrete Made of Manufactured Sand Using Gene Expression Programming Model. *Materials* **2022**, 15, 5823, doi:10.3390/ma15175823.
  203. Azimi-Pour, M.; Eskandari-Naddaf, H. ANN and GEP Prediction for Simultaneous Effect of Nano and Micro Silica on the Compressive and Flexural Strength of Cement Mortar. *Constr Build Mater* **2018**, 189, 978–992, doi:10.1016/j.conbuildmat.2018.09.031.
  204. Chopra, P.; Sharma, R.K.; Kumar, M. Prediction of Compressive Strength of Concrete Using Artificial Neural Network and Genetic Programming. *Advances in Materials Science and Engineering* **2016**, 2016, 1–10, doi:10.1155/2016/7648467.
  205. Sadrmomtazi, A.; Sobhani, J.; Mirgozar, M.A. Modeling Compressive Strength of EPS Lightweight Concrete Using Regression, Neural Network and ANFIS. *Constr Build Mater* **2013**, 42, 205–216, doi:10.1016/j.conbuildmat.2013.01.016.
  206. Golafshani, E.M.; Rahai, A.; Sebt, M.H.; Akbarpour, H. Prediction of Bond Strength of Spliced Steel Bars in Concrete Using Artificial Neural Network and Fuzzy Logic. *Constr Build Mater* **2012**, 36, 411–418, doi:10.1016/j.conbuildmat.2012.04.046.
  207. Madandoust, R.; Bungey, J.H.; Ghavidel, R. Prediction of the Concrete Compressive Strength by Means of Core Testing Using GMDH-Type Neural Network and ANFIS Models. *Comput Mater Sci* **2012**, 51, 261–272, doi:10.1016/j.commatsci.2011.07.053.
  208. Gupta, S. Concrete Mix Design Using Artificial Neural Network. *Journal on Today's Ideas-Tomorrow's Technologies* **2013**, 1, doi:10.15415/jotitt.2013.11003.
  209. Lee, S.-C. Prediction of Concrete Strength Using Artificial Neural Networks. *Eng Struct* **2003**, 25, 849–857, doi:10.1016/S0141-0296(03)00004-X.
  210. Aggarwal, Y.; Aggarwal, P. Prediction of Compressive Strength of Scc Containing Bottom Ash Using-Artificial Neural Networks. *World Academy of Science, Engineering and Technology International Journal of Mathematical and Computational Sciences* **2011**, 753–740.
  211. Elsanadedy, H.M.; Al-Salloum, Y.A.; Abbas, H.; Alsayed, S.H. Prediction of Strength Parameters of FRP-Confined Concrete. *Compos B Eng* **2012**, 43, 228–239, doi:10.1016/j.compositesb.2011.08.043.
  212. Sobhani, J.; Najimi, M.; Pourkhorshidi, A.R.; Parhizkar, T. Prediction of the Compressive Strength of No-Slump Concrete: A Comparative

- Study of Regression, Neural Network and ANFIS Models. *Constr Build Mater* **2010**, *24*, 709–718, doi:10.1016/j.conbuildmat.2009.10.037.
213. Oh, J.W.; Lee, I.W.; Kim, J.T.; Lee, G.W. Application of Neural Networks for Proportioning of Concrete Mixes. *ACI Mater J* **1999**, *96*, 61–67, doi:10.14359/429.
  214. Abu Yaman, M.; Abd Elaty, M.; Taman, M. Predicting the Ingredients of Self Compacting Concrete Using Artificial Neural Network. *Alexandria Engineering Journal* **2017**, *56*, 523–532, doi:10.1016/j.aej.2017.04.007.
  215. Lee, S.-C. Prediction of Concrete Strength Using Artificial Neural Networks. *Eng Struct* **2003**, *25*, 849–857, doi:10.1016/S0141-0296(03)00004-X.
  216. Chopra, P.; Sharma, R.K.; Kumar, M. Prediction of Compressive Strength of Concrete Using Artificial Neural Network and Genetic Programming. *Advances in Materials Science and Engineering* **2016**, *2016*, 1–10, doi:10.1155/2016/7648467.
  217. Chopra, P.; Kumar, R.; Kumar, M. Artificial Neural Networks for the Prediction of Compressive Strength of Concrete. *International Journal of Applied Science and Engineerin* **2015**, *13*, 187–204.
  218. Kandiri, A.; Mohammadi Golafshani, E.; Behnood, A. Estimation of the Compressive Strength of Concretes Containing Ground Granulated Blast Furnace Slag Using Hybridized Multi-Objective ANN and Salp Swarm Algorithm. *Constr Build Mater* **2020**, *248*, 118676, doi:10.1016/j.conbuildmat.2020.118676.
  219. Dantas, A.T.A.; Batista Leite, M.; de Jesus Nagahama, K. Prediction of Compressive Strength of Concrete Containing Construction and Demolition Waste Using Artificial Neural Networks. *Constr Build Mater* **2013**, *38*, 717–722, doi:10.1016/j.conbuildmat.2012.09.026.
  220. Abu Yaman, M.; Abd Elaty, M.; Taman, M. Predicting the Ingredients of Self Compacting Concrete Using Artificial Neural Network. *Alexandria Engineering Journal* **2017**, *56*, 523–532, doi:10.1016/j.aej.2017.04.007.
  221. Elevado, K.J.T. Artificial Neural Network (ANN) Modelling Of Concrete Mixed With Waste Ceramic Tiles And Fly Ash. *International Journal of GEOMATE* **2018**, *15*, doi:10.21660/2018.51.58567.
  222. Namyong, J.; Sangchun, Y.; Hongbum, C. Prediction of Compressive Strength of In-Situ Concrete Based on Mixture Proportions. *Journal of Asian Architecture and Building Engineering* **2004**, *3*, 9–16, doi:10.3130/jaabe.3.9.
  223. DeRousseau, M.A.; Kasprzyk, J.R.; Srubar, W. v. Computational Design Optimization of Concrete Mixtures: A Review. *Cem Concr Res* **2018**, *109*, 42–53.
  224. Onyari, E.K.; Ikotun, B.D. Prediction of Compressive and Flexural Strengths of a Modified Zeolite Additive Mortar Using Artificial Neural Network. *Constr Build Mater* **2018**, *187*, 1232–1241, doi:10.1016/j.conbuildmat.2018.08.079.
  225. Gayatri Vineela, M.; Dave, A.; Kiran Chaganti, P. Artificial Neural Network Based Prediction of Tensile Strength of Hybrid Composites.



- Mater Today Proc* **2018**, *5*, 19908–19915, doi:10.1016/j.matpr.2018.06.356.
226. Duan, Z.H.; Kou, S.C.; Poon, C.S. Using Artificial Neural Networks for Predicting the Elastic Modulus of Recycled Aggregate Concrete. *Constr Build Mater* **2013**, *44*, 524–532, doi:10.1016/j.conbuildmat.2013.02.064.
  227. Davraz, M.; Kiliçarslan, Ş.; Ceylan, H. Predicting the Poisson Ratio of Lightweight Concretes Using Artificial Neural Network. *Acta Phys Pol A* **2015**, *128*, B-184-B-187, doi:10.12693/APhysPolA.128.B-184.
  228. Abambres; Lantsoght ANN-Based Fatigue Strength of Concrete under Compression. *Materials* **2019**, *12*, 3787, doi:10.3390/ma12223787.
  229. Karakoç, M.B.; Demirboğa, R.; Türkmen, İ.; Can, İ. Modeling with ANN and Effect of Pumice Aggregate and Air Entrainment on the Freeze–Thaw Durabilities of HSC. *Constr Build Mater* **2011**, *25*, 4241–4249, doi:10.1016/j.conbuildmat.2011.04.068.
  230. Shi, L.; Lin, S.T.K.; Lu, Y.; Ye, L.; Zhang, Y.X. Artificial Neural Network Based Mechanical and Electrical Property Prediction of Engineered Cementitious Composites. *Constr Build Mater* **2018**, *174*, 667–674, doi:10.1016/j.conbuildmat.2018.04.127.
  231. Bal, L.; Buyle-Bodin, F. Artificial Neural Network for Predicting Drying Shrinkage of Concrete. *Constr Build Mater* **2013**, *38*, 248–254, doi:10.1016/j.conbuildmat.2012.08.043.
  232. Marks, M.; Glinicki, M.; Gibas, K. Prediction of the Chloride Resistance of Concrete Modified with High Calcium Fly Ash Using Machine Learning. *Materials* **2015**, *8*, 8714–8727, doi:10.3390/ma8125483.
  233. Boğa, A.R.; Öztürk, M.; Topçu, İ.B. Using ANN and ANFIS to Predict the Mechanical and Chloride Permeability Properties of Concrete Containing GGBFS and CNI. *Compos B Eng* **2013**, *45*, 688–696, doi:10.1016/j.compositesb.2012.05.054.
  234. Hodhod, O.A.; Ahmed, H.I. Developing an Artificial Neural Network Model to Evaluate Chloride Diffusivity in High Performance Concrete. *HBRC Journal* **2013**, *9*, 15–21, doi:10.1016/j.hbrj.2013.04.001.
  235. Zavrtnik, N.; Prosen, J.; Tušar, M.; Turk, G. The Use of Artificial Neural Networks for Modeling Air Void Content in Aggregate Mixture. *Autom Constr* **2016**, *63*, 155–161, doi:10.1016/j.autcon.2015.12.009.
  236. Onal, O.; Ozturk, A.U. Artificial Neural Network Application on Microstructure–Compressive Strength Relationship of Cement Mortar. *Advances in Engineering Software* **2010**, *41*, 165–169, doi:10.1016/j.advengsoft.2009.09.004.
  237. Ozturan, M.; Kutlu, B.; Ozturan, T. Comparison of Concrete Strength Prediction Techniques with Artificial Neural Network Approach. *Building Research Journal* **2008**, *56*, 23–36.
  238. Lai, S.; Serra, M. Concrete Strength Prediction by Means of Neural Network. *Constr Build Mater* **1997**, *11*, 93–98, doi:10.1016/S0950-0618(97)00007-X.

239. Sonawane, D.A.; Jadhav, R.M.; Student, P.G.; Civil, A. *Prediction of Compression Strength of Concrete by Using Artificial Neural Network*; **2018**; Vol. 807;.
240. Ni, H.-G.; Wang, J.-Z. Prediction of Compressive Strength of Concrete by Neural Networks. *Cem Concr Res* **2000**, *30*, 1245–1250, doi:10.1016/S0008-8846(00)00345-8.
241. Sarıdemir, M. Prediction of Compressive Strength of Concretes Containing Metakaolin and Silica Fume by Artificial Neural Networks. *Advances in Engineering Software* **2009**, *40*, 350–355, doi:10.1016/j.advengsoft.2008.05.002.
242. Abuodeh, O.R.; Abdalla, J.A.; Hawileh, R.A. Assessment of Compressive Strength of Ultra-High Performance Concrete Using Deep Machine Learning Techniques. *Appl Soft Comput* **2020**, *95*, 106552, doi:10.1016/j.asoc.2020.106552.
243. Atici, U. Prediction of the Strength of Mineral Admixture Concrete Using Multivariable Regression Analysis and an Artificial Neural Network. *Expert Syst Appl* **2011**, *38*, 9609–9618, doi:10.1016/j.eswa.2011.01.156.
244. Erdal, H.I. Two-Level and Hybrid Ensembles of Decision Trees for High Performance Concrete Compressive Strength Prediction. *Eng Appl Artif Intell* **2013**, *26*, 1689–1697, doi:10.1016/j.engappai.2013.03.014.
245. Yeh, I.C. Modeling of Strength of High-Performance Concrete Using Artificial Neural Networks. *Cem Concr Res* **1998**, *28*, 1797–1808, doi:10.1016/S0008-8846(98)00165-3.
246. Khashman, A.; Akpınar, P. Non-Destructive Prediction of Concrete Compressive Strength Using Neural Networks. In *Proceedings of the Procedia Computer Science*; **2017**; Vol. 108, pp. 2358–2362.
247. Bilim, C.; Atiş, C.D.; Tanyildizi, H.; Karahan, O. Predicting the Compressive Strength of Ground Granulated Blast Furnace Slag Concrete Using Artificial Neural Network. *Advances in Engineering Software* **2009**, *40*, 334–340, doi:10.1016/j.advengsoft.2008.05.005.
248. Han, I.-J.; Yuan, T.-F.; Lee, J.-Y.; Yoon, Y.-S.; Kim, J.-H. Learned Prediction of Compressive Strength of GGBFS Concrete Using Hybrid Artificial Neural Network Models. *Materials* **2019**, *12*, 3708, doi:10.3390/ma12223708.
249. Abu Yaman, M.; Abd Elaty, M.; Taman, M. Predicting the Ingredients of Self Compacting Concrete Using Artificial Neural Network. *Alexandria Engineering Journal* **2017**, *56*, 523–532, doi:10.1016/j.aej.2017.04.007.
250. Kooshkaki, A.; Eskandari-Naddaf, H. Effect of Porosity on Predicting Compressive and Flexural Strength of Cement Mortar Containing Micro and Nano-Silica by Multi-Objective ANN Modeling. *Constr Build Mater* **2019**, *212*, 176–191, doi:10.1016/j.conbuildmat.2019.03.243.
251. Asteris, P.G.; Apostolopoulou, M.; Skentou, A.; Moropoulou, A. Application of Artificial Neural Networks for the Prediction of the Compressive Strength of Cement-Based Mortars. *Computers and Concrete* **2019**, *24*, 329–345.

252. Khademi, F.; Jamal, S.M.; Deshpande, N.; Londhe, S. Predicting Strength of Recycled Aggregate Concrete Using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression. *International Journal of Sustainable Built Environment* **2016**, *5*, 355–369, doi:10.1016/j.ijbsbe.2016.09.003.
253. Deshpande, N.; Londhe, S.; Kulkarni, S. Modeling Compressive Strength of Recycled Aggregate Concrete by Artificial Neural Network, Model Tree and Non-Linear Regression. *International Journal of Sustainable Built Environment* **2014**, *3*, 187–198, doi:10.1016/j.ijbsbe.2014.12.002.
254. Dantas, A.T.A.; Batista Leite, M.; de Jesus Nagahama, K. Prediction of Compressive Strength of Concrete Containing Construction and Demolition Waste Using Artificial Neural Networks. *Constr Build Mater* **2013**, *38*, 717–722, doi:10.1016/j.conbuildmat.2012.09.026.
255. Getahun, M.A.; Shitote, S.M.; Abiero Gariy, Z.C. Artificial Neural Network Based Modelling Approach for Strength Prediction of Concrete Incorporating Agricultural and Construction Wastes. *Constr Build Mater* **2018**, *190*, 517–525, doi:10.1016/j.conbuildmat.2018.09.097.
256. Elevado, K.J.T. Artificial Neural Network (ANN) Modelling Of Concrete Mixed With Waste Ceramic Tiles And Fly Ash. *International Journal of GEOMATE* **2018**, *15*, doi:10.21660/2018.51.58567.
257. Deng, F.; He, Y.; Zhou, S.; Yu, Y.; Cheng, H.; Wu, X. Compressive Strength Prediction of Recycled Concrete Based on Deep Learning. *Constr Build Mater* **2018**, *175*, 562–569, doi:10.1016/j.conbuildmat.2018.04.169.
258. Topçu, İ.B.; Sarıdemir, M. Prediction of Rubberized Mortar Properties Using Artificial Neural Network and Fuzzy Logic. *J Mater Process Technol* **2008**, *199*, 108–118, doi:10.1016/j.jmatprotec.2007.08.042.
259. Gupta, T.; Patel, K.A.; Siddique, S.; Sharma, R.K.; Chaudhary, S. Prediction of Mechanical Properties of Rubberised Concrete Exposed to Elevated Temperature Using ANN. *Measurement* **2019**, *147*, 106870, doi:10.1016/j.measurement.2019.106870.
260. Topçu, İ.B.; Sarıdemir, M. Prediction of Properties of Waste AAC Aggregate Concrete Using Artificial Neural Network. *Comput Mater Sci* **2007**, *41*, 117–125, doi:10.1016/j.commatsci.2007.03.010.
261. Cihan, M.T. Corrigendum to “Prediction of Concrete Compressive Strength and Slump by Machine Learning Methods.” *Advances in Civil Engineering* **2020**, *2020*, 1–1, doi:10.1155/2020/8201734.
262. Apostolopoulou, M.; Armaghani, D.J.; Bakolas, A.; Douvika, M.G.; Moropoulou, A.; Asteris, P.G. Compressive Strength of Natural Hydraulic Lime Mortars Using Soft Computing Techniques. *Procedia Structural Integrity* **2019**, *17*, 914–923, doi:10.1016/j.prostr.2019.08.122.
263. Abellán-García, J. Four-Layer Perceptron Approach for Strength Prediction of UHPC. *Constr Build Mater* **2020**, *256*, 119465, doi:10.1016/j.conbuildmat.2020.119465.
264. Kurpínska, M.; Kułak, L. Predicting Performance of Lightweight Concrete with Granulated Expanded Glass and Ash Aggregate by Means of

- Using Artificial Neural Networks. *Materials* **2019**, *12*, 2002, doi:10.3390/ma12122002.
265. Koneru, V.S.; Ghorpade, V.G. Assessment of Strength Characteristics for Experimental Based Workable Self Compacting Concrete Using Artificial Neural Network. *Mater Today Proc* **2020**, *26*, 1238–1244, doi:10.1016/j.matpr.2020.02.248.
  266. Nikoo, M.; Torabian Moghadam, F.; Sadowski, Ł. Prediction of Concrete Compressive Strength by Evolutionary Artificial Neural Networks. *Advances in Materials Science and Engineering* **2015**, *2015*, 1–8, doi:10.1155/2015/849126.
  267. Zhao, M.; Fu, C.; Ji, L.; Tang, K.; Zhou, M. Feature Selection and Parameter Optimization for Support Vector Machines: A New Approach Based on Genetic Algorithm with Feature Chromosomes. *Expert Syst Appl* **2011**, *38*, 5197–5204, doi:10.1016/j.eswa.2010.10.041.
  268. Pendharkar, P.C. Genetic Algorithm Based Neural Network Approaches for Predicting Churn in Cellular Wireless Network Services. *Expert Syst Appl* **2009**, *36*, 6714–6720, doi:10.1016/j.eswa.2008.08.050.
  269. Awwad, M. Developing a Forecasting Model of Concrete Compressive Strength Using Relevance Vector Machines. *International Journal of Engineering & Technology* **2014**, *3*, 224, doi:10.14419/ijet.v3i2.2011.
  270. Santosa, S.; Purbo Santosa, Y. Evolutionary Artificial Neural Networks for Concrete Mix Design Modelling. *International Journal Of Computer Application* **2017**, *5*, doi:10.26808/rs.ca.i7v5.06.
  271. Nagarajan, D.; Rajagopal, T.; Meyappan, N. A Comparative Study on Prediction Models for Strength Properties of LWA Concrete Using Artificial Neural Network. *Revista de la construcción* **2020**, 103–111, doi:10.7764/rdlc.19.1.103-111.
  272. Adil, M.; Ullah, R.; Noor, S.; Gohar, N. Effect of Number of Neurons and Layers in an Artificial Neural Network for Generalized Concrete Mix Design. *Neural Comput Appl* **2022**, *34*, 8355–8363, doi:10.1007/s00521-020-05305-8.
  273. Tenza-Abril, A.J.; Villacampa, Y.; Solak, A.M.; Baeza-Brotons, F. Prediction and Sensitivity Analysis of Compressive Strength in Segregated Lightweight Concrete Based on Artificial Neural Network Using Ultrasonic Pulse Velocity. *Constr Build Mater* **2018**, *189*, 1173–1183, doi:10.1016/j.conbuildmat.2018.09.096.
  274. Ashrafi, H.R.; Jalal, M.; Garmsiri, K. *Prediction Of Compressive Strength Of Composite Fiber Reinforced Concrete (FRC) Using Artificial Neuron Network*;
  275. Dauji, S. Neural Prediction of Concrete Compressive Strength. *International Journal of Materials and Structural Integrity* **2018**, *12*, 17, doi:10.1504/ijmsi.2018.093884.
  276. Lai, S.; Serra, M. Concrete Strength Prediction by Means of Neural Network. *Constr Build Mater* **1997**, *11*, 93–98, doi:10.1016/S0950-0618(97)00007-X.
  277. Lee, S. Prediction of Concrete Strength Using Artificial Neural Networks. *Eng Struct* **2003**, *25*, 849–857, doi:10.1016/S0141-0296(03)00004-X.

278. Al-Salloum, Y.A.; Shah, A.A.; Abbas, H.; Alsayed, S.H.; Almusallam, T.H.; Al-Haddad, M.S. Prediction of Compressive Strength of Concrete Using Neural Networks. *Computers and Concrete* **2012**, *10*, 197–217, doi:10.12989/cac.2012.10.2.197.
279. Dias, W.P.S.; Pooliyadda, S.P. Neural Networks for Predicting Properties of Concretes with Admixtures. *Constr Build Mater* **2001**, *15*, 371–379, doi:10.1016/S0950-0618(01)00006-X.
280. Hamid-Zadeh, N.; Jamali, A.; Nariman-Zadeh, N.; Akbarzadeh, H. Prediction of Concrete Compressive Strength Using Evolved Polynomial Neural Networks. *WSEAS Transactions on Systems* **2007**, *6*, 802–807.
281. Alshihri, M.M.; Azmy, A.M.; El-Bisy, M.S. Neural Networks for Predicting Compressive Strength of Structural Light Weight Concrete. *Constr Build Mater* **2009**, *23*, 2214–2219, doi:10.1016/j.conbuildmat.2008.12.003.
282. Gayathri, U.; Shanmugapriya, T.; Suveka, V. Predicting the Strength of High Performance Concrete Using Artificial Neural Network. *International Journal of Applied Engineering Research* **2016**, *11*, 3–8.
283. Ji, T.; Lin, T.; Lin, X. A Concrete Mix Proportion Design Algorithm Based on Artificial Neural Networks. *Cem Concr Res* **2006**, *36*, 1399–1408, doi:10.1016/j.cemconres.2006.01.009.
284. Hasan Taher, A.; Al-Jaberi, L.A.; Mosa, A.M. Artificial Neural Network for Mix Proportioning Optimization of Reactive Powder Concrete. *J Theor Appl Inf Technol* **2018**, *15*.
285. Parichatprecha, R.; Nimityongskul, P. Analysis of Durability of High Performance Concrete Using Artificial Neural Networks. *Constr Build Mater* **2009**, *23*, 910–917, doi:10.1016/j.conbuildmat.2008.04.015.
286. Nehdi, M.; el Chabib, H.; el Naggar, M.H. Predicting Performance of Self-Compacting Concrete Mixtures Using Artificial Neural Networks. *ACI Mater J* **2001**, *98*, 394–401.
287. Torre, A.; Garcia, F.; Moromi, I.; Espinoza, P.; Acuña, L. Prediction of Compression Strength of High Performance Concrete Using Artificial Neural Networks. *J Phys Conf Ser* **2015**, *582*, doi:10.1088/1742-6596/582/1/012010.
288. Yeh, I.-C. Analysis of Strength of Concrete Using Design of Experiments and Neural Networks. *Journal of Materials in Civil Engineering* **2006**, *18*, 597–604, doi:10.1061/(asce)0899-1561(2006)18:4(597).
289. Naderpour, H.; Kheyroddin, A.; Amiri, G.G. Prediction of FRP-Confining Compressive Strength of Concrete Using Artificial Neural Networks. *Compos Struct* **2010**, *92*, 2817–2829, doi:10.1016/j.compstruct.2010.04.008.
290. Öztaş, A.; Pala, M.; Özbay, E.; Kanca, E.; Çag˘lar, N.; Bhatti, M.A. Predicting the Compressive Strength and Slump of High Strength Concrete Using Neural Network. *Constr Build Mater* **2006**, *20*, 769–775, doi:10.1016/j.conbuildmat.2005.01.054.
291. Henigal, A.; Elbeltgai, E.; Eldwiny, M.; Serry, M. Artificial Neural Network Model For Forecasting Concrete Compressive Strength And Slump In Egypt. **2016**, *11*, 435–446.

292. Khanlari, G.; Abdilor, Y. Estimation of Strength Parameters of Limestone Using Artificial Neural Networks and Regression Analysis. *Aust J Basic Appl Sci* **2011**, *5*, 1049–1053.
293. Yadollahi, A.; Nazemi, E.; Zolfaghari, A.; Ajourloo, A.M. Application of Artificial Neural Network for Predicting the Optimal Mixture of Radiation Shielding Concrete. *Progress in Nuclear Energy* **2016**, *89*, 69–77, doi:10.1016/j.pnucene.2016.02.010.
294. Atici, U. Prediction of the Strength of Mineral Admixture Concrete Using Multivariable Regression Analysis and an Artificial Neural Network. *Expert Syst Appl* **2011**, *38*, 9609–9618, doi:10.1016/j.eswa.2011.01.156.
295. Khademi, F.; Jamal, S.M.; Deshpande, N.; Londhe, S. Predicting Strength of Recycled Aggregate Concrete Using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression. *International Journal of Sustainable Built Environment* **2016**, *5*, doi:10.1016/j.ijbsbe.2016.09.003.
296. Sobhani, J.; Najimi, M.; Pourkhorshidi, A.R.; Parhizkar, T. Prediction of the Compressive Strength of No-Slump Concrete: A Comparative Study of Regression, Neural Network and ANFIS Models. *Constr Build Mater* **2010**, *24*, 709–718, doi:10.1016/j.conbuildmat.2009.10.037.
297. Özcan, F.; Atiş, C.D.; Karahan, O.; Uncuoğlu, E.; Tanyildizi, H. Comparison of Artificial Neural Network and Fuzzy Logic Models for Prediction of Long-Term Compressive Strength of Silica Fume Concrete. *Advances in Engineering Software* **2009**, *40*, 856–863, doi:10.1016/j.advengsoft.2009.01.005.
298. Liang, L.; Guo, W.; Zhang, Y.; Zhang, W.Z.; Li, L.; Xing, X. Radial Basis Function Neural Network for Prediction of Medium-Frequency Sound Absorption Coefficient of Composite Structure Open-Cell Aluminum Foam. *Applied Acoustics* **2020**, *170*.
299. Duan, Z.H.; Kou, S.C.; Poon, C.S. Prediction of Compressive Strength of Recycled Aggregate Concrete Using Artificial Neural Networks. *Constr Build Mater* **2013**, *40*, 1200–1206, doi:10.1016/j.conbuildmat.2012.04.063.
300. Yaseen, Z.M.; Deo, R.C.; Hilal, A.; Abd, A.M.; Bueno, L.C.; Salcedo-Sanz, S.; Nehdi, M.L. Predicting Compressive Strength of Lightweight Foamed Concrete Using Extreme Learning Machine Model. *Advances in Engineering Software* **2018**, *115*, 112–125, doi:10.1016/j.advengsoft.2017.09.004.
301. Grzybowska, A.; Mroziak, Ł. Use of Admixture Effectiveness Curver for Prediction of the Compressive Strength. *Technical Sciences* **2018**, *21*, 175–182.
302. Grzybowska, A.; Acalski, P.; Mroziak, Ł.; Piekarski, P. Wybrane Problemy Nowoczesnej Technologii Betonu. *Materiały Budowlane* **2015**, *1*, 75–77, doi:10.15199/33.2015.05.29.
303. Goodfellow, I.; Bengio, Y.; Courville, A. *Deep Learning*; MIT Press: www.deeplearningbook.org, **2016**;

## SPIS RYSUNKÓW

Rysunek	Nazwa rysunku	Strona
Rysunek 1.1	Kryteria podziału betonów wysokiej wytrzymałości [7,16]	10
Rysunek 1.2	Uogólniona krzywa wytrzymałości betonu na ściskanie w zależności od stosunku wodno-spoiwowego (na podstawie literatury przedmiotu [11,27])	11
Rysunek 2.1	Wzrost wytrzymałości na ściskanie w zależności od stosunku w/c [10]	13
Rysunek 2.2	Przykłady obiektów zrealizowanych przy zastosowaniu BWW: a) Petronas Towers; b) Burj Khalifa [7]	14
Rysunek 2.3	Przekrój poprzeczny słupów o równoważnej nośności przy różnej wytrzymałości betonu na ściskanie [16]	15
Rysunek 2.4	Ciężar 1m słupa równoważnej nośności w zależności od betonu na ściskanie [16]	15
Rysunek 2.5	Ścieralność w funkcji wytrzymałości betonu [16]	17
Rysunek 2.6	Wzrost wytrzymałości mieszanki w funkcji czasu [16]	18
Rysunek 2.7	Porównanie zależności naprężenie-odkształcenie dla różnych betonów [7]	19
Rysunek 2.8	Porównanie składów betonów w zależności od przeznaczenia	22
Rysunek 2.9	Struktura betonu wysokowartościowego [31]	22
Rysunek 2.10	Wytrzymałość na ściskanie betonów wysokowartościowych z różnym kruszywem grubym [69]	23
Rysunek 2.11	Przyczepność pomiędzy stwardniałym zaczynem, a różnymi typami kruszyw przy stosunku w/s = 0,35 [70]	24
Rysunek 2.12	Współdziałanie mechanizmów: 1) elektrostatycznego i 2) sterycznego [73]	25
Rysunek 2.13	Mechanizm smarny: a) zaglomerowane ziarna cementu; b) ziarna cementu pokryte warstewkami smarnymi; c) rozproszone ziarna cementu [73]	26
Rysunek 2.14	Struktura ziaren cementu przy $\omega \gg \omega_n$	29
Rysunek 2.15	Struktura ziaren cementu przy $\omega = \omega_n$	29
Rysunek 2.16	Struktura ziaren cementu przy $\omega < \omega_n$	30
Rysunek 2.17	Wpływ stosunku wodno-cementowego oraz zawartości kruszywa na skurcz betonu [32]	32
Rysunek 2.18	Wpływ rodzaju cementu na skurcz zaprawy normowej [na podstawie Górażdże cement]	33
Rysunek 2.19	Graficzna interpretacja zestawienia parametrów struktury zaczynu cementowego [77]	33
Rysunek 2.20	Porównanie zależności naprężenie – odkształcenie dla betonów wykonanych z różnych kruszyw: B – bazaltowe; G – granitowe; O – otczakowe [70]	34
Rysunek 2.21	Typowe wykresy naprężenie-odkształcenie betonu konwencjonalnego oraz wysokowartościowego [32]	35
Rysunek 2.22	Zależność naprężenie-odkształcenie zaczynu, kruszywa i betonu dla: a) betonu zwykłego; b) betonu wysokowartościowego [16,69]	35

CD. SPISU RYSUNKÓW

Rysunek 2.23	Porównanie wybranych właściwości mechanicznych betonów zwykłych i BWW	36
Rysunek 2.24	Rozwój wytrzymałości na ściskanie dla różnych technologii betonu w funkcji czasu [30]	37
Rysunek 2.25	Redukcja mikroporowatości struktury BWW jako: a) wynik przemian fazowych w czasie [16]; b) zależności stosunku w/c (promień porów wyrażono w mikro metrach) [79]	38
Rysunek 2.26	Przepuszczalność betonów zwykłych i wysokowartościowych w wyniku działania wody i acetonu po 72 godzinach dojrzewania [80]	39
Rysunek 2.27	Wpływ stosunku w/c na przesiąkliwość zaczynu cementowego [16]	40
Rysunek 2.28	Spulchnienie stosu okruszowego kruszywa grubego warstwą zaprawy [77]	44
Rysunek 2.29	Wytrzymałość na ściskanie w zależności od współczynnika wodno-cementowego [75]	47
Rysunek 2.30	Model struktury Reniusa [77]	49
Rysunek 2.31	Model struktury betonu wg. Zubelewicza [77,89]	49
Rysunek 2.32	Krzywe (profile) upakowania cząstek o wysokiej, niskiej i pośredniej interakcji w stosunku do teoretycznych przypadków projektowych dla całkowicie nasyconych mieszanek betonowych o stałym stosunku wodno-spoiwowym	51
Rysunek 3.1	Zależności pomiędzy rozpatrywanymi obszarami wiedzy (opracowane na podstawie literatury przedmiotu [98–101]	58
Rysunek 3.2	Widok Perceptronu: a) zbudowanego w Cornell Aeronautical Laboratory – 1957 r.; b) układu potencjometrów [109]	60
Rysunek 3.3	a) schemat komórki nerwowej [118]; b) schemat sztucznej sieci neuronowej na podstawie [102]	61
Rysunek 3.4	Schemat działania modelu sztucznej sieci neuronowej, odzwierciedlający procesy zachodzące wewnątrz neuronu	64
Rysunek 3.5	Architektura sieci według Santosa [270]	76
Rysunek 3.6	Architektura sieci według Nagarajan [271]	76
Rysunek 3.7	Architektura sieci według DeRousseau [223]	77
Rysunek 3.8	Architektura sieci według Lee [215]	78
Rysunek 3.9	Architektura sieci według Mohammada Adil [272]	78
Rysunek 5.1	Widok beleczek: a) gotowe beleczki; b) złamane beleczki	87
Rysunek 5.2	Widok próbki przygotowanej do badania	88
Rysunek 5.3	Widok próbek wykonanych w celu oznaczenia gęstości pozornej zaczynu	89
Rysunek 5.4	Widok próbek	89
Rysunek 5.5	Widok zniszczonej w maszynie wytrzymałościowej próbki	90
Rysunek 5.6	Porównanie wytrzymałości na ściskanie zapraw CEM I o stosunku w/s = 0,5 z danymi domieszkami i dodatkiem	92
Rysunek 5.7	Porównanie wytrzymałości na ściskanie zapraw CEM II o stosunku w/s = 0,5 z danymi domieszkami i dodatkiem	93



## CD. SPISU RYSUNKÓW

Rysunek 5.8	Porównanie wytrzymałości na ściskanie zapraw CEM IV o stosunku w/s = 0,5 z danymi domieszkami i dodatkiem	94
Rysunek 5.9	Porównanie czasów wiązania dla poszczególnych cementów	96
Rysunek 5.10	Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Fluid Premia 380 dla CEM I	98
Rysunek 5.11	Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Plast 209 dla CEM I	98
Rysunek 5.12	Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Fluid Premia 380 dla CEM IV	99
Rysunek 5.13	Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Plast 209 dla CEM IV	99
Rysunek 5.14	Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Fluid Premia 380 dla CEM II	100
Rysunek 5.15	Porównanie gęstości pozornej zaczynu bez domieszek z gęstościami zaczynów z domieszką CHRYSO Plast 209 dla CEM II	100
Rysunek 5.16	Porównanie wytrzymałości na ściskanie zaprawy bez domieszki i dodatku oraz zaprawy z domieszką i dodatkiem dla CEM I	103
Rysunek 5.17	Porównanie wytrzymałości na ściskanie zaprawy bez domieszki i dodatku oraz zaprawy z domieszką i dodatkiem dla CEM II a) dla wszystkich wyników b) po odrzuceniu wyniku 18 MPa dla w/s 0,21	104
Rysunek 5.18	Porównanie wytrzymałości na ściskanie zaprawy bez domieszki i dodatku oraz zaprawy z domieszką i dodatkiem dla CEM IV	105
Rysunek 5.19	Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM I (kruszywo otoczkowe)	107
Rysunek 5.20	Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM II (kruszywo otoczkowe)	107
Rysunek 5.21	Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM IV (kruszywo otoczkowe)	108
Rysunek 5.22	Porównanie wytrzymałości betonu na ściskanie bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM I (kruszywo łamane)	109
Rysunek 5.23	Porównanie wytrzymałości betonu na ściskanie bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM II (kruszywo łamane)	109
Rysunek 5.24	Porównanie wytrzymałości na ściskanie betonu bez domieszki i dodatku oraz betonu z domieszką i dodatkiem dla CEM IV (kruszywo łamane)	110
Rysunek 5.25	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu bez domieszki i dodatku (kruszywo otoczkowe)	112

CD. SPISU RYSUNKÓW

Rysunek 5.26	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 1% (kruszywo otoczkowe)	112
Rysunek 5.27	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 3% (kruszywo otoczkowe)	113
Rysunek 5.28	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 5% (kruszywo otoczkowe)	113
Rysunek 5.29	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 15% (kruszywo otoczkowe)	114
Rysunek 5.30	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu bez domieszki i dodatku (kruszywo łamane)	114
Rysunek 5.31	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 1% (kruszywo łamane)	115
Rysunek 5.32	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z domieszką CHRYSO Fluid Premia 380 w ilości 3% (kruszywo łamane)	115
Rysunek 5.33	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 5% (kruszywo łamane)	116
Rysunek 5.34	Porównanie wytrzymałości na ściskanie z różnymi rodzajami cementu (CEM I, CEM II, CEM IV) dla betonu z dodatkiem mikrokrzemionki w ilości 15% (kruszywo łamane)	116
Rysunek 6.1	Architektura sieci zastosowana dla zadania 1	120
Rysunek 6.2	Architektura sieci zastosowana dla zadania 2	121
Rysunek 6.3	Schemat działania algorytmu wstecznej propagacji błędu [303]	124
Rysunek 6.4	Podział przestrzeni wektorów wag [303]	125
Rysunek 6.5	Przebieg procesu nauki [303]	126
Rysunek 6.6	Przebieg procesu nauki [303]	127
Rysunek 6.7	Przebieg procesu nauki [303]	128
Rysunek 6.8	Przebieg procesu nauki [303]	129
Rysunek 6.9	Przebieg procesu nauki [303]	130
Rysunek 6.10	Przebieg procesu nauki [303]	131
Rysunek 6.11	Funkcje aktywacji dostępne w programie Statistica (gdzie logistyczna oznacza funkcję sigmoidalną)	133
Rysunek 6.12	Wybór wektora wejścia oraz wyjścia	134
Rysunek 6.13	Graficzna prezentacja wyników sieci	136
Rysunek 6.14	Graficzna prezentacja wyników sieci	137
Rysunek 6.15	Graficzna prezentacja wyników sieci	137
Rysunek 6.16	Graficzna prezentacja wyników sieci	138
Rysunek 6.17	Graficzna prezentacja wyników sieci	138
Rysunek 6.18	Graficzna prezentacja wyników sieci	139

CD. SPISU RYSUNKÓW

Rysunek 6.19	Graficzna prezentacja wyników sieci	139
Rysunek 6.20	Wykres błędu dla próby uczącej i testowej	140
Rysunek 6.21	Wybór wektora wejścia oraz wyjścia	144
Rysunek 6.22	Graficzna prezentacja wyników sieci dla masy cementu	151
Rysunek 6.23	Graficzna prezentacja wyników sieci dla masy wody	152
Rysunek 6.24	Graficzna prezentacja wyników sieci dla masy kruszywa frakcji 2-8 mm	152
Rysunek 6.25	Graficzna prezentacja wyników sieci dla masy domieszki	153
Rysunek 6.26	Graficzna prezentacja wyników sieci dla masy mikrokrzemionki	153
Rysunek 6.27	Graficzna prezentacja wyników sieci, gdzie: masa cementu wg. receptury (Zm. zal), masa cementu otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)	154
Rysunek 6.28	Graficzna prezentacja wyników sieci, gdzie: masa wody wg. receptury (Zm. zal), masa wody otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)	154
Rysunek 6.29	Graficzna prezentacja wyników sieci, gdzie: masa domieszki wg. receptury (Zm. zal), masa domieszki otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)	155
Rysunek 6.30	Graficzna prezentacja wyników sieci, gdzie: masa dodatku wg. receptury (Zm. zal), masa dodatku otrzymana na wyjściu z predykcji (wyjście), wytrzymałość (wejście)	155
Rysunek 6.31	Graficzna prezentacja wyników sieci, gdzie: masa cementu wg. receptury (Zm. zal), masa cementu otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)	156
Rysunek 6.32	Graficzna prezentacja wyników sieci, gdzie: masa wody wg. receptury (Zm. zal), masa wody otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)	156
Rysunek 6.33	Graficzna prezentacja wyników sieci, gdzie: masa domieszki wg. receptury (Zm. zal), domieszki otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)	157
Rysunek 6.34	Graficzna prezentacja wyników sieci, gdzie: masa dodatku wg. receptury (Zm. zal), dodatku otrzymana na wyjściu z predykcji (wyjście), różnica pomiędzy wartościami z predykcji a rzeczywistymi (reszty)	157
Rysunek 6.35	Wykres błędu dla próby uczącej i testowej	158
Rysunek 6.36	Analiza wrażliwości wygenerowana z programu XGBoost	163
Rysunek 7.1	Widok okna służącego do wprowadzania nowych danych	167
Rysunek 7.2	Prognoza wytrzymałości dla zadanego przypadku	168
Rysunek 7.3	Widok okna służącego do wprowadzania nowych danych	168
Rysunek 7.4	Prognoza składu ilościowego mieszanki dla zadanego przypadku	169

## SPIS TABEL

<b>Tabela</b>	<b>Nazwa tabeli</b>	<b>Strona</b>
Tabela 2.1	Przykłady wymagań stawianym BWW w zależności Od przeznaczenia [48]	14
Tabela 2.2	Przykładowe kompozycje mieszanek betonowych [69,75]	27
Tabela 2.3	Wartość parametru K do wzoru (2.9) [13]	45
Tabela 3.1	Różne rodzaje mieszanek betonowych badanych za pomocą SSN	73
Tabela 5.1	Zestawienie badań wykonanych w ramach eksperymentu	86
Tabela 5.2	Wyniki oznaczenia klasy wytrzymałościowej spoiwa	91
Tabela 5.3	Wyniki oznaczenia wodożadności oraz czasu wiązania	95
Tabela 5.4	Wyniki badań gęstości pozornej zaczynów	97
Tabela 5.5	Porowatość zaczynów	101
Tabela 5.6	Wyniki oznaczenia wytrzymałości zaprawy na ściskanie	102
Tabela 5.7	Wyniki oznaczenia wytrzymałości betonu na ściskanie (żwir)	106
Tabela 5.8	Wyniki oznaczenia wytrzymałości betonu na ściskanie (grys)	108
Tabela 6.1	Predykcja wytrzymałości betonu na ściskanie	135
Tabela 6.2	Podsumowanie sieci	141
Tabela 6.3	Statystyki predykcji	142
Tabela 6.4	Analiza wrażliwości	143
Tabela 6.5	Predykcja masy cementu	145
Tabela 6.6	Predykcja masy wody	146
Tabela 6.7	Predykcja masy kruszywa frakcji 2-8 mm	147
Tabela 6.8	Predykcja masy kruszywa frakcji 8-16 mm	148
Tabela 6.9	Predykcja masy domieszki	149
Tabela 6.10	Predykcja masy dodatku	150
Tabela 6.11	Podsumowanie sieci	159
Tabela 6.12	Statystyki predykcji	160
Tabela 6.13	Analiza wrażliwości	161
Tabela 6.14	Oznaczenia zmiennych przyjętych do klasyfikatora XGBoost	163
Tabela 6.15	Wyniki predykcji wytrzymałości betonu na ściskanie otrzymane za pomocą klasyfikatora XGBoost	164
Tabela 7.1	Zmienne wejściowe do predykcji wytrzymałości	167
Tabela 7.2	Zmienne wejściowe do predykcji wytrzymałości	168
Tabela 7.3	Wyniki badań laboratoryjnych	169
Tabela 7.4	Wyniki badań laboratoryjnych	169
Tabela 7.5	Ocena efektywności	170

## STRESZCZENIE

Przedmiotem niniejszej pracy są kompozyty cementowe o ekstremalnie niskim stosunku wodno-spoiwowym. W początkowych rozdziałach pracy podjęto problem opisu takich kompozytów. Wytrzymałość jest wiodącą cechą mechaniczną betonu jako materiału budowlanego. Wyniki badań stwarzają coraz to nowe możliwości zastosowań, a w dotychczas stosowanych rozwiązaniach uzyskuje się dodatkowe korzyści. Aby jakikolwiek teoretyczny model mógł być wykorzystany w praktycznym projektowaniu składu mieszanki betonowej, musi najpierw zostać poprawnie skalibrowany. Kalibracja jest także niezbędna przy każdorazowej zmianie parametrów wejściowych, jak również wprowadzeniu nowych zmiennych. Proces ten wymaga przeprowadzenia niezbędnych badań laboratoryjnych próbnych serii betonów (co okazuje się czasochłonne i kosztochłonne). Sformułowanie modelu empirycznego w wielowymiarowej przestrzeni parametrów składu i właściwości kompozytu wysokowartościowego może okazać się zbyt skomplikowane. W takiej sytuacji do obiektywnego rozpoznania związków między składem, a właściwościami kompozytu można wykorzystać metodę sztucznej inteligencji – sztuczne sieci neuronowe (SSN). Możliwość wykorzystania SSN przy projektowaniu mieszanek betonowych została przedstawiona w wielu pracach naukowych, które przedstawiono w rozdziale 2. Obecne procedury projektowania mieszanek obowiązują tylko dla ograniczonego zakresu składów konkretnego rodzaju betonu, który został poddany wcześniejszej ocenie eksperymentalnej. Ponadto także różne inne czynniki wpływają na wytrzymałość betonu, które można w znacznym stopniu rozwiązać za pomocą metod prognozowania SSN. Dlatego uznano aktualny stan wiedzy w tym zakresie za niewystarczający, co posłużyło jako impuls do rozpoczęcia studiów literaturowych z tematyki implementacji SSN do predykcji cech betonów o niskim stosunku wodno-spoiwowym. Uzyskane wnioski (generujące problemy badawcze) posłużyły jako składowe stanowiące fragment analizy teoretycznej przygotowanej rozprawy doktorskiej. Przedstawiono możliwości zastosowania sztucznych sieci neuronowych do predykcji, np. wytrzymałości betonów wysokowartościowych o niskim stosunku wodno-spoiwowym. W dalszych rozważaniach wytrzymałość betonu na ściskanie definiowana była jako zmienna wyjściowa i wejściowa dla dwóch konkretnych zadań. W celu ich rozwiązania należało przeprowadzić niezbędne, obszerne badania laboratoryjne. Badania te były wykonywane i analizowane w ramach dalszych rozważań niniejszej pracy. Stworzenie bazy danych (prezentowanej w załączniku do pracy) pozwoliło na budowę konkretnych sieci neuronowych, możliwych do zastosowania w przemyśle. Dane wejściowe tworzonej macierzy danych służącej do rozwiązania zadania 1 stanowiły zmienne o charakterze ilościowym i jakościowym, natomiast wyjściową, podlegającą predykcji była zmienna zawierająca parametry betonu (wytrzymałość betonu na ściskanie). Z kolei przy zadaniu 2 wytrzymałość na ściskanie wprowadzana była w zestawie danych wejściowych. Kalibracja modelu fenomenologicznego (abstrakcyjnego) utworzonego przez sieć polegała na adekwatnym doborze wag w procesie uczenia. W pracy uwzględniono podstawowe aspekty sztucznej sieci neuronowej do rozwiązywania złożonych problemów nieliniowych w przewidywaniu właściwości mechanicznych betonu pod względem jego wytrzymałości. Metodologia wykorzystana w ramach niniejszej dysertacji jest bardziej ekonomiczna i wygodniejsza niż opracowywanie betonu za pomocą eksperymentów laboratoryjnych. Może być także doskonalona i poszerzana o nowe zbiory danych, oraz docelowo z powodzeniem wykorzystywana przez wytwórnice do projektowania i dozowania mieszanek.

## SUMMARY

The subject of this work are cement composites with an extremely low water-binder ratio. In the initial chapters of the work, the problem of describing such composites was addressed. Strength is the leading mechanical property of concrete as a building material. The results of research create new possibilities for applications, and additional benefits are obtained in the solutions used so far. In order for any theoretical model to be used in the practical design of the composition of the concrete mix, it must first be properly calibrated. Calibration is also necessary each time the input parameters are changed, as well as the introduction of new variables. This process requires carrying out the necessary laboratory tests of test series of concretes (which turns out to be time-consuming and cost-intensive). Formulation of the empirical model in the multidimensional space of parameters of the composition and properties of the high-performance composite may turn out to be too complicated. In such a situation, the artificial intelligence method - artificial neural networks (ANN) can be used to objectively identify the relationships between the composition and the properties of the composite. The possibility of using ANN in the design of concrete mixes has been presented in many scientific papers, which are presented in Chapter 2. Current mix design procedures are valid only for a limited range of compositions of a specific type of concrete that has been subjected to prior experimental evaluation. In addition, various other factors also affect the strength of concrete, which can be largely addressed by ANN prediction methods. Therefore, the current state of knowledge in this area was considered insufficient, which served as an impulse to start literature studies on the subject of ANN implementation for predicting the properties of concretes with a low water-binder ratio. The obtained conclusions (generating research problems) were used as components constituting a part of the theoretical analysis of the prepared doctoral dissertation. Possibilities of using artificial neural networks for prediction, e.g. strength of high-performance concretes with a low water-binder ratio, were presented. In further considerations, the compressive strength of concrete was defined as the input and output variable for two specific tasks. In order to solve them, the necessary extensive laboratory tests had to be carried out. These studies were performed and analyzed as part of further considerations in this paper. The creation of a database (presented in the appendix to the work) allowed for the construction of specific neural networks that can be used in industry. The input data for the created data matrix used to solve the task 1 were quantitative and qualitative variables, while the output, subject to prediction, was a variable containing concrete parameters (concrete compressive strength). On the other hand, in task 2, the compressive strength was entered in the input data set. Calibration of the phenomenological (abstract) model created by the network consisted in the appropriate selection of weights in the learning process. The work includes the basic aspects of an artificial neural network for solving complex non-linear problems in predicting the mechanical properties of concrete in terms of its strength. The methodology used in this dissertation is more economical and convenient than developing concrete through laboratory experiments. It can also be improved and extended with new data sets, and ultimately successfully used by factories for designing and dosing mixtures.

## **SPIS ZAŁĄCZNIKÓW**

<b>ZAŁĄCZNIK 1 – RECEPTURY ZAPRAW I MIESZANEK BETONOWYCH ORAZ WYNIKI BADAŃ.....</b>	<b>208</b>
<b>ZAŁĄCZNIK 2 – MATRYCA DANYCH.....</b>	<b>298</b>
<b>ZAŁĄCZNIK 3 – WAGI SIECI.....</b>	<b>319</b>
<b>ZAŁĄCZNIK 4 – KODY ALGORYTMÓW SSN DLA POSZCZEGÓLNYCH ZADAŃ.....</b>	<b>351</b>

## ZAŁĄCZNIK 1 – RECEPTURY ZAPRAW I MIESZANEK BETONOWYCH ORAZ WYNIKI BADAŃ

### SPIS TREŚCI

<b>1. RECEPTURY ZAPRAW i MIESZANEK BETONOWYCH ..</b>	<b>211</b>
1.1. Zaprawa bez domieszek.....	211
1.2. Zaprawa z domieszką Nr 2 w ilości 0,8%.....	211
1.3. Zaprawa z domieszką Nr 2 w ilości 3%.....	212
1.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5% .....	212
1.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15% .....	213
1.6. Beton bez domieszek .....	213
1.7. Beton z domieszką Nr 2 w ilości 1% .....	215
1.8. Beton z domieszką Nr 2 w ilości 3% .....	217
1.9. Beton z dodatkiem pyłu krzemionkowego w ilości 5%.....	219
1.10. Beton z dodatkiem pyłu krzemionkowego w ilości 15%.....	221
<b>2. CEM I 42,5 R .....</b>	<b>224</b>
2.1. Klasa wytrzymałościowa spoiwa.....	224
2.2. Wodozadržność normowa i czas wiązania.....	225
2.2.1. Zaprawa bez domieszek .....	225
2.2.2. Zaprawa z domieszką Nr 2 w ilości 0,8% .....	225
2.2.3. Zaprawa z domieszką Nr 1 w ilości 0,5% .....	225
2.2.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5% .....	226
2.2.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15% .....	226
2.3. Gęstość pozorna świeżego zaczynu .....	227
2.3.1. Zaczyn bez domieszek.....	227
2.3.2. Zaczyn z domieszką Nr 2 w ilości 0,8% .....	228
2.3.3. Zaczyn z domieszką Nr 2 w ilości 3% .....	229
2.3.4. Zaczyn z domieszką Nr 2 w ilości 6% .....	230
2.3.5. Zaczyn z domieszką Nr 1 w ilości 0,5% .....	231
2.4. Wytrzymałość na ściskanie zaprawy .....	232
2.4.1. Zaprawa bez domieszek .....	232
2.4.2. Zaprawa z domieszką Nr 2 w ilości 0,8% .....	234
2.4.3. Zaprawa z domieszką Nr 2 w ilości 3% .....	236
2.4.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5% .....	238
2.4.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15% .....	240
2.5. Wytrzymałość betonu na ściskanie.....	242
2.5.1. Beton bez domieszek.....	242
2.5.2. Beton z domieszką Nr 2 w ilości 1%.....	244
2.5.3. Beton z domieszką Nr 2 w ilości 3%.....	246
2.5.4. Beton z dodatkiem pyłu krzemionkowego w ilości 5% .....	248
2.5.5. Beton z dodatkiem pyłu krzemionkowego w ilości 15% .....	250



<b>3.</b>	<b>CEM II/A-M (S- LL) 52,5 N</b> .....	<b>252</b>
3.1.	Klasa wytrzymałościowa spoiwa.....	252
3.2.	Wodozgodność normowa i czas wiązania.....	253
3.2.1.	Zaprawa bez domieszek .....	253
3.2.2.	Zaprawa z domieszką Nr 2 w ilości 0,8% .....	253
3.2.3.	Zaprawa z domieszką Nr 1 w ilości 0,5% .....	253
3.2.4.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5% .....	254
3.2.5.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15% .....	254
3.3.	Gęstość pozorna świeżego zaczynu .....	255
3.3.1.	Zaczyn bez domieszek.....	255
3.3.2.	Zaczyn z domieszką Nr 2 w ilości 0,8% .....	256
3.3.3.	Zaczyn z domieszką Nr 2 w ilości 3% .....	257
3.3.4.	Zaczyn z domieszką Nr 1 w ilości 0,5% .....	258
3.4.	Wytrzymałość na ściskanie zaprawy .....	259
3.4.1.	Zaprawa bez domieszek .....	259
3.4.2.	Zaprawa z domieszką Nr 2 w ilości 0,8% .....	261
3.4.3.	Zaprawa z domieszką Nr 2 w ilości 3% .....	263
3.4.4.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5% .....	265
3.4.5.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15% .....	267
3.5.	Wytrzymałość betonu na ściskanie.....	269
3.5.1.	Beton bez domieszek.....	269
3.5.2.	Beton z domieszką Nr 2 w ilości 1%.....	271
3.5.3.	Beton z domieszką Nr 2 w ilości 3%.....	273
3.5.4.	Beton z dodatkiem pyłu krzemionkowego w ilości 5% .....	275
3.5.5.	Beton z dodatkiem pyłu krzemionkowego w ilości 15% .....	277
<b>4.</b>	<b>CEM IV/B(V) 32,5 R - LH/NA</b> .....	<b>279</b>
4.1.	Klasa wytrzymałościowa spoiwa.....	279
4.2.	Wodozgodność normowa i czas wiązania.....	280
4.2.1.	Zaprawa bez domieszek .....	280
4.2.2.	Zaprawa z domieszką Nr 2 w ilości 0,8% .....	280
4.2.3.	Zaprawa z domieszką Nr 1 w ilości 0,5% .....	280
4.2.4.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5% .....	281
4.2.5.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15% .....	281
4.3.	Gęstość pozorna świeżego zaczynu .....	282
4.3.1.	Zaczyn bez domieszek.....	282
4.3.2.	Zaczyn z domieszką Nr 2 w ilości 0,8% .....	283
4.3.3.	Zaczyn z domieszką Nr 2 w ilości 3% .....	284
4.3.4.	Zaczyn z domieszką Nr 1 w ilości 0,5% .....	285
4.4.	Wytrzymałość na ściskanie zaprawy .....	286
4.4.1.	Zaprawa bez domieszek .....	286
4.4.2.	Zaprawa z domieszką Nr 2 w ilości 0,8% .....	288
4.4.3.	Zaprawa z domieszką Nr 2 w ilości 3% .....	290
4.4.4.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5% .....	292
4.4.5.	Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15% .....	294
4.5.	Wytrzymałość betonu na ściskanie.....	296

4.5.1. Beton bez domieszek.....	296
4.5.2. Beton z domieszką Nr 2 w ilości 1%.....	298
4.5.3. Beton z domieszką Nr 2 w ilości 3%.....	300
4.5.4. Beton z dodatkiem pyłu krzemionkowego w ilości 5% .....	302
4.5.5. Beton z dodatkiem pyłu krzemionkowego w ilości 15% .....	304

## 1. RECEPTURY ZAPRAW I MIESZANEK BETONOWYCH

### 1.1. ZAPRAWA BEZ DOMIESZEK

Tabela 1.1. Receptura zaprawy bez domieszek i dodatków na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [g]	Masa wody [g]	Masa piasku [g]
1	0,21	834,04	175,15	1620,00
2	0,24	789,57	189,50	1620,00
3	0,27	749,59	202,39	1620,00
4	0,30	713,47	214,04	1620,00
5	0,33	680,67	224,62	1620,00
6	0,36	650,76	234,27	1620,00
7	0,40	614,73	245,89	1620,00
8	0,45	574,95	258,73	1620,00
9	0,50	540,00	270,00	1620,00

### 1.2. ZAPRAWA Z DOMIESZKĄ NR 2 W ILOŚCI 0,8%

Tabela 1.2. Receptura zaprawy z domieszką Nr 2 w ilości 0,8% na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [g]	Masa wody [g]	Masa piasku [g]	Masa fluid premia 0,8% [g]
1	0,21	834,04	175,15	1620,00	6,67
2	0,24	789,57	189,50	1620,00	6,32
3	0,27	749,59	202,39	1620,00	6,00
4	0,30	713,47	214,04	1620,00	5,71
5	0,33	680,67	224,62	1620,00	5,45
6	0,36	650,76	234,27	1620,00	5,21
7	0,40	614,73	245,89	1620,00	4,92
8	0,45	574,95	258,73	1620,00	4,60
9	0,50	540,00	270,00	1620,00	4,32

### 1.3. ZAPRAWA Z DOMIESZKĄ NR 2 W ILOŚCI 3%

Tabela 1.3. Receptura zaprawy z domieszką Nr 2 w ilości 3% na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [g]	Masa wody [g]	Masa piasku [g]	Masa fluid premia 3% [g]
1	0,21	834,04	175,15	1620,00	25,02
2	0,24	789,57	189,50	1620,00	23,69
3	0,27	749,59	202,39	1620,00	22,49
4	0,30	713,47	214,04	1620,00	21,40
5	0,33	680,67	224,62	1620,00	20,42
6	0,36	650,76	234,27	1620,00	19,52
7	0,40	614,73	245,89	1620,00	18,44
8	0,45	574,95	258,73	1620,00	17,25
9	0,50	540,00	270,00	1620,00	16,20

### 1.4. ZAPRAWA Z DODATKIEM PYŁU KRZEMIONKOWEGO W ILOŚCI 5%

Tabela 1.4. Receptura zaprawy z dodatkiem pyłu krzemionkowego w ilości 5% na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [g]	Masa wody [g]	Masa piasku [g]	Masa mikro-krzemionki 5% [g]
1	0,21	792,34	175,15	1620,00	41,70
2	0,24	750,09	189,50	1620,00	39,48
3	0,27	712,11	202,39	1620,00	37,48
4	0,30	677,80	214,04	1620,00	35,67
5	0,33	646,64	224,62	1620,00	34,03
6	0,36	618,22	234,27	1620,00	32,54
7	0,40	584,00	245,89	1620,00	30,74
8	0,45	546,20	258,73	1620,00	28,75
9	0,50	513,00	270,00	1620,00	27,00

## 1.5. ZAPRAWA Z DODATKIEM PYŁU KRZEMIONKOWEGO W ILOŚCI 15%

Tabela 1.5. Receptura zaprawy z dodatkiem pyłu krzemionkowego w ilości 15% na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [g]	Masa wody [g]	Masa piasku [g]	Masa mikrokrzemionki 15% [g]
1	0,21	708,94	175,15	1620,00	125,11
2	0,24	671,13	189,50	1620,00	118,43
3	0,27	637,15	202,39	1620,00	112,44
4	0,30	606,45	214,04	1620,00	107,02
5	0,33	578,57	224,62	1620,00	102,10
6	0,36	553,14	234,27	1620,00	97,61
7	0,40	522,52	245,89	1620,00	92,21
8	0,45	488,71	258,73	1620,00	86,24
9	0,50	459,00	270,00	1620,00	81,00

## 1.6. BETON BEZ DOMIESZEK

Tabela 1.6. Receptura betonu bez domieszek i dodatków na kruszywie otoczkowym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa żwiru [kg]	
					2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	2,340	2,340
2	0,24	2,149	0,516	1,656	2,340	2,340
3	0,27	2,040	0,551	1,656	2,340	2,340
4	0,30	1,942	0,583	1,656	2,340	2,340
5	0,33	1,853	0,611	1,656	2,340	2,340
6	0,36	1,771	0,638	1,656	2,340	2,340
7	0,40	1,673	0,669	1,656	2,340	2,340
8	0,45	1,565	0,704	1,656	2,340	2,340
9	0,50	1,470	0,735	1,656	2,340	2,340

Tabela 1.7. Receptura betonu bez domieszek i dodatków na kruszywie otoczkowym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa żwiru [kg]	
					2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	702,00	702,00
2	0,24	644,74	154,74	496,80	702,00	702,00
3	0,27	612,10	165,27	496,80	702,00	702,00
4	0,30	582,60	174,78	496,80	702,00	702,00
5	0,33	555,82	183,42	496,80	702,00	702,00
6	0,36	531,39	191,30	496,80	702,00	702,00
7	0,40	501,97	200,79	496,80	702,00	702,00
8	0,45	469,49	211,27	496,80	702,00	702,00
9	0,50	440,95	220,48	496,80	702,00	702,00

Tabela 1.8. Receptura betonu bez domieszek i dodatków na kruszywie łamanym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa żwiru [kg]	
					2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	2,826	2,826
2	0,24	2,149	0,516	1,656	2,826	2,826
3	0,27	2,040	0,551	1,656	2,826	2,826
4	0,30	1,942	0,583	1,656	2,826	2,826
5	0,33	1,853	0,611	1,656	2,826	2,826
6	0,36	1,771	0,638	1,656	2,826	2,826
7	0,40	1,673	0,669	1,656	2,826	2,826
8	0,45	1,565	0,704	1,656	2,826	2,826
9	0,50	1,470	0,735	1,656	2,826	2,826

Tabela 1.9. Receptura betonu bez domieszek i dodatków na kruszywie łamanym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa żwiru [kg]	
					2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	847,65	847,65
2	0,24	644,74	154,74	496,80	847,65	847,65
3	0,27	612,10	165,27	496,80	847,65	847,65
4	0,30	582,60	174,78	496,80	847,65	847,65
5	0,33	555,82	183,42	496,80	847,65	847,65
6	0,36	531,39	191,30	496,80	847,65	847,65
7	0,40	501,97	200,79	496,80	847,65	847,65
8	0,45	469,49	211,27	496,80	847,65	847,65
9	0,50	440,95	220,48	496,80	847,65	847,65

### 1.7. BETON Z DOMIESZKĄ NR 2 W ILOŚCI 1%

Tabela 1.10. Receptura betonu z domieszką Nr 2 w ilości 1% na kruszywie otoczkowym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 1% [kg]	Masa żwiru [kg]	
						2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,023	2,340	2,340
2	0,24	2,149	0,516	1,656	0,021	2,340	2,340
3	0,27	2,040	0,551	1,656	0,020	2,340	2,340
4	0,30	1,942	0,583	1,656	0,019	2,340	2,340
5	0,33	1,853	0,611	1,656	0,019	2,340	2,340
6	0,36	1,771	0,638	1,656	0,018	2,340	2,340
7	0,40	1,673	0,669	1,656	0,017	2,340	2,340
8	0,45	1,565	0,704	1,656	0,016	2,340	2,340
9	0,50	1,470	0,735	1,656	0,015	2,340	2,340

Tabela 1.11. Receptura betonu z domieszką Nr 2 w ilości 1% na kruszywie otoczkowym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 1% [kg]	Masa żwiru [kg]	
						2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	6,81	702,00	702,00
2	0,24	644,74	154,74	496,80	6,45	702,00	702,00
3	0,27	612,10	165,27	496,80	6,12	702,00	702,00
4	0,30	582,60	174,78	496,80	5,83	702,00	702,00
5	0,33	555,82	183,42	496,80	5,56	702,00	702,00
6	0,36	531,39	191,30	496,80	5,31	702,00	702,00
7	0,40	501,97	200,79	496,80	5,02	702,00	702,00
8	0,45	469,49	211,27	496,80	4,69	702,00	702,00
9	0,50	440,95	220,48	496,80	4,41	702,00	702,00

Tabela 1.12. Receptura betonu z domieszką Nr 2 w ilości 1% na kruszywie łamanym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 1% [kg]	Masa grysłu [kg]	
						2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,023	2,826	2,826
2	0,24	2,149	0,516	1,656	0,021	2,826	2,826
3	0,27	2,040	0,551	1,656	0,020	2,826	2,826
4	0,30	1,942	0,583	1,656	0,019	2,826	2,826
5	0,33	1,853	0,611	1,656	0,019	2,826	2,826
6	0,36	1,771	0,638	1,656	0,018	2,826	2,826
7	0,40	1,673	0,669	1,656	0,017	2,826	2,826
8	0,45	1,565	0,704	1,656	0,016	2,826	2,826
9	0,50	1,470	0,735	1,656	0,015	2,826	2,826



Tabela 1.13. Receptura betonu z domieszką Nr 2 w ilości 1% na kruszywie łamanym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 1% [kg]	Masa grysu [kg]	
						2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	6,81	847,65	847,65
2	0,24	644,74	154,74	496,80	6,45	847,65	847,65
3	0,27	612,10	165,27	496,80	6,12	847,65	847,65
4	0,30	582,60	174,78	496,80	5,83	847,65	847,65
5	0,33	555,82	183,42	496,80	5,56	847,65	847,65
6	0,36	531,39	191,30	496,80	5,31	847,65	847,65
7	0,40	501,97	200,79	496,80	5,02	847,65	847,65
8	0,45	469,49	211,27	496,80	4,69	847,65	847,65
9	0,50	440,95	220,48	496,80	4,41	847,65	847,65

## 1.8. BETON Z DOMIESZKĄ NR 2 W ILOŚCI 3%

Tabela 1.14. Receptura betonu z domieszką Nr 2 w ilości 3% na kruszywie otoczkowym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 3% [kg]	Masa żwiru [kg]	
						2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,068	2,340	2,340
2	0,24	2,149	0,516	1,656	0,064	2,340	2,340
3	0,27	2,040	0,551	1,656	0,061	2,340	2,340
4	0,30	1,942	0,583	1,656	0,058	2,340	2,340
5	0,33	1,853	0,611	1,656	0,056	2,340	2,340
6	0,36	1,771	0,638	1,656	0,053	2,340	2,340
7	0,40	1,673	0,669	1,656	0,050	2,340	2,340
8	0,45	1,565	0,704	1,656	0,047	2,340	2,340
9	0,50	1,470	0,735	1,656	0,044	2,340	2,340

Tabela 1.15. Receptura betonu z domieszką Nr 2 w ilości 3% na kruszywie otoczkowym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 3% [kg]	Masa żwiru [kg]	
						2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	20,40	702,00	702,00
2	0,24	644,74	154,74	496,80	19,20	702,00	702,00
3	0,27	612,10	165,27	496,80	18,30	702,00	702,00
4	0,30	582,60	174,78	496,80	17,40	702,00	702,00
5	0,33	555,82	183,42	496,80	16,80	702,00	702,00
6	0,36	531,39	191,30	496,80	15,90	702,00	702,00
7	0,40	501,97	200,79	496,80	15,00	702,00	702,00
8	0,45	469,49	211,27	496,80	14,10	702,00	702,00
9	0,50	440,95	220,48	496,80	13,20	702,00	702,00

Tabela 1.16. Receptura betonu z domieszką Nr 2 w ilości 3% na kruszywie łamanym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 3% [kg]	Masa grysłu [kg]	
						2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,068	2,826	2,826
2	0,24	2,149	0,516	1,656	0,064	2,826	2,826
3	0,27	2,040	0,551	1,656	0,061	2,826	2,826
4	0,30	1,942	0,583	1,656	0,058	2,826	2,826
5	0,33	1,853	0,611	1,656	0,056	2,826	2,826
6	0,36	1,771	0,638	1,656	0,053	2,826	2,826
7	0,40	1,673	0,669	1,656	0,050	2,826	2,826
8	0,45	1,565	0,704	1,656	0,047	2,826	2,826
9	0,50	1,470	0,735	1,656	0,044	2,826	2,826

Tabela 1.17. Receptura betonu z domieszką Nr 2 w ilości 3% na kruszywie łamanym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa fluid premia 3% [kg]	Masa grysłu [kg]	
						2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	20,40	847,65	847,65
2	0,24	644,74	154,74	496,80	19,20	847,65	847,65
3	0,27	612,10	165,27	496,80	18,30	847,65	847,65
4	0,30	582,60	174,78	496,80	17,40	847,65	847,65
5	0,33	555,82	183,42	496,80	16,80	847,65	847,65
6	0,36	531,39	191,30	496,80	15,90	847,65	847,65
7	0,40	501,97	200,79	496,80	15,00	847,65	847,65
8	0,45	469,49	211,27	496,80	14,10	847,65	847,65
9	0,50	440,95	220,48	496,80	13,20	847,65	847,65

### 1.9. BETON Z DODATKIEM PYŁU KRZEMIONKOWEGO W ILOŚCI 5%

Tabela 1.18. Receptura betonu z dodatkiem pyłu krzemionkowego w ilości 5% oraz z domieszką Nr 2 w ilości 3% na kruszywie otoczkowym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikrokrzemionki 5% [kg]	Masa fluid premia 3% [kg]	Masa żwiru [kg]	
							2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,114	0,068	2,340	2,340
2	0,24	2,149	0,516	1,656	0,107	0,064	2,340	2,340
3	0,27	2,040	0,551	1,656	0,102	0,061	2,340	2,340
4	0,30	1,942	0,583	1,656	0,097	0,058	2,340	2,340
5	0,33	1,853	0,611	1,656	0,093	0,056	2,340	2,340
6	0,36	1,771	0,638	1,656	0,089	0,053	2,340	2,340
7	0,40	1,673	0,669	1,656	0,084	0,050	2,340	2,340
8	0,45	1,565	0,704	1,656	0,078	0,047	2,340	2,340
9	0,50	1,470	0,735	1,656	0,073	0,044	2,340	2,340

Tabela 1.19. Receptura betonu z dodatkiem pyły krzemionkowej w ilości 5% oraz domieszką Nr 2 w ilości 3% na kruszywie otoczkowym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikrokrzemionki 5% [kg]	Masa fluid premia 3% [kg]	Masa żwiru [kg]	
							2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	113,509	20,40	702,00	702,00
2	0,24	644,74	154,74	496,80	107,456	19,20	702,00	702,00
3	0,27	612,10	165,27	496,80	102,016	18,30	702,00	702,00
4	0,30	582,60	174,78	496,80	97,101	17,40	702,00	702,00
5	0,33	555,82	183,42	496,80	92,637	16,80	702,00	702,00
6	0,36	531,39	191,30	496,80	88,565	15,90	702,00	702,00
7	0,40	501,97	200,79	496,80	83,662	15,00	702,00	702,00
8	0,45	469,49	211,27	496,80	78,248	14,10	702,00	702,00
9	0,50	440,95	220,48	496,80	73,492	13,20	702,00	702,00

Tabela 1.20. Receptura betonu z dodatkiem pyły krzemionkowej w ilości 5% oraz domieszką Nr 2 w ilości 3% na kruszywie łamanym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikrokrzemionki 5% [kg]	Masa fluid premia 3% [kg]	Masa grysłu [kg]	
							2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,114	0,068	2,826	2,826
2	0,24	2,149	0,516	1,656	0,107	0,064	2,826	2,826
3	0,27	2,040	0,551	1,656	0,102	0,061	2,826	2,826
4	0,30	1,942	0,583	1,656	0,097	0,058	2,826	2,826
5	0,33	1,853	0,611	1,656	0,093	0,056	2,826	2,826
6	0,36	1,771	0,638	1,656	0,089	0,053	2,826	2,826
7	0,40	1,673	0,669	1,656	0,084	0,050	2,826	2,826
8	0,45	1,565	0,704	1,656	0,078	0,047	2,826	2,826
9	0,50	1,470	0,735	1,656	0,073	0,044	2,826	2,826

Tabela 1.21. Receptura betonu z dodatkiem pyłu krzemionkowego w ilości 5% oraz domieszką Nr 2 w ilości 3% na kruszywie łamanym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikro-krzemionki 5% [kg]	Masa fluid premia 3% [kg]	Masa grysu [kg]	
							2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	113,509	20,40	847,65	847,65
2	0,24	644,74	154,74	496,80	107,456	19,20	847,65	847,65
3	0,27	612,10	165,27	496,80	102,016	18,30	847,65	847,65
4	0,30	582,60	174,78	496,80	97,101	17,40	847,65	847,65
5	0,33	555,82	183,42	496,80	92,637	16,80	847,65	847,65
6	0,36	531,39	191,30	496,80	88,565	15,90	847,65	847,65
7	0,40	501,97	200,79	496,80	83,662	15,00	847,65	847,65
8	0,45	469,49	211,27	496,80	78,248	14,10	847,65	847,65
9	0,50	440,95	220,48	496,80	73,492	13,20	847,65	847,65

### 1.10. BETON Z DODATKIEM PYŁU KRZEMIONKOWEGO W ILOŚCI 15%

Tabela 1.22. Receptura betonu z dodatkiem pyłu krzemionkowego w ilości 15% oraz z domieszką Nr 2 w ilości 3% na kruszywie otoczkowym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikro-krzemionki 15% [kg]	Masa fluid premia 3% [kg]	Masa żwiru [kg]	
							2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,341	0,068	2,340	2,340
2	0,24	2,149	0,516	1,656	0,322	0,064	2,340	2,340
3	0,27	2,040	0,551	1,656	0,306	0,061	2,340	2,340
4	0,30	1,942	0,583	1,656	0,291	0,058	2,340	2,340
5	0,33	1,853	0,611	1,656	0,278	0,056	2,340	2,340
6	0,36	1,771	0,638	1,656	0,266	0,053	2,340	2,340
7	0,40	1,673	0,669	1,656	0,251	0,050	2,340	2,340
8	0,45	1,565	0,704	1,656	0,235	0,047	2,340	2,340
9	0,50	1,470	0,735	1,656	0,220	0,044	2,340	2,340

Tabela 1.23. Receptura betonu z dodatkiem pyły krzemionkowej w ilości 15% oraz domieszką Nr 2 w ilości 3% na kruszywie otoczkowym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikro-krzemionki 15% [kg]	Masa fluid premia 3% [kg]	Masa żwiru [kg]	
							2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	340,528	20,40	702,00	702,00
2	0,24	644,74	154,74	496,80	322,369	19,20	702,00	702,00
3	0,27	612,10	165,27	496,80	306,049	18,30	702,00	702,00
4	0,30	582,60	174,78	496,80	291,302	17,40	702,00	702,00
5	0,33	555,82	183,42	496,80	277,910	16,80	702,00	702,00
6	0,36	531,39	191,30	496,80	265,696	15,90	702,00	702,00
7	0,40	501,97	200,79	496,80	250,987	15,00	702,00	702,00
8	0,45	469,49	211,27	496,80	234,744	14,10	702,00	702,00
9	0,50	440,95	220,48	496,80	220,475	13,20	702,00	702,00

Tabela 1.24. Receptura betonu z dodatkiem pyły krzemionkowej w ilości 15% oraz domieszką Nr 2 w ilości 3% na kruszywie łamanym na jeden laboratoryjny zarób

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikro-krzemionki 15% [kg]	Masa fluid premia 3% [kg]	Masa grysu [kg]	
							2-8 mm	8-16 mm
1	0,21	2,270	0,477	1,656	0,341	0,068	2,826	2,826
2	0,24	2,149	0,516	1,656	0,322	0,064	2,826	2,826
3	0,27	2,040	0,551	1,656	0,306	0,061	2,826	2,826
4	0,30	1,942	0,583	1,656	0,291	0,058	2,826	2,826
5	0,33	1,853	0,611	1,656	0,278	0,056	2,826	2,826
6	0,36	1,771	0,638	1,656	0,266	0,053	2,826	2,826
7	0,40	1,673	0,669	1,656	0,251	0,050	2,826	2,826
8	0,45	1,565	0,704	1,656	0,235	0,047	2,826	2,826
9	0,50	1,470	0,735	1,656	0,220	0,044	2,826	2,826

Tabela 1.25. Receptura betonu z dodatkiem pyły krzemionkowej w ilości 15% oraz domieszką Nr 2 w ilości 3% na kruszywie łamanym na m<sup>3</sup> mieszanki betonowej

Lp.	w/s	Masa cementu [kg]	Masa wody [kg]	Masa piasku [kg]	Masa mikrokrzemionki 15% [kg]	Masa fluid premia 3% [kg]	Masa grysłu [kg]	
							2-8 mm	8-16 mm
1	0,21	681,06	143,02	496,80	340,528	20,40	847,65	847,65
2	0,24	644,74	154,74	496,80	322,369	19,20	847,65	847,65
3	0,27	612,10	165,27	496,80	306,049	18,30	847,65	847,65
4	0,30	582,60	174,78	496,80	291,302	17,40	847,65	847,65
5	0,33	555,82	183,42	496,80	277,910	16,80	847,65	847,65
6	0,36	531,39	191,30	496,80	265,696	15,90	847,65	847,65
7	0,40	501,97	200,79	496,80	250,987	15,00	847,65	847,65
8	0,45	469,49	211,27	496,80	234,744	14,10	847,65	847,65
9	0,50	440,95	220,48	496,80	220,475	13,20	847,65	847,65

## 2. CEM I 42,5 R

### 2.1. KLASA WYTRZYMAŁOŚCIOWA SPOIWA

Tabela 2.1. Wyniki wytrzymałości na ściskanie zapraw po 7 i 28 dniach dla stosunku w/s = 0,5

Lp.	Rodzaj zaprawy	7 dni	28 dni	7 dni	28 dni
		kN	kN	MPa	MPa
1	bez dodatków	66,2	85,2	41,2	52,5
		64,8	84,6		
		65,6	85,0		
		70,0	85,0		
		62,8	85,2		
		66,2	79,4		
2	z domieszką CHRYSO Fluid Premia 380 w ilości 0,8%	80,6	82,4	49,9	52,5
		76,4	81,4		
		84,0	85,2		
		77,4	82,8		
		80,6	86,6		
		80,4	86,0		
3	z domieszką CHRYSO Plast 209 w ilości 0,5%	50,6	80,4	34,1	48,1
		56,6	77,2		
		53,0	73,4		
		57,4	73,6		
		54,8	78,8		
		55,6	78,8		
4	z dodatkiem pyłu krzemionkowego w ilości 5%	59,8	79,8	37,1	36,3
		58,8	79,6		
		58,0	82,0		
		58,6	81,4		
		60,6	84,0		
		60,0	83,4		
5	z dodatkiem pyłu krzemionkowego w ilości 15%	50,0	71,2	31,3	42,9
		52,0	68,6		
		47,6	68,0		
		52,8	68,0		
		48,4	65,0		
		49,6	71,0		



## 2.2. WODOŻĄDNOŚĆ NORMOWA I CZAS WIĄZANIA

### 2.2.1. Zaprawa bez domieszek

Ilość cementu: 500 [g]

Ilość wody: 147 [g]

Wodożądność normowa: 0,294

Tabela 2.2. Czas wiązania próbek zapraw bez domieszek

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	190	256
2	197	272

### 2.2.2. Zaprawa z domieszką Nr 2 w ilości 0,8%

Ilość cementu: 500 [g]

Ilość wody: 114,5 [g]

Ilość superplastyfikatora: 4 [g]

Wodożądność normowa: 0,229

Tabela 2.3. Czas wiązania próbek zapraw z domieszką Nr 2 w ilości 0,8%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	189	250
2	195	262

### 2.2.3. Zaprawa z domieszką Nr 1 w ilości 0,5%

Ilość cementu: 500 [g]

Ilość wody: 137 [g]

Ilość plastyfikatora: 2,5 [g]

Wodożądność normowa: 0,274

Tabela 2.4. Czas wiązania próbek zapraw z domieszką Nr 1 w ilości 0,5%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	239	293
2	229	287

#### 2.2.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5%

Ilość cementu: 475 [g]

Ilość wody: 150 [g]

Ilość dodatku: 25 [g]

Wodożądność normowa: 0,3

Tabela 2.5. Czas wiązania próbek zapraw z dodatkiem pyłu krzemionkowego w ilości 5%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	191	243
2	198	236

#### 2.2.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15%

Ilość cementu: 425 [g]

Ilość wody: 168 [g]

Ilość dodatku: 75 [g]

Wodożądność normowa: 0,336

Tabela 2.6. Czas wiązania próbek zapraw z dodatkiem pyłu krzemionkowego w ilości 15%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	193	236
2	185	232

## 2.3. GĘSTOŚĆ POZORNA ŚWIEŻEGO ZACZYNU

### 2.3.1. Zaczyn bez domieszek

Tabela 2.7. Gęstość pozorna zaczynu bez domieszek

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,21	266,53	2,27	1,28
		266,68		
2	0,24	296,38	2,20	1,42
		295,72		
3	0,27	433,19	2,14	2,08
		433,00		
4	0,30	431,33	2,09	2,07
		431,34		
5	0,33	420,79	2,04	2,02
		420,62		
6	0,36	415,31	1,99	2,00
		415,10		
7	0,40	406,63	1,94	1,96
		407,01		
8	0,45	390,05	1,88	1,87
		389,82		
9	0,50	375,51	1,82	1,80
		375,37		

### 2.3.2. Zaczyn z domieszką Nr 2 w ilości 0,8%

Tabela 2.8. Gęstość pozorna zaczynu z domieszką Nr 2 w ilości 0,8%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,15	390,86	2,43	1,88
		390,28		
2	0,18	385,91	2,35	1,86
		386,08		
3	0,21	364,48	2,27	1,75
		364,67		
4	0,24	439,66	2,20	2,11
		439,92		
5	0,27	444,06	2,14	2,14
		445,54		
6	0,30	423,28	2,09	2,03
		422,91		
7	0,33	401,75	2,04	1,93
		402,44		
8	0,36	408,95	1,99	1,97
		409,13		
9	0,40	389,67	1,94	1,87
		389,74		
10	0,45	383,55	1,88	1,84
		383,88		
11	0,50	369,75	1,82	1,78
		370,37		

### 2.3.3. Zaczyn z domieszką Nr 2 w ilości 3%

Tabela 2.9. Gęstość pozorna zaczynu z domieszką Nr 2 w ilości 3%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,15	428,41	2,43	2,06
		428,79		
2	0,18	414,42	2,35	1,99
		414,86		
3	0,21	445,35	2,27	2,14
		445,11		
4	0,24	424,28	2,20	2,04
		424,91		
5	0,27	433,11	2,14	2,08
		433,87		
6	0,30	416,43	2,09	2,00
		416,89		
7	0,33	403,16	2,04	1,94
		403,05		
8	0,36	390,11	1,99	1,87
		389,83		
9	0,40	380,11	1,94	1,83
		380,51		
10	0,45	368,75	1,88	1,77
		368,41		
11	0,50	355,57	1,82	1,71
		356,48		

### 2.3.4. Zaczyn z domieszką Nr 2 w ilości 6%

Tabela 2.10. Gęstość pozorna zaczynu z domieszką CHRYSO Fluid Premia 380 w ilości 6%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,15	476,20	2,43	2,29
		476,49		
2	0,18	480,73	2,35	2,31
		479,77		
3	0,21	450,08	2,27	2,16
		450,35		
4	0,24	438,50	2,20	2,11
		438,29		
5	0,27	428,73	2,14	2,06
		428,60		
6	0,30	415,04	2,09	1,99
		414,68		
7	0,33	409,86	2,04	1,97
		409,73		
8	0,36	386,69	1,99	1,86
		387,25		
9	0,40	383,44	1,94	1,84
		383,67		
10	0,45	371,40	1,88	1,79
		371,67		
11	0,50	359,46	1,82	1,73
		359,64		

### 2.3.5. Zaczyn z domieszką Nr 1 w ilości 0,5%

Tabela 2.11. Gęstość pozorna zaczynu z domieszką Nr 1 w ilości 0,5%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,21	295,88	2,27	1,42
		296,21		
2	0,24	432,69	2,20	2,08
		432,45		
3	0,27	424,25	2,14	2,04
		424,01		
4	0,30	424,56	2,09	2,04
		424,64		
5	0,33	419,53	2,04	2,02
		420,12		
6	0,36	405,28	1,99	1,95
		405,11		
7	0,40	395,80	1,94	1,90
		395,76		
8	0,45	372,36	1,88	1,79
		372,22		
9	0,50	367,97	1,82	1,77
		367,84		

## 2.4. WYTRZYMAŁOŚĆ NA ŚCISKANIE ZAPRAWY

### 2.4.1. Zaprawa bez domieszek

Tabela 2.12. Wytrzymałość na ściskanie zaprawy bez domieszek

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	5,6	3,5	5,4
		7,8	4,9	
		8,2	5,1	
		10,0	6,3	
		9,6	6,0	
		11,0	6,9	
2	0,24	15,7	9,8	7,9
		17,8	11,1	
		9,4	5,9	
		11,0	6,9	
		12,0	7,5	
		10,0	6,3	
3	0,27	19,5	12,2	9,9
		11,8	7,4	
		15,0	9,4	
		18,6	11,6	
		13,4	8,4	
		16,6	10,4	
4	0,30	13,4	8,4	13,3
		22,0	13,8	
		25,3	15,8	
		24,0	15,0	
		22,1	13,8	
		21,3	13,3	
5	0,33	34,6	21,6	22,5
		36,0	22,5	
		30,1	18,8	
		44,0	27,5	
		35,0	21,9	
		36,0	22,5	



CD. Tabela 2.12. Wytrzymałość na ściskanie zaprawy bez domieszek

6	0,36	54,1	33,8	29,5
		56,0	35,0	
		43,0	26,9	
		39,0	24,4	
		44,0	27,5	
		47,0	29,4	
7	0,40	47,0	29,4	32,2
		57,0	35,6	
		53,4	33,4	
		51,0	31,9	
		49,4	30,9	
		51,0	31,9	
8	0,45	77,0	48,1	48,1
		72,0	45,0	
		75,0	46,9	
		82,0	51,3	
		78,1	48,8	
		78,1	48,8	
9	0,50	71,0	44,4	42,2
		49,0	30,6	
		72,5	45,3	
		73,0	45,6	
		68,5	42,8	
		71,5	44,7	

### 2.4.2. Zaprawa z domieszką Nr 2 w ilości 0,8%

Tabela 2.13. Wytrzymałość na ściskanie zaprawy z domieszką Nr 2 w ilości 0,8%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	30,1	18,8	19,5
		30,6	19,1	
		35,0	21,9	
		32,0	20,0	
		31,0	19,4	
		28,5	17,8	
2	0,24	61,0	38,1	62,2
		110,1	68,8	
		114,6	71,6	
		105,0	65,6	
		106,6	66,6	
		100,0	62,5	
3	0,27	107,0	66,9	63,0
		110,1	68,8	
		95,0	59,4	
		92,0	57,5	
		97,0	60,6	
		104,0	65,0	
4	0,30	120,0	75,0	75,7
		120,5	75,3	
		122,0	76,3	
		119,0	74,4	
		119,0	74,4	
		126,1	78,8	
5	0,33	104,0	65,0	70,1
		116,0	72,5	
		112,0	70,0	
		106,6	66,6	
		117,4	73,4	
		117,0	73,1	
6	0,36	109,0	68,1	67,0
		105,4	65,9	
		114,0	71,3	
		110,1	68,8	
		105,0	65,6	
		100,0	62,5	

CD. Tabela 2.13. Wytrzymałość na ściskanie  
zaprawy z domieszką Nr 2 w ilości 0,8%

7	0,40	86,6	54,1	58,2
		96,0	60,0	
		99,0	61,9	
		98,1	61,3	
		97,0	60,6	
		82,1	51,3	
8	0,45	81,0	50,6	49,0
		82,1	51,3	
		76,0	47,5	
		67,5	42,2	
		86,1	53,8	
		78,1	48,8	
9	0,50	73,0	45,6	43,3
		74,1	46,3	
		72,0	45,0	
		66,6	41,6	
		64,5	40,3	
		66,1	41,3	

### 2.4.3. Zaprawa z domieszką Nr 2 w ilości 3%

Tabela 2.14. Wytrzymałość na ściskanie zaprawy z domieszką Nr 2 w ilości 3%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	22,1	13,8	15,1
		27,0	16,9	
		24,5	15,3	
		23,5	14,7	
		24,0	15,0	
		24,0	15,0	
2	0,24	77,0	48,1	45,7
		75,0	46,9	
		73,0	45,6	
		71,0	44,4	
		71,0	44,4	
		72,0	45,0	
3	0,27	106,1	66,3	67,4
		101,0	63,1	
		108,0	67,5	
		111,0	69,4	
		110,1	68,8	
		111,0	69,4	
4	0,30	114,1	71,3	67,1
		106,1	66,3	
		105,0	65,6	
		105,0	65,6	
		104,5	65,3	
		110,1	68,8	
5	0,33	101,0	63,1	61,9
		104,0	65,0	
		100,0	62,5	
		96,5	60,3	
		96,0	60,0	
		97,0	60,6	
6	0,36	101,0	63,1	58,8
		94,6	59,1	
		91,0	56,9	
		91,5	57,2	
		94,6	59,1	
		92,0	57,5	

CD. Tabela 2.14. Wytrzymałość na ściskanie  
zaprawy z domieszką Nr 2 w ilości 3%

7	0,40	91,5	57,2	54,4
		88,5	55,3	
		86,1	53,8	
		85,0	53,1	
		86,0	53,8	
		85,0	53,1	
8	0,45	85,4	53,4	50,1
		82,1	51,3	
		77,4	48,4	
		77,0	48,1	
		75,5	47,2	
		83,0	51,9	
9	0,50	83,5	52,2	48,6
		75,0	46,9	
		74,6	46,6	
		83,5	52,2	
		75,5	47,2	
		75,0	46,9	

#### 2.4.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5%

Tabela 2.15. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 5%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	8,8	5,5	5,7
		10,3	6,4	
		9,0	5,6	
		8,4	5,3	
		9,0	5,6	
		8,9	5,6	
2	0,24	7,0	4,4	5,7
		7,9	4,9	
		12,0	7,5	
		13,4	8,4	
		7,7	4,8	
		6,4	4,0	
3	0,27	17,6	11,0	10,3
		15,0	9,4	
		15,4	9,6	
		18,6	11,6	
		17,7	11,1	
		14,6	9,1	
4	0,30	16,2	10,1	10,1
		15,8	9,9	
		16,0	10,0	
		16,9	10,6	
		15,9	9,9	
		16,6	10,4	
5	0,33	24,0	15,0	14,6
		21,4	13,4	
		24,5	15,3	
		20,8	13,0	
		23,6	14,8	
		26,2	16,4	
6	0,36	29,0	18,1	18,5
		30,6	19,1	
		29,4	18,4	
		35,0	21,9	
		26,1	16,3	
		28,0	17,5	

CD. Tabela 2.15. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 5%

7	0,40	54,0	33,8	33,5
		50,1	31,3	
		53,0	33,1	
		57,0	35,6	
		53,4	33,4	
		54,0	33,8	
8	0,45	49,4	30,9	30,6
		49,0	30,6	
		44,0	27,5	
		51,0	31,9	
		50,6	31,6	
		49,4	30,9	
9	0,50	63,0	39,4	43,8
		70,6	44,1	
		71,0	44,4	
		75,0	46,9	
		70,6	44,1	
		70,1	43,8	

### 2.4.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15%

Tabela 2.16. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 15%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	4,6	2,9	2,8
		4,9	3,1	
		4,0	2,5	
		5,0	3,1	
		4,5	2,8	
		4,2	2,6	
2	0,24	3,8	2,4	2,4
		4,4	2,8	
		3,0	1,9	
		3,6	2,3	
		4,2	2,6	
		4,4	2,8	
3	0,27	3,4	2,1	2,1
		3,2	2,0	
		3,4	2,1	
		3,3	2,1	
		3,0	1,9	
		3,9	2,4	
4	0,30	6,2	3,9	4,3
		6,3	3,9	
		8,0	5,0	
		7,2	4,5	
		7,6	4,8	
		6,3	3,9	
5	0,33	13,1	8,2	7,5
		11,3	7,1	
		11,6	7,3	
		11,5	7,2	
		12,1	7,6	
		12,0	7,5	
6	0,36	14,0	8,8	9,4
		17,3	10,8	
		16,0	10,0	
		14,9	9,3	
		15,8	9,9	
		12,3	7,7	



CD. Tabela 2.16. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 15%

7	0,40	24,2	15,1	14,3
		21,4	13,4	
		24,3	15,2	
		24,0	15,0	
		22,5	14,1	
		21,2	13,3	
8	0,45	25,8	16,1	17,1
		23,4	14,6	
		24,5	15,3	
		27,9	17,4	
		31,4	19,6	
		31,5	19,7	
9	0,50	24,2	15,1	17,6
		27,9	17,4	
		26,4	16,5	
		29,1	18,2	
		28,6	17,9	
		33,0	20,6	

## 2.5. WYTRZYMAŁOŚĆ BETONU NA ŚCISKANIE

### 2.5.1. Beton bez domieszek

Tabela 2.17. Wytrzymałość na ściskanie betonu bez domieszek z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,50	100,50	10100,25	92,3	9,14	8,85
	100,80	102,00	10281,60	98,8	9,61	
0,21	101,00	100,30	10130,30	80,3	7,93	
	99,40	100,60	9999,64	87,3	8,73	
0,24	100,50	100,50	10100,25	260,8	25,82	23,90
	101,00	100,50	10150,50	235,3	23,18	
0,24/0,27	100,30	100,60	10090,18	228,9	22,69	
	100,30	100,50	10080,15	574,0	56,94	
0,27	100,90	100,40	10130,36	484,4	47,82	49,06
	100,30	101,90	10220,57	433,6	42,42	
0,30	100,20	101,00	10120,20	462,1	45,66	48,17
	100,30	102,70	10300,81	497,9	48,34	
0,30/0,33	100,40	101,10	10150,44	512,8	50,52	
	100,90	100,30	10120,27	687,8	67,96	
0,33	100,40	102,00	10240,80	709,0	69,23	68,43
	100,20	101,60	10180,32	693,1	68,08	
0,36	100,20	101,60	10180,32	664,6	65,28	66,38
	101,70	100,10	10180,17	681,1	66,90	
0,36/0,40	100,30	100,40	10070,12	674,1	66,94	
	99,60	100,40	9999,84	645,1	64,51	
0,40	101,50	99,90	10139,85	624,6	61,60	63,69
	100,40	99,60	9999,84	649,5	64,95	
0,45	100,10	100,80	10090,08	515,5	51,09	52,83
	100,00	99,90	9990,00	549,5	55,01	
0,45/0,50	100,40	101,10	10150,44	531,8	52,39	
	100,10	100,70	10080,07	423,8	42,04	
0,50	99,90	100,20	10009,98	420,4	42,00	42,54
	100,50	98,50	9899,25	431,3	43,57	

Tabela 2.18. Wytrzymałość na ściskanie betonu bez domieszek z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość			
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]	
0,21	100,27	101,13	10140,31	60,9	6,01	5,98	
	98,88	100,50	9937,44	55,2	5,55		
0,21	100,56	101,10	10166,62	60,9	5,99		
	100,70	101,15	10185,81	64,9	6,37		
0,24	100,29	104,46	10476,29	191,2	18,25		20,66
	104,60	100,38	10499,75	222,8	21,22		
0,24/0,27	100,27	103,58	10385,97	233,9	22,52		
	100,15	102,12	10227,32	263,3	25,74		
0,27	103,49	100,57	10407,99	244,7	23,51	25,16	
	100,90	100,90	10180,81	267,1	26,24		
0,30	100,20	100,63	10083,13	533,2	52,88	54,23	
	101,27	100,48	10175,61	584,4	57,43		
0,30/0,33	100,70	100,55	10125,39	530,3	52,37		
	100,33	100,00	10033,00	769,7	76,72		
0,33	100,48	101,67	10215,80	727,7	71,23	74,74	
	100,13	100,84	10097,11	770,2	76,28		
0,36	100,66	99,91	10056,94	896,5	89,14	89,20	
	100,50	100,83	10133,42	916,7	90,46		
0,36/0,40	100,53	103,75	10429,99	917,8	88,00		
	99,83	101,70	10152,71	862,5	84,95		
0,40	100,00	101,75	10175,00	853,8	83,91	84,59	
	100,50	102,21	10272,11	872,3	84,92		
0,45	100,25	101,63	10188,41	730,0	71,65	73,06	
	99,55	101,51	10105,32	745,2	73,74		
0,45/0,50	100,00	102,25	10225,00	754,6	73,80		
	100,27	102,33	10260,63	592,5	57,74		
0,50	100,60	102,63	10324,58	566,3	54,85	56,07	
	99,27	101,88	10113,63	562,6	55,63		

### 2.5.2. Beton z domieszką Nr 2 w ilości 1%

Tabela 2.19. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 1% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	102,45	100,04	10249,10	110,5	10,78	9,89
	100,50	100,57	10107,29	96,8	9,58	
0,21/0,24	99,97	101,65	10161,95	94,5	9,30	70,75
	100,00	99,97	9997,00	715,5	71,57	
0,24	99,94	101,57	10150,91	695,6	68,53	80,08
	100,12	101,24	10136,15	731,5	72,17	
0,27	100,11	101,92	10203,21	826,0	80,95	80,08
	100,18	101,78	10196,32	824,7	80,88	
0,27/0,30	100,36	101,13	10149,41	795,8	78,41	77,39
	100,25	99,82	10006,96	796,2	79,56	
0,30	100,33	100,61	10094,20	749,8	74,28	77,39
	100,28	100,42	10070,12	788,8	78,33	
0,33	100,32	100,10	10042,03	776,2	77,30	77,37
	100,11	100,03	10014,00	803,9	80,28	
0,33/0,36	100,78	101,63	10242,27	763,3	74,52	74,92
	100,74	99,99	10072,99	757,9	75,24	
0,36	100,26	101,11	10137,29	756,8	74,66	74,92
	100,44	100,51	10095,22	755,7	74,86	
0,40	99,89	101,00	10088,89	663,3	65,75	64,41
	100,43	101,65	10208,71	646,6	63,34	
0,4/0,45	100,57	101,21	10178,69	652,8	64,13	53,65
	100,40	99,04	9943,62	533,6	53,66	
0,45	100,43	100,38	10081,16	547,2	54,28	53,65
	100,99	99,06	10004,07	530,4	53,02	
0,50	100,21	100,39	10060,08	406,7	40,43	40,73
	98,37	100,47	9883,23	397,1	40,18	
0,50 x1	100,22	100,80	10102,18	420,2	41,59	

Tabela 2.20. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 1 % z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,29	101,59	10188,46	151,8	14,90	14,73
	100,44	98,00	9843,12	129,1	13,12	
0,21 x1	100,24	100,50	10074,12	162,8	16,16	
0,24	100,25	102,05	10230,51	989,9	96,76	97,04
	99,69	100,64	10032,80	991,7	98,85	
0,24/0,45	100,18	103,15	10333,57	986,9	95,50	
	97,27	100,94	9818,43	928,6	94,58	
0,27	100,34	103,40	10375,16	1060,3	102,20	
	99,62	102,38	10199,10	991,0	97,17	
0,27/0,40	100,26	102,81	10307,73	1031,4	100,06	85,07
	99,94	100,38	10031,98	856,9	85,42	
0,30	100,10	103,07	10317,31	905,0	87,72	
	100,12	103,05	10317,37	862,3	83,58	
0,30	100,66	104,71	10540,11	880,9	83,58	84,23
	100,40	103,01	10342,20	902,0	87,22	
0,33	100,15	101,72	10187,26	853,6	83,79	
	100,14	101,71	10185,24	870,7	85,49	
0,33/0,50	100,23	102,01	10224,46	852,9	83,42	75,08
	99,48	98,99	9847,53	769,6	78,15	
0,36	100,52	98,78	9929,37	795,5	80,12	
	100,33	99,04	9936,68	786,0	79,10	
0,36	101,48	100,39	10187,58	780,1	76,57	44,99
	100,21	98,72	9892,73	742,3	75,03	
0,40	100,18	99,52	9969,91	691,6	69,37	
	100,38	100,51	10089,19	710,8	70,45	
0,45	100,18	101,54	10172,28	664,7	65,34	44,99
	100,20	101,84	10204,37	439,6	43,08	
0,50	100,67	104,03	10472,70	484,3	46,24	
	100,38	102,20	10258,84	468,2	45,64	

### 2.5.3. Beton z domieszką Nr 2 w ilości 3%

Tabela 2.21. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 3% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,45	102,47	10293,11	765,3	74,35	72,10
	100,38	106,04	10644,30	760,2	71,42	
0,21/0,24	100,43	101,10	10153,47	716,1	70,53	79,32
	100,27	102,85	10312,77	841,6	81,61	
0,24	100,46	105,77	10625,65	815,7	76,77	82,34
	100,21	102,33	10254,49	816,0	79,57	
0,27	100,41	101,61	10202,66	817,8	80,16	86,25
	100,22	100,79	10101,17	823,9	81,56	
0,27/0,30	100,30	99,44	9973,83	850,8	85,30	79,64
	100,34	101,66	10200,56	876,2	85,90	
0,30	100,40	100,62	10102,25	855,3	84,66	75,91
	100,32	101,25	10157,40	895,9	88,20	
0,33	100,21	99,35	9955,86	800,1	80,36	59,96
	100,60	99,70	10029,82	791,4	78,90	
0,33/0,36	100,14	98,60	9873,80	786,6	79,67	47,39
	100,40	97,91	9830,16	747,1	76,00	
0,36	97,49	100,36	9784,10	731,1	74,72	39,88
	100,22	97,33	9754,41	751,1	77,00	
0,40	100,27	101,44	10171,39	616,3	60,59	72,10
	100,48	100,39	10087,19	618,3	61,30	
0,40/0,45	100,36	100,11	10047,04	582,6	57,99	79,32
	100,14	98,27	9840,76	428,5	43,54	
0,45	100,35	96,48	9681,77	470,6	48,61	72,10
	100,57	101,04	10161,59	508,3	50,02	
0,50	100,69	100,94	10163,65	385,6	37,94	72,10
	100,70	102,60	10331,82	425,0	41,14	
0,50 x1	100,30	102,45	10275,74	416,9	40,57	72,10

Tabela 2.22. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 3% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,42	100,77	10119,32	987,5	97,59	96,25
	99,95	102,57	10251,87	980,2	95,61	
0,21/0,24	100,35	102,70	10305,95	984,9	95,57	105,05
	100,32	103,16	10349,01	1080,9	104,44	
0,24	100,43	100,52	10095,22	1093,3	108,30	102,01
	100,83	104,31	10517,58	1077,2	102,42	
0,27	100,42	101,20	10162,50	1007,5	99,14	94,75
	100,19	101,37	10156,26	1046,9	103,08	
0,27/0,30	100,27	100,73	10100,20	1048,6	103,82	84,54
	100,48	101,31	10179,63	939,1	92,25	
0,30	100,18	100,83	10101,15	986,7	97,68	81,66
	100,33	101,79	10212,59	963,1	94,31	
0,33	100,29	107,09	10740,06	848,1	78,97	61,85
	100,30	102,33	10263,70	902,2	87,90	
0,33/0,36	99,93	104,58	10450,68	906,7	86,76	48,50
	100,62	101,21	10183,75	866,1	85,05	
0,36	99,98	103,14	10311,94	774,8	75,14	22,13
	100,41	103,18	10360,30	878,5	84,79	
0,40	100,27	104,49	10477,21	686,7	65,54	20,82
	100,49	106,32	10684,10	650,0	60,84	
0,40/0,45	100,25	102,79	10304,70	609,6	59,16	21,27
	100,79	101,68	10248,33	664,8	64,87	
0,45	100,37	106,34	10673,35	355,6	33,32	24,29
	100,35	104,13	10449,45	494,4	47,31	
0,50	100,61	101,47	10208,90	217,1	21,27	20,82
	100,53	101,21	10174,64	247,2	24,29	
0,50 x1	100,01	101,37	10138,01	211,1	20,82	

### 2.5.4. Beton z dodatkiem pyłu krzemionkowego w ilości 5%

Tabela 2.23. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 5% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,32	100,67	10099,21	5,92	0,59	0,5
	99,95	102,57	10251,87	6,54	0,64	
0,21/0,24	100,42	100,77	10119,32	2,04	0,20	1,55
	99,95	102,57	10251,87	15,86	1,55	
0,24	100,27	103,40	10367,92	16,11	1,55	81,29
	100,02	102,14	10216,04	15,97	1,56	
0,27	100,27	103,40	10367,92	805,9	77,73	81,29
	100,02	102,14	10216,04	843,0	82,52	
0,27/0,30	101,91	97,35	9920,94	829,6	83,62	81,96
	100,74	94,97	9567,28	807,0	84,35	
0,30	100,34	100,36	10070,12	789,1	78,36	85,19
	101,09	95,43	9647,02	802,2	83,16	
0,33	100,55	95,20	9572,36	851,2	88,92	85,19
	100,26	98,46	9871,60	786,5	79,67	
0,33 x1	100,18	98,58	9875,74	859,0	86,98	78,86
0,36	100,29	95,04	9531,56	754,4	79,15	78,86
	100,40	97,79	9818,12	784,3	79,88	
0,36/0,40	100,36	96,55	9689,76	751,4	77,55	68,28
	100,39	97,12	9749,88	663,7	68,07	
0,40	100,15	97,65	9779,65	666,1	68,11	57,32
	100,28	95,86	9612,84	659,9	68,65	
0,45	100,42	97,71	9812,04	564,1	57,49	57,32
	100,49	99,19	9967,60	588,1	59,00	
0,45/0,5	101,21	98,91	10010,68	555,2	55,46	45,64
	100,97	99,37	10033,39	460,7	45,92	
0,50	100,33	99,28	9960,76	445,2	44,70	45,64
	100,42	95,40	9580,07	443,5	46,29	



Tabela 2.24. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 5% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,42	100,77	10119,32	8,8	0,86	0,75
	99,95	102,57	10251,87	8,0	0,78	
0,21/0,24	99,10	99,89	9899,10	6,0	0,60	1,48
	100,38	101,81	10219,69	19,4	1,90	
0,24	100,21	102,46	10267,52	14,6	1,42	
	100,24	102,64	10288,63	11,6	1,13	
0,27	100,21	102,46	10267,52	944,6	92,00	93,88
	100,04	101,64	10168,07	981,6	96,54	
0,27 x1	100,11	101,36	10147,15	944,6	93,09	
0,30	100,65	100,33	10098,21	829,9	82,18	80,92
	100,28	100,20	10048,06	780,7	77,70	
0,30/0,33	100,62	100,30	10092,19	836,3	82,87	
	100,75	99,59	10033,69	767,2	76,46	
0,33	100,80	98,50	9928,80	844,3	85,04	68,98
	99,95	98,50	9845,08	820,3	83,32	
0,36	100,28	101,71	10199,48	701,9	68,82	70,64
	100,53	102,07	10261,10	685,6	66,82	
0,36/0,40	100,34	100,18	10052,06	716,8	71,31	40,42
	100,79	99,89	10067,91	794,5	78,91	
0,40	100,00	100,14	10014,00	687,6	68,66	32,89
	101,85	101,00	10286,85	662,0	64,35	
0,45	100,15	101,76	10191,26	393,8	38,64	32,89
	100,11	101,28	10139,14	440,9	43,48	
0,45/0,5	100,13	100,86	10099,11	395,1	39,12	32,89
	100,31	101,79	10210,55	338,7	33,17	
0,50	100,13	101,65	10178,21	316,8	31,13	32,89
	101,15	100,84	10199,97	350,7	34,38	

### 2.5.5. Beton z dodatkiem pyłu krzemionkowego w ilości 15%

Tabela 2.25. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 15% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21						0,09
	101,07	100,11	10118,12	0,9	0,09	
0,21	100,06	100,61	10067,04	0,8	0,08	0,09
	99,97	102,42	10238,93	0,9	0,09	
0,24	100,22	100,87	10109,19	10,3	1,02	1,00
	100,19	99,90	10008,98	11,2	1,12	
0,24/0,27	100,72	98,48	9918,91	8,4	0,85	3,34
	100,16	101,20	10136,19	36,2	3,57	
0,27	100,61	100,10	10071,06	27,8	2,76	3,34
	100,51	98,98	9948,48	36,7	3,69	
0,30 x1						83,46
	100,07	100,01	10008,00	859,9	85,92	
0,30	100,19	102,66	10285,51	865,8	84,18	83,46
	99,95	102,32	10226,88	820,9	80,27	
0,33 x1						83,19
	100,19	99,90	10008,98	825,9	82,52	
0,33	100,72	98,48	9918,91	868,3	87,54	83,19
	100,16	101,20	10136,19	806,1	79,53	
0,36	100,13	100,90	10103,12	759,5	75,17	74,49
	100,04	99,86	9989,99	712,5	71,32	
0,36/0,40	98,48	100,28	9875,57	760,1	76,97	67,82
	100,29	98,25	9853,49	674,6	68,46	
0,40	100,08	99,26	9933,94	720,9	72,57	67,82
	100,03	99,06	9908,97	618,7	62,44	
0,45	100,36	100,15	10051,05	588,9	58,59	56,70
	100,75	99,35	10009,51	562,9	56,24	
0,45/0,5	101,24	98,32	9953,92	550,3	55,28	43,36
	100,83	97,80	9861,17	390,8	39,63	
0,50	100,43	97,53	9794,94	446,9	45,63	43,36
	100,77	97,96	9871,43	442,5	44,83	

Tabela 2.26. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 15% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,14	101,50	10164,21	1,2	0,12	0,10
	103,26	100,28	10354,91	1,9	0,18	
0,21/0,24	100,73	100,00	10073,00	0,1	0,01	1,34
	99,95	100,45	10039,98	16,4	1,63	
0,24	101,71	102,30	10404,93	10,9	1,05	42,65
	100,27	100,60	10087,16	13,6	1,35	
0,27	100,53	100,82	10135,43	427,8	42,21	92,17
	99,83	101,74	10156,70	436,7	43,00	
0,27	100,26	102,78	10304,72	427,8	41,51	91,47
	100,51	98,98	9948,48	436,7	43,90	
0,30	100,24	102,46	10270,59	917,3	89,31	77,56
	100,19	102,90	10309,55	957,1	92,84	
0,30/0,33	100,21	101,52	10173,32	960,1	94,37	76,49
	100,21	102,45	10266,51	926,4	90,24	
0,33	100,19	101,48	10167,28	905,9	89,10	40,80
	100,18	98,65	9882,76	939,5	95,06	
0,36	100,61	100,10	10071,06	827,8	82,20	52,89
	100,51	98,98	9948,48	736,7	74,05	
0,36/0,40	100,48	100,24	10072,12	769,9	76,44	52,89
	100,00	99,09	9909,00	858,1	86,60	
0,40	100,74	99,58	10031,69	710,8	70,86	52,89
	100,19	98,67	9885,75	711,8	72,00	
0,45	100,19	101,56	10175,30	360,8	35,46	52,89
	100,28	101,31	10159,37	398,7	39,24	
0,45/0,50	100,65	102,13	10279,38	490,3	47,70	52,89
	100,43	99,81	10023,92	518,4	51,72	
0,50	100,39	101,16	10155,45	548,7	54,03	52,89
	100,70	101,11	10181,78	538,8	52,92	

### 3. CEM II/A-M (S- LL) 52,5 N

#### 3.1. KLASA WYTRZYMAŁOŚCIOWA SPOIWA

Tabela 3.1. Wyniki wytrzymałości na ściskanie zapraw po 7 i 28 dniach dla stosunku w/s = 0,5

Lp.	Rodzaj zaprawy	7 dni	28 dni	7 dni	28 dni
		kN	kN	MPa	MPa
1	bez dodatków	62,8	87,2	40,4	55,4
		66,8	90,0		
		64,4	85,2		
		65,4	90,2		
		60,6	90,0		
		67,6	89,4		
2	z domieszką CHRYSO Fluid Premia 380 w ilości 0,8%	72,8	92,0	44,4	61,3
		71,4	99,0		
		72,0	98,2		
		70,2	98,8		
		69,2	100,0		
		70,8	100,0		
3	z domieszką CHRYSO Plast 209 w ilości 0,5%	59,0	80,8	34,0	50,9
		49,4	80,4		
		55,2	84,6		
		53,6	79,4		
		52,6	80,8		
		56,2	82,8		
4	z dodatkiem pyłu krzemionkowego w ilości 5%	55,0	79,8	36,3	51,9
		61,0	81,4		
		57,4	83,0		
		55,6	84,6		
		59,0	83,6		
		60,4	85,6		
5	z dodatkiem pyłu krzemionkowego w ilości 15%	51,2	77,8	32,9	47,1
		50,0	76,8		
		48,2	77,4		
		54,6	72,8		
		55,0	71,6		
		56,6	75,4		

## 3.2. WODOŻĄDNOŚĆ NORMOWA I CZAS WIĄZANIA

### 3.2.1. Zaprawa bez domieszek

Ilość cementu: 500 [g]

Ilość wody: 155 [g]

Wodożądność normowa: 0,310

Tabela 3.2. Czas wiązania próbek zapraw bez domieszek

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	168	263
2	208	303

### 3.2.2. Zaprawa z domieszką Nr 2 w ilości 0,8%

Ilość cementu: 500 [g]

Ilość wody: 120,36 [g]

Ilość superplastyfikatora: 4 [g]

Wodożądność normowa: 0,240

Tabela 3.3. Czas wiązania próbek zapraw z domieszką Nr 2 w ilości 0,8%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	213	307
2	207	292

### 3.2.3. Zaprawa z domieszką Nr 1 w ilości 0,5%

Ilość cementu: 500 [g]

Ilość wody: 143 [g]

Ilość plastyfikatora: 2,5 [g]

Wodożądność normowa: 0,286

Tabela 3.4. Czas wiązania próbek zapraw z domieszką Nr 1 w ilości 0,5%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	229	308
2	248	338

### 3.2.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5%

Ilość cementu: 475 [g]

Ilość wody: 160 [g]

Ilość dodatku: 25 [g]

Wodożądność normowa: 0,320

Tabela 3.5. Czas wiązania próbek zapraw z dodatkiem pyłu krzemionkowego w ilości 5%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	193	241
2	148	195

### 3.2.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15%

Ilość cementu: 425 [g]

Ilość wody: 181,5 [g]

Ilość dodatku: 75 [g]

Wodożądność normowa: 0,363

Tabela 3.6. Czas wiązania próbek zapraw z dodatkiem pyłu krzemionkowego w ilości 15%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	133	170
2	143	181

### 3.3. GĘSTOŚĆ POZORNA ŚWIEŻEGO ZACZYNU

#### 3.3.1. Zaczyn bez domieszek

Tabela 3.7. Gęstość pozorna zaczynu bez domieszek

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,21	272,22	2,27	1,30
		270,42		
2	0,24	394,20	2,20	1,89
		392,61		
3	0,27	452,30	2,14	2,17
		452,48		
4	0,30	436,82	2,09	2,11
		436,34		
5	0,33	426,54	2,04	2,05
		427,00		
6	0,36	416,92	1,99	2,0
		416,82		
7	0,40	405,26	1,94	1,95
		405,57		
8	0,45	394,56	1,88	1,90
		395,78		
9	0,50	381,11	1,82	1,83
		380,38		

### 3.3.2. Zaczyn z domieszką Nr 2 w ilości 0,8%

Tabela 3.8. Gęstość pozorna zaczynu z domieszką Nr 2 w ilości 0,8%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,15	365,12	2,43	1,75
		363,31		
2	0,18	431,86	2,35	2,07
		431,22		
3	0,21	447,70	2,27	2,16
		452,51		
4	0,24	442,55	2,20	2,15
		450,10		
5	0,27	441,60	2,14	2,13
		443,04		
6	0,30	430,09	2,09	2,07
		429,95		
7	0,33	412,72	2,04	1,98
		412,61		
8	0,36	402,07	1,99	1,93
		399,59		
9	0,40	388,65	1,94	1,87
		388,48		
10	0,45	373,79	1,88	1,80
		375,36		
11	0,50	365,77	1,82	1,75
		362,12		



### 3.3.3. Zaczyn z domieszką Nr 2 w ilości 3%

Tabela 3.9. Gęstość pozorna zaczynu z domieszką Nr 2 w ilości 3%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,15	432,81	2,43	2,08
		431,87		
2	0,18	482,19	2,35	2,32
		483,79		
3	0,21	451,85	2,27	2,18
		453,35		
4	0,24	432,28	2,20	2,07
		431,16		
5	0,27	431,36	2,14	2,07
		429,83		
6	0,30	415,60	2,09	2,00
		414,95		
7	0,33	402,94	2,04	1,94
		404,88		
8	0,36	391,33	1,99	1,88
		390,17		
9	0,40	381,24	1,94	1,83
		380,56		
10	0,45	360,12	1,88	1,73
		360,52		
11	0,50	367,03	1,82	1,76
		365,92		

### 3.3.4. Zaczyn z domieszką Nr 1 w ilości 0,5%

Tabela 3.10. Gęstość pozorna zaczynu z domieszką Nr 1 w ilości 0,5%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,21	271,52	2,27	1,31
		271,58		
2	0,24	423,64	2,20	2,04
		424,42		
3	0,27	439,24	2,14	2,11
		439,33		
4	0,30	431,65	2,09	2,08
		432,52		
5	0,33	422,60	2,04	2,03
		423,22		
6	0,36	412,24	1,99	1,98
		412,44		
7	0,40	405,36	1,94	1,95
		404,72		
8	0,45	386,52	1,88	1,86
		386,54		
9	0,50	381,11	1,82	1,83
		381,68		

### 3.4. WYTRZYMAŁOŚĆ NA ŚCISKANIE ZAPRAWY

#### 3.4.1. Zaprawa bez domieszek

Tabela 3.11. Wytrzymałość na ściskanie zaprawy bez domieszek

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	3,4	2,1	2,7
		5,3	3,3	
		4,5	2,8	
		4,6	2,9	
		5,0	3,1	
		3,4	2,1	
2	0,24	21,4	13,4	10,9
		16,0	10	
		15,8	9,9	
		18,6	11,6	
		13,3	8,3	
		19,8	12,4	
3	0,27	25,3	15,8	12,6
		19,4	12,1	
		17,6	11	
		19,4	12,1	
		18,1	11,3	
		21,1	13,2	
4	0,30	32,0	20	18,8
		40,5	25,3	
		15,4	9,4	
		29,0	18,1	
		35,0	21,9	
		29,0	18,1	
5	0,33	23,0	14,4	15,7
		26,6	16,6	
		23,5	14,7	
		25,4	15,9	
		25,4	15,9	
		27,0	16,9	

CD. Tabela 3.11. Wytrzymałość na ściskanie zaprawy bez domieszek

6	0,36	77,0	48,1	50,0
		76,0	47,5	
		82,6	51,6	
		78,6	49,1	
		80,0	50	
		86,1	53,8	
7	0,40	68,0	42,5	43,85
		68,5	42,8	
		70,1	43,8	
		71,0	44,4	
		72,0	45	
		71,5	44,7	
	0,45	71,0	44,4	41,7
		62,6	39,1	
		65,0	40,6	
		68,5	42,8	
		63,0	39,4	
		70,1	43,8	
9	0,50	72,0	45	43,3
		66,6	41,6	
		68,0	42,5	
		69,4	43,4	
		69,0	43,1	
		70,1	43,8	

### 3.4.2. Zaprawa z domieszką Nr 2 w ilości 0,8%

Tabela 3.12. Wytrzymałość na ściskanie zaprawy z domieszką Nr 2 w ilości 0,8%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	26,1	16,3	18,0
		29,0	18,1	
		32,0	20,0	
		30,6	19,1	
		26,1	16,3	
		29,0	18,1	
2	0,24	118,1	73,8	75,3
		116,6	72,5	
		119,3	74,4	
		124,2	77,5	
		127,2	79,4	
		119,1	74,4	
3	0,27	129,3	80,6	80,7
		129,4	80,9	
		125,0	78,1	
		130,1	81,3	
		129,0	80,6	
		132,0	82,5	
4	0,30	127	79,4	76,6
		121,0	75,6	
		126,0	78,8	
		120,5	75,3	
		120,0	75,0	
		121,0	75,6	
5	0,33	118,1	73,8	74,9
		117,0	73,1	
		120,5	75,3	
		119,0	74,4	
		120,0	75,0	
		125,0	78,1	
6	0,36	106,1	66,3	65,0
		105,0	65,6	
		105,4	65,9	
		97,0	60,6	
		110,1	68,8	
		100,5	62,8	

CD. Tabela 3.12. Wytrzymałość na ściskanie  
zaprawy z domieszką Nr 2 w ilości 0,8%

7	0,40	69,0	43,1	41,7
		69,0	43,1	
		66,1	41,3	
		62,6	39,1	
		64,5	40,3	
		69,4	43,4	
8	0,45	76,0	47,5	47,1
		80,0	50,0	
		77,4	48,4	
		71,0	44,4	
		71,0	44,4	
		76,5	47,8	
9	0,50	65,0	40,6	39,8
		65,0	40,6	
		57,4	35,9	
		64,0	40,0	
		64,5	40,3	
		66,1	41,3	

### 3.4.3. Zaprawa z domieszką Nr 2 w ilości 3%

Tabela 3.13. Wytrzymałość na ściskanie zaprawy z domieszką Nr 2 w ilości 3%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	125,0	78,1	82,2
		127,0	79,4	
		138,6	86,6	
		132,0	82,5	
		131,5	82,2	
		135,0	84,4	
2	0,24	129,0	80,6	87,2
		144,0	90,0	
		140,0	87,5	
		150,6	94,1	
		135,5	84,7	
		138,1	86,3	
3	0,27	147,0	91,9	91,6
		148,5	92,8	
		154,1	96,3	
		144,0	90,0	
		147,0	91,9	
		139,0	86,9	
4	0,30	127,5	79,7	80,5
		127,0	79,4	
		130,1	81,3	
		125,0	78,1	
		131,0	81,9	
		132,0	82,5	
5	0,33	119,0	74,4	71,5
		116,0	72,5	
		112,5	70,3	
		120,0	75,0	
		108,5	67,8	
		110,1	68,8	
6	0,36	103,0	64,4	63,5
		98,6	61,6	
		102,1	63,8	
		105,0	65,6	
		97,4	60,9	
		104,0	65,0	

CD. Tabela 3.13. Wytrzymałość na ściskanie  
zaprawy z domieszką Nr 2 w ilości 3%

7	0,40	86,1	53,8	56,8
		91,0	56,9	
		94,1	58,8	
		94,1	58,8	
		91,5	57,2	
		89,0	55,6	
8	0,45	62,1	38,8	45,5
		77,0	48,1	
		77,0	48,1	
		76,5	47,8	
		74,6	46,6	
		70,1	43,8	
9	0,50	50,1	31,3	36,3
		61,0	38,1	
		55,0	34,4	
		57,4	35,9	
		65,4	40,9	
		59,0	36,9	



### 3.4.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5%

Tabela 3.14. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 5%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	5,4	3,4	3,3
		5,3	3,3	
		4,8	3	
		5,6	3,5	
		5,4	3,4	
		5,3	3,3	
2	0,24	13,6	8,5	6,6
		10,6	6,6	
		11,4	7,1	
		9,0	5,6	
		10,1	6,3	
		9,3	5,8	
3	0,27	12,0	7,5	7,72
		13,4	8,4	
		14,2	8,9	
		10,1	6,3	
		12,0	7,5	
		12,5	7,8	
4	0,30	25,0	15,6	14,7
		25,0	15,6	
		19,8	12,4	
		20,0	12,5	
		21,1	13,2	
		24,0	15,0	
5	0,33	48,0	30,0	29,3
		58,6	36,6	
		38,1	23,8	
		44,2	27,6	
		48,5	30,3	
		44,0	27,5	
6	0,36	64,0	40,0	40,4
		71,5	44,7	
		71,5	44,7	
		65,0	40,6	
		60,0	37,5	
		56,0	35,0	

CD. Tabela 3.14. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 5%

7	0,40	58,6	36,6	40,3
		67,5	42,2	
		66,1	41,3	
		61	38,1	
		66,1	41,3	
		67,0	41,9	
8	0,45	90,1	56,3	56,4
		95,0	59,4	
		89,0	55,6	
		90,1	56,3	
		89,4	55,9	
		88,0	55,0	
9	0,50	63,0	39,4	43,7
		67,5	42,2	
		68,0	42,5	
		70,1	43,8	
		77,0	48,1	
		74,1	46,3	

### 3.4.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15%

Tabela 3.15. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 15%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	4,0	2,5	2,7
		3,8	2,4	
		4,2	2,6	
		4,8	3,0	
		4,8	3,0	
		4,6	2,9	
2	0,24	10,6	6,6	6,4
		10,8	6,8	
		9,6	6,0	
		7,2	4,5	
		10,6	6,6	
		13,0	8,1	
3	0,27	6,8	4,3	3,7
		6,8	4,3	
		6,4	4,0	
		5,8	3,6	
		6,3	3,9	
		3,7	2,3	
4	0,30	15,0	9,4	10,8
		15,8	9,9	
		16,2	10,1	
		22,0	13,8	
		17,8	11,1	
		17,2	10,8	
5	0,33	27,0	16,9	17,6
		28,0	17,5	
		30,1	18,8	
		26,1	16,3	
		27,5	17,2	
		30,1	18,8	
6	0,36	51,0	31,9	39,6
		59,0	36,9	
		63,0	39,4	
		69,4	43,4	
		66,1	41,3	
		72,0	45,0	

CD. Tabela 3.15. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 15%

7	0,40	46,6	29,1	38,1
		60,0	37,5	
		64,5	40,3	
		62,1	38,8	
		61,0	38,1	
		72,0	45,0	
8	0,45	62,5	39,1	40,6
		65,0	40,6	
		63,0	39,4	
		64,0	40,0	
		68,5	42,8	
		66,6	41,6	
9	0,50	70,6	44,1	40,7
		63,5	39,7	
		58,1	36,3	
		64,0	40,0	
		71,0	44,4	
		64,0	40,0	

### 3.5. WYTRZYMAŁOŚĆ BETONU NA ŚCISKANIE

#### 3.5.1. Beton bez domieszek

Tabela 3.16. Wytrzymałość na ściskanie betonu bez domieszek z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	99,95	98,25	9820,09	126,2	12,85	10,91
	100,40	91,76	9212,70	106,9	11,60	
0,21/0,24	100,28	99,53	9980,87	82,5	8,27	60,27
	100,26	102,04	10230,53	582,1	56,90	
0,24	100,25	100,90	10115,23	644,3	63,70	60,20
	100,33	103,14	10348,04	623,0	60,20	
0,27	100,36	102,71	10307,98	750,3	72,79	74,83
	100,02	101,77	10179,04	752,9	73,97	
0,27/0,30	100,32	101,15	10147,37	788,8	77,73	73,75
	99,30	100,57	9986,60	743,5	74,45	
0,30	99,47	101,92	10137,98	730,9	72,10	74,72
	100,85	101,60	10246,36	765,6	74,72	
0,33	100,22	100,87	10109,19	731,4	72,35	72,40
	99,99	102,85	10283,97	762,5	74,14	
0,33/0,36	100,20	99,90	10009,98	707,9	70,72	90,68
	100,24	101,91	10215,46	940,4	92,06	
0,36	100,15	102,90	10305,44	923,4	89,60	90,37
	100,21	100,76	10097,16	912,5	90,37	
0,40 x1						84,22
	100,30	102,45	10275,74	840,5	81,79	
0,40	100,01	101,33	10134,01	873,1	86,16	84,70
	100,07	104,35	10442,30	884,5	84,70	
0,45	99,92	102,66	10257,79	572,4	55,80	52,00
	100,39	97,80	9818,14	465,4	47,40	
0,45/0,50	100,20	103,01	10321,60	545,0	52,80	48,69
	100,32	98,29	9860,45	468,1	47,47	
0,50	100,69	100,94	10163,65	485,6	47,78	50,81
	100,70	102,60	10331,82	525,0	50,81	

Tabela 3.17. Wytrzymałość na ściskanie betonu bez domieszek z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,27	100,60	10087,16	183,2	18,16	15,44
	100,53	100,82	10135,43	146,9	14,49	
0,21 x1						15,44
	100,30	102,45	10275,74	140,5	13,67	
0,24	100,27	100,60	10087,16	83,2	8,25	8,46
	100,53	100,82	10135,43	86,9	8,57	
0,24/0,27	99,83	101,74	10156,70	86,8	8,55	86,11
	100,26	102,78	10304,72	903,6	87,69	
0,27	100,14	101,50	10164,21	899,7	88,52	86,11
	103,26	100,28	10354,91	850,4	82,13	
0,30	100,73	100,00	10073,00	894,1	88,76	93,14
	99,95	100,45	10039,98	931,9	92,82	
0,30 x1	101,71	102,30	10404,93	1018,0	97,84	93,14
0,33	100,40	103,01	10342,20	902,0	87,22	93,84
	100,30	101,41	10171,42	1007,7	99,07	
0,33/0,36	100,05	100,20	10025,01	954,7	95,23	86,40
	100,14	101,95	10209,27	776,7	76,08	
0,36	100,34	98,88	9921,62	928,6	93,59	86,40
	100,49	100,17	10066,08	901,3	89,54	
0,40	100,14	100,37	10051,05	806,9	80,28	75,20
	100,21	98,72	9892,73	742,3	75,03	
0,40 x1	100,13	100,68	10081,09	708,7	70,30	75,20
0,45	100,60	101,60	10220,96	712,2	69,68	69,81
	100,14	98,71	9884,82	704,1	71,23	
0,45/0,50	100,03	100,21	10024,01	686,7	68,51	52,81
	101,26	100,78	10204,98	518,7	50,83	
0,50 x1	99,10	99,89	9899,10	545,6	55,12	52,81
	100,16	101,88	10204,30	535,6	52,49	

### 3.5.2. Beton z domieszką Nr 2 w ilości 1%

Tabela 3.18. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 1% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,58	100,29	10087,17	73,5	7,29	7,88
	100,15	100,24	10039,04	62,5	6,21	
0,21/0,24	100,33	100,95	10128,31	102,5	10,12	25,41
	101,65	100,21	10186,35	267,8	26,29	
0,24	105	100,28	10529,40	301,2	28,61	25,41
	104,93	100,28	10522,38	224,4	21,33	
0,27	100,26	101,08	10134,28	797,3	78,67	77,91
	100,79	100,49	10128,39	814,2	80,39	
0,27/0,30	99,97	102,5	10246,93	765	74,66	75,78
	100,35	99,7	10004,90	728,4	72,80	
0,30	102,67	100,34	10301,91	782,8	75,99	75,78
	100,18	101,87	10205,34	801,6	78,55	
0,33	100,82	100,27	10109,22	735,2	72,73	73,87
	100,5	101,25	10175,63	760,6	74,75	
0,33/0,36	102,17	100,3	10247,65	759,6	74,12	75,76
	100,51	99,38	9988,68	776,6	77,75	
0,36	100,43	101,1	10153,47	760,5	74,90	75,76
	100,5	100,02	10052,01	750,1	74,63	
0,40	100,35	97,55	9789,14	708,2	72,35	69,40
	99,2	100,35	9954,72	688,7	69,18	
0,40 x1	102,13	100,37	10250,79	683,4	66,66	69,40
0,45	100,57	101,21	10178,69	552,8	54,31	54,08
	100,40	99,04	9943,62	531,6	53,46	
0,45/50	100,43	100,38	10081,16	549,2	54,48	41,21
	100,99	99,06	10004,07	430,4	43,02	
0,50	100,21	100,39	10060,08	406,7	40,43	41,21
	98,37	100,47	9883,23	397,1	40,18	

Tabela 3.19. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 1% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	101,68	100,75	10244,26	156,6	15,29	15,12
	99,96	99,62	9958,02	159,5	16,02	
0,21/0,24	100,20	103,01	10321,60	145,0	14,05	76,29
	103,52	100,26	10378,92	796,9	76,78	
0,24	101,68	100,75	10244,26	776,6	75,81	76,29
	99,96	99,62	9958,02	759,5	76,27	
0,27	99,41	100,19	9959,89	941,7	94,55	94,57
	100,45	101,4	10185,63	970,2	95,25	
0,27/0,30	101,74	100,23	10197,40	957,7	93,92	88,99
	100	100,35	10035,00	898,4	89,53	
0,30	101,72	100,14	10186,24	916,6	89,98	88,99
	100,16	100,05	10021,01	876,3	87,45	
0,33	100,61	100,4	10101,24	889,9	88,10	89,62
	100,52	97,41	9791,65	915,5	93,50	
0,33/0,36	100,3	100,15	10045,05	876,6	87,27	85,69
	101,2	100,57	10177,68	881,9	86,65	
0,36	100,36	100,13	10049,05	845,5	84,14	85,69
	100,35	100,23	10058,08	867,8	86,28	
0,40	102,13	100,37	10250,79	583,4	56,91	63,84
	103,4	100,93	10436,16	587,2	56,27	
0,40 x1	99,86	101,68	10153,76	795,6	78,36	63,84
0,40	100,18	99,52	9969,91	591,6	59,34	61,40
	100,38	100,51	10089,19	610,4	60,50	
0,45	100,18	101,54	10172,28	654,6	64,35	51,80
	100,20	101,84	10204,37	539,6	52,88	
0,50	100,67	104,03	10472,70	524,3	50,06	51,80
	100,38	102,20	10258,84	538,2	52,46	



### 3.5.3. Beton z domieszką Nr 2 w ilości 3%

Tabela 3.20. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 3% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,52	102,76	10329,44	906,0	87,71	88,79
	100,09	102,35	10244,21	909,1	88,74	
0,21/0,24	100,25	101,00	10125,25	910,4	89,91	85,32
	100,16	102,81	10297,45	884,3	85,88	
0,24	100,24	101,60	10184,38	859,7	84,41	85,32
	100,36	101,17	10153,42	869,7	85,66	
0,27	100,20	100,18	10038,04	915,5	91,20	92,27
	100,24	100,99	10123,24	926,4	91,51	
0,27/0,30	100,39	99,65	10003,86	941,3	94,09	94,20
	100,34	98,62	9895,53	925,7	93,55	
0,30	100,25	98,96	9920,74	935,9	94,34	94,20
	100,26	97,96	9821,47	930,1	94,70	
0,33	100,15	97,77	9791,67	748,1	76,40	80,26
	100,20	100,07	10027,01	856,4	85,41	
0,33/0,36	100,28	99,39	9966,83	787,2	78,98	71,21
	100,46	98,49	9894,31	700,7	70,82	
0,36	100,46	97,08	9752,66	698,1	71,58	71,21
	100,40	99,71	10010,88	713,0	71,22	
0,40	100,32	98,55	9886,54	661,6	66,92	67,64
	99,93	98,70	9863,09	683,9	69,34	
0,40/0,45	100,21	99,35	9955,86	663,6	66,65	54,24
	100,20	99,98	10018,00	531,2	53,02	
0,45	100,14	98,91	9904,85	541,2	54,64	54,24
	100,11	97,92	9802,77	539,7	55,06	
0,50	100,71	98,80	9950,15	431,9	43,41	43,98
	100,54	98,88	9941,40	433,4	43,60	
0,50 x1	100,13	99,30	9942,91	446,8	44,94	43,98

Tabela 3.21. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 3% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,18	100,26	10044,05	930,6	92,65	91,09
	100,10	100,32	10042,03	889,3	88,56	
0,21/0,24	100,56	100,17	10073,10	927,2	92,05	107,45
	100,18	100,16	10034,03	1067,6	106,40	
0,24	99,98	100,27	10024,99	1089,0	108,63	101,27
	99,80	100,32	10011,94	1094,5	107,32	
0,27	99,62	100,71	10032,73	1004,7	100,14	101,27
	99,90	100,33	10022,97	1063,7	103,13	
0,27/0,30	100,00	100,25	10025,00	1028	100,54	90,93
	100,06	100,08	10014,00	1064	106,25	
0,30	100,01	100,79	10080,01	865,3	85,84	90,93
	100,30	101,61	10191,48	822,4	80,69	
0,33	101,08	100,30	10138,32	939,9	92,71	93,96
	102,20	100,35	10255,77	945,1	92,15	
0,33/0,36	100,03	100,51	10054,02	975,3	97,01	74,48
	101,66	100,46	10212,76	832,3	81,50	
0,36	101,75	100,35	10210,61	681,7	66,77	74,48
	100,64	100,40	10104,26	759,6	75,18	
0,40	106,60	100,21	10682,39	658,1	61,61	70,40
	100,86	100,32	10118,28	758,5	74,96	
0,40/0,45	100,58	100,32	10090,19	752,9	74,62	61,00
	100,49	101,68	10217,82	638,7	62,51	
0,45	103,00	100,38	10339,14	624,9	60,44	61,00
	105,97	100,38	10637,27	638,8	60,05	
0,50	100,00	100,14	10014,00	317,1	31,67	31,98
	101,85	101,00	10286,85	347,2	33,75	
0,50 x1	100,15	101,76	10191,26	311,1	30,53	31,98

### 3.5.4. Beton z dodatkiem pyłu krzemionkowego w ilości 5%

Tabela 3.22. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 5% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,28	100,81	10109,23	9,9	0,98	0,75
	100,45	100,51	10096,23	5,8	0,57	
0,21/0,24	100,52	99,95	10046,97	6,9	0,69	1,34
	100,84	100,88	10172,74	10,2	1,00	
0,24	100,31	101,37	10168,42	12,6	1,24	1,34
	100,40	101,10	10150,44	18	1,77	
0,27	103,50	100,40	10391,40	800,5	77,03	77,71
	101,82	100,24	10206,44	794,2	77,81	
0,27/0,30	101,14	100,39	10153,44	794,7	78,27	73,87
	100,11	101,00	10111,11	769,6	76,11	
0,30	101,50	100,18	10168,27	726,2	71,42	73,87
	102,20	100,30	10250,66	759,3	74,07	
0,33	100,22	100,13	10035,03	750,0	74,74	74,01
	100,60	99,97	10056,98	735,5	73,13	
0,33/0,36	100,68	99,75	10042,83	744,7	74,15	73,62
	99,58	100,07	9964,97	718,2	72,07	
0,36	99,11	100,44	9954,61	736,8	74,02	73,62
	99,41	100,17	9957,90	744,6	74,77	
0,40	100,95	100,00	10095,00	733,9	72,70	70,22
	99,50	100,50	9999,75	698,8	69,88	
0,40/0,45	101,60	100,03	10163,05	691,8	68,07	58,58
	101,80	100,54	10234,97	598,7	58,50	
0,45	101,20	100,50	10170,60	583,4	57,36	58,58
	100,15	101,75	10190,26	610,3	59,89	
0,50	100,60	100,60	10120,36	505,1	49,91	50,79
	102,55	100,30	10285,77	512,5	49,83	
0,50 x1	100,60	100,70	10130,42	533,1	52,62	50,79

Tabela 3.23. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 5% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,17	102,38	10255,40	9,2	0,90	0,86
	100,19	101,54	10173,29	8,3	0,82	
0,21/0,24	100,60	100,30	10090,18	8,6	0,85	2,82
	100,49	100,28	10077,14	28,0	2,78	
0,24	100,56	100,22	10078,12	27,5	2,73	94,05
	100,13	100,86	10099,11	29,7	2,94	
0,27	100,29	98,39	9867,53	917,9	93,02	96,98
	101,25	100,53	10178,66	972,5	95,54	
0,27/0,30	102,61	100,31	10292,81	963,4	93,60	95,49
	97,78	100,29	9806,36	973,0	99,22	
0,30	100,58	99,23	9980,55	944,4	94,62	84,40
	100,23	99,50	9972,89	968,4	97,10	
0,33	99,98	100,20	10018,00	958,8	95,71	78,26
	100,00	100,08	10008,00	968,8	96,80	
0,33/0,36	100,33	99,55	9987,85	938,4	93,95	53,48
	98,60	100,14	9873,80	826,8	83,74	
0,36	102,35	100,71	10307,67	867,2	84,13	39,96
	100,05	102,40	10245,12	874,2	85,33	
0,40	100,34	100,28	10062,10	795,0	79,01	78,26
	100,54	100,35	10089,19	791,7	78,47	
0,40 x1	100,60	100,70	10130,42	783,1	77,30	53,48
0,45	101,71	100,20	10191,34	557,9	54,74	53,48
	101,12	100,34	10146,38	491,6	48,45	
0,45/0,50	100,26	100,58	10084,15	577,4	57,26	39,96
	99,98	100,28	10025,99	459,0	45,78	
0,50	100,4	100,51	10091,20	390,3	38,68	39,96
	100,35	101,42	10177,50	360,6	35,43	

### 3.5.5. Beton z dodatkiem pyłu krzemionkowego w ilości 15%

Tabela 3.24. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 15% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21 x1						0,11
	101,07	100,11	10118,12	0,9	0,09	
0,21	100,06	100,61	10067,04	1,1	0,11	0,11
	99,97	102,42	10238,93	1,2	0,12	
0,24	100,22	100,87	10109,19	3,4	0,34	0,38
	100,19	99,90	10008,98	4,1	0,41	
0,24/0,27	100,72	98,48	9918,91	3,8	0,38	12,30
	100,16	101,20	10136,19	106,2	10,48	
0,27	100,61	100,10	10071,06	127,8	12,69	12,30
	100,51	98,98	9948,48	136,7	13,74	
0,30 x1						67,44
	100,20	101,47	10167,29	681,2	67,00	
0,30	101,30	100,36	10166,47	672,2	66,12	67,44
	100,80	100,00	10080,00	697,5	69,20	
0,33	100,53	102,32	10286,23	768,3	74,69	74,98
	100,20	101,42	10162,28	775,4	76,30	
0,33/0,36	99,92	102,21	10212,82	755,3	73,96	78,61
	100,43	99,93	10035,97	798,9	79,60	
0,36	100,16	100,05	10021,01	795,7	79,40	78,61
	100,16	101,35	10151,22	780,0	76,84	
0,40	100,37	101,06	10143,39	734,3	72,39	71,41
	99,84	101,02	10085,84	730,6	72,44	
0,40/0,45	100,03	100,48	10051,01	697,4	69,39	63,29
	100,10	99,48	9957,95	646,5	64,92	
0,45	100,28	100,15	10043,04	607,8	60,52	63,29
	101,63	100,15	10178,24	655,7	64,42	
0,50	100,03	102,30	10233,07	554,0	54,14	51,85
	100,06	101,67	10173,10	535,0	52,59	
0,50 x1	101,92	100,12	10204,23	498,3	48,83	51,85

Tabela 3.25. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 15% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,14	101,50	10164,21	5,2	0,51	0,79
	103,26	100,28	10354,91	9,9	0,96	
0,21/0,24	100,73	100,00	10073,00	9,1	0,90	1,00
	99,95	100,45	10039,98	10,4	1,04	
0,24	101,71	102,30	10404,93	9,9	0,95	1,00
	100,27	100,60	10087,16	10,2	1,02	
0,27	100,21	102,52	10273,53	747,5	72,76	68,78
	100,11	102,85	10296,31	710,4	69,00	
0,27/0,30	100,25	100,14	10039,04	648,3	64,58	81,19
	103,20	100,10	10330,32	853,6	82,63	
0,30	101,38	100,13	10151,18	837,5	82,50	81,19
	100,07	101,49	10156,10	796,6	78,44	
0,33	100,26	100,27	10053,07	897,4	89,27	89,60
	100,99	100,26	10125,26	927,6	91,61	
0,33/0,36	100,42	101,14	10156,48	893,1	87,93	85,57
	100,09	101,01	10110,09	885,5	87,59	
0,36	100,20	101,42	10162,28	861,2	84,74	85,57
	100,18	101,62	10180,29	858,9	84,37	
0,40	99,54	100,20	9973,91	840,3	84,25	81,24
	99,52	99,99	9951,00	832,2	83,63	
0,40/0,45	99,70	100,45	10014,87	759,4	75,83	72,67
	100,52	100,47	10099,24	753,3	74,59	
0,45	99,83	100,18	10000,97	694,2	69,41	72,67
	100,44	100,70	10114,31	748,5	74,00	
0,50	99,80	103,87	10366,23	584,8	56,41	60,91
	101,80	100,19	10199,34	647,3	63,46	
0,50 x1	99,86	102,17	10202,70	641,3	62,86	60,91

#### 4. CEM IV/B(V) 32,5 R - LH/NA

##### 4.1. KLASA WYTRZYMAŁOŚCIOWA SPOIWA

Tabela 4.1. Wyniki wytrzymałości na ściskanie zapraw po 7 i 28 dniach dla stosunku w/s = 0,5

Lp.	Rodzaj zaprawy	7 dni	28 dni	7 dni	28 dni
		MPa	MPa	MPa	MPa
1	bez dodatków	43,6	59,6	28,7	36,3
		44,8	61,0		
		45,8	56,4		
		42,2	56,0		
		50,2	57,4		
		49,0	58,0		
2	z domieszką CHRYSO Fluid Premia 380 w ilości 0,8%	46,0	60,0	29,0	37,9
		47,0	61,0		
		47,6	59,4		
		47,4	61,0		
		45,2	61,8		
		44,8	60,8		
3	z domieszką CHRYSO Plast 209 w ilości 0,5%	45,6	64,2	28,2	39,1
		45,8	58,0		
		44,8	65,2		
		44,8	65,6		
		45,2	61,6		
		44,4	61,2		
4	z dodatkiem pyłu krzemionkowego w ilości 5%	43,2	62,0	27,0	37,1
		44,8	61,4		
		41,8	61,0		
		41,8	58,2		
		43,8	56,8		
		43,6	56,8		
5	z dodatkiem pyłu krzemionkowego w ilości 15%	38,0	52,0	24,3	33,8
		38,0	52,4		
		37,8	55,2		
		39,2	56,2		
		39,8	55,8		
		40,0	53,0		

## 4.2. WODOŻĄDNOŚĆ NORMOWA I CZAS WIĄZANIA

### 4.2.1. Zaprawa bez domieszek

Ilość cementu: 500 [g]  
Ilość wody: 150 [g]  
Wodożądność normowa: 0,3

Tabela 4.2. Czas wiązania próbek zapraw bez domieszek

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	223	294
2	212	283

### 4.2.2. Zaprawa z domieszką Nr 2 w ilości 0,8%

Ilość cementu: 500 [g]  
Ilość wody: 108,25 [g]  
Ilość superplastyfikatora: 4 [g]  
Wodożądność normowa: 0,216

Tabela 4.3. Czas wiązania próbek zapraw z domieszką Nr 2 w ilości 0,8%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	311	386
2	311	376

### 4.2.3. Zaprawa z domieszką Nr 1 w ilości 0,5%

Ilość cementu: 500 [g]  
Ilość wody: 138 [g]  
Ilość plastyfikatora: 2,5 [g]  
Wodożądność normowa: 0,276

Tabela 4.4. Czas wiązania próbek zapraw z domieszką Nr 1 w ilości 0,5%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	446	521
2	443	518



#### 4.2.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5%

Ilość cementu: 475 [g]

Ilość wody: 152 [g]

Ilość dodatku: 25 [g]

Wodożądność normowa: 0,304

Tabela 4.5. Czas wiązania próbek zapraw z dodatkiem pyłu krzemionkowego w ilości 5%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	250	302
2	264	326

#### 4.2.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15%

Ilość cementu: 425 [g]

Ilość wody: 156 [g]

Ilość dodatku: 75 [g]

Wodożądność normowa: 0,312

Tabela 4.6. Czas wiązania próbek zapraw z dodatkiem pyłu krzemionkowego w ilości 15%

Nr próbki	Początek wiązania [min]	Koniec wiązania [min]
1	251	322
2	265	329

### 4.3. GĘSTOŚĆ POZORNA ŚWIEŻEGO ZACZYNU

#### 4.3.1. Zaczyn bez domieszek

Tabela 4.7. Gęstość pozorna zaczynu bez domieszek

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,21	243,91	2,27	1,17
		244,19		
2	0,24	407,50	2,20	1,96
		408,00		
3	0,27	407,49	2,14	1,96
		407,32		
4	0,30	401,90	2,09	1,93
		401,48		
5	0,33	389,15	2,04	1,87
		389,67		
6	0,36	384,70	1,99	1,85
		385,05		
7	0,40	371,20	1,94	1,78
		370,90		
8	0,45	365,12	1,88	1,76
		365,46		
9	0,50	348,04	1,82	1,67
		348,03		

### 4.3.2. Zaczyn z domieszką Nr 2 w ilości 0,8%

Tabela 4.8. Gęstość pozorna zaczynu z domieszką Nr 2 w ilości 0,8%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,15	352,93	2,43	1,69
		350,67		
2	0,18	411,53	2,35	1,98
		411,53		
3	0,21	416,79	2,27	2,00
		417,14		
4	0,24	410,53	2,20	1,97
		410,08		
5	0,27	399,70	2,14	1,92
		399,47		
6	0,30	390,95	2,09	1,88
		391,61		
7	0,33	387,36	2,04	1,86
		388,13		
8	0,36	373,87	1,99	1,80
		374,14		
9	0,40	370,03	1,94	1,78
		369,54		
10	0,45	356,04	1,88	1,71
		356,50		
11	0,50	348,82	1,82	1,68
		349,05		

### 4.3.3. Zaczyn z domieszką Nr 2 w ilości 3%

Tabela 4.9. Gęstość pozorna zaczynu z domieszką Nr 2 w ilości 3%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,15	423,30	2,43	2,04
		424,31		
2	0,18	455,53	2,35	2,19
		455,54		
3	0,21	419,97	2,27	2,02
		420,44		
4	0,24	406,39	2,20	1,95
		405,97		
5	0,27	393,84	2,14	1,89
		394,34		
6	0,30	382,33	2,09	1,84
		382,70		
7	0,33	385,76	2,04	1,85
		386,06		
8	0,36	370,33	1,99	1,78
		369,94		
9	0,40	361,91	1,94	1,74
		361,00		
10	0,45	344,88	1,88	1,66
		344,82		
11	0,50	335,86	1,82	1,61
		335,03		

#### 4.3.4. Zaczyn z domieszką Nr 1 w ilości 0,5%

Tabela 4.10. Gęstość pozorna zaczynu z domieszką Nr 1 w ilości 0,5%

Nr	w/s	Masa pojemnika z zaczynem	Gęstość	
		[g]	Teoretyczna	Rzeczywista
1	0,21	225,99	2,27	1,09
		226,42		
2	0,24	264,58	2,20	1,27
		264,64		
3	0,27	402,08	2,14	1,93
		401,57		
4	0,30	397,66	2,09	1,91
		397,61		
5	0,33	389,05	2,04	1,87
		389,96		
6	0,36	382,89	1,99	1,84
		383,08		
7	0,40	375,72	1,94	1,81
		375,86		
8	0,45	364,87	1,88	1,75
		363,61		
9	0,50	353,96	1,82	1,70
		354,39		

## 4.4. WYTRZYMAŁOŚĆ NA ŚCISKANIE ZAPRAWY

### 4.4.1. Zaprawa bez domieszek

Tabela 4.11. Wytrzymałość na ściskanie zaprawy bez domieszek

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	7,8	4,9	5,2
		7,2	4,5	
		7,6	4,8	
		10,8	6,8	
		8,8	5,5	
		7,4	4,6	
2	0,24	14,9	9,3	7,6
		10,1	6,3	
		12,2	7,6	
		11,4	7,1	
		11,9	7,4	
		12,5	7,8	
3	0,27	20,2	12,6	13,3
		22,8	14,3	
		18,4	11,5	
		19,7	12,3	
		25,2	15,8	
		21,5	13,4	
4	0,30	25,0	15,6	15,2
		27,0	16,9	
		22,5	14,1	
		23,0	14,4	
		25,0	15,6	
		23,0	14,4	
5	0,33	46,1	28,8	28,0
		44,0	27,5	
		45,4	28,4	
		48,0	30,0	
		42,1	26,3	
		43,0	26,9	

CD. Tabela 4.11. Wytrzymałość na ściskanie  
zaprawy bez domieszek

6	0,36	72,5	45,3	46,1
		72,0	45,0	
		70,1	43,8	
		74,6	46,6	
		80,0	50,0	
		74,1	46,3	
7	0,40	55,0	34,4	31,6
		48,0	30,0	
		49,0	30,6	
		49,4	30,9	
		56,0	35,0	
		46,1	28,8	
8	0,45	57,4	35,9	35,3
		59,5	37,2	
		55,0	34,4	
		54,0	33,8	
		56,0	35	
		57,0	35,6	
9	0,50	51,0	31,9	31,6
		46,6	29,1	
		49,9	31,2	
		52,0	32,5	
		51,0	31,9	
		53,0	33,1	

#### 4.4.2. Zaprawa z domieszką Nr 2 w ilości 0,8%

Tabela 4.12. Wytrzymałość na ściskanie zaprawy z domieszką Nr 2 w ilości 0,8%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	89,0	55,6	52,0
		84,0	52,5	
		87,0	54,4	
		75,0	46,9	
		82,1	51,3	
		82,6	51,6	
2	0,24	130,6	81,6	78,8
		129,0	80,6	
		125,0	78,1	
		125,0	78,1	
		121,0	75,6	
		126,1	78,8	
3	0,27	110,1	68,8	69,1
		110,1	68,8	
		117,0	73,1	
		105,0	65,6	
		108,5	67,8	
		113,0	70,6	
4	0,30	89,4	55,9	59,1
		93,0	58,1	
		92,5	57,8	
		97,4	60,9	
		102,0	63,8	
		92,5	57,8	
5	0,33	111,0	69,4	67,4
		107,0	66,9	
		106,1	66,3	
		110,1	68,8	
		108,0	67,5	
		105,0	65,6	
6	0,36	87,0	54,4	50,8
		81,4	50,9	
		81,0	50,6	
		85,0	53,1	
		78,6	49,1	
		75,0	46,9	



CD. Tabela 4.12. Wytrzymałość na ściskanie  
zaprawy z domieszką Nr 2 w ilości 0,8%

7	0,40	69,0	43,1	43,2
		70,1	43,8	
		72,0	45,0	
		70,6	44,1	
		66,1	41,3	
		67,0	41,9	
8	0,45	60,0	37,5	36,5
		54,1	33,8	
		61,0	38,1	
		60,5	37,8	
		55,0	34,4	
		60,0	37,5	
9	0,50	45,0	28,1	28,3
		42,1	26,3	
		43,0	26,9	
		50,6	31,6	
		46,1	28,8	
		45,0	28,1	

#### 4.4.3. Zaprawa z domieszką Nr 2 w ilości 3%

Tabela 4.13. Wytrzymałość na ściskanie zaprawy z domieszką Nr 2 w ilości 3%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	140,0	87,5	86,3
		138,1	86,3	
		155,5	97,2	
		149,0	93,1	
		131,0	81,9	
		115,0	71,9	
2	0,24	115,0	71,9	78,2
		124,0	77,5	
		129,0	80,6	
		123,0	76,9	
		126,1	78,8	
		134,1	83,8	
3	0,27	121,0	75,6	74,8
		129,0	80,6	
		118,1	73,8	
		111,5	69,7	
		117,0	73,1	
		121,4	75,9	
4	0,30	112,0	70,0	68,4
		115,0	71,9	
		109,0	68,1	
		100,0	62,5	
		111,5	69,7	
		109,0	68,1	
5	0,33	95,5	59,7	56,3
		90,1	56,3	
		92,5	57,8	
		88,5	55,3	
		89,0	55,6	
		85,0	53,1	
6	0,36	78,1	48,8	48,5
		80,5	50,3	
		79,5	49,7	
		75,0	46,9	
		76,0	47,5	
		76,5	47,8	

CD. Tabela 4.13. Wytrzymałość na ściskanie  
zaprawy z domieszką Nr 2 w ilości 3%

7	0,40	62,1	38,8	42,6
		69,4	43,4	
		67,5	42,2	
		70,1	43,8	
		69,4	43,4	
		70,1	43,8	
8	0,45	54,1	33,8	31,3
		48,5	30,3	
		42,1	26,3	
		50,1	31,3	
		54,1	33,8	
		52,0	32,5	
9	0,50	52,5	32,8	33,5
		55,0	34,4	
		50,6	31,6	
		55,0	34,4	
		51,0	31,9	
		57,4	35,9	

#### 4.4.4. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 5%

Tabela 4.14. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 5%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	5,6	3,5	3,3
		4,8	3	
		6,9	4,3	
		5,0	3,1	
		4,6	2,9	
		4,8	3	
2	0,24	8,0	5	4,6
		6,9	4,3	
		6,9	4,3	
		7,7	4,8	
		6,4	4	
		8,3	5,2	
3	0,27	13,3	8,3	8,9
		10,2	6,4	
		16,6	10,4	
		13,6	8,5	
		15,4	9,6	
		16,2	10,1	
4	0,30	19,7	12,3	15,1
		29,8	18,6	
		27,0	16,9	
		18,4	11,5	
		24,6	15,4	
		26,1	16,3	
5	0,33	37,0	23,1	23,0
		32,2	20,1	
		38,1	23,8	
		38,6	24,1	
		40,0	25	
		35,5	22,2	
6	0,36	63,0	39,4	37,3
		63,5	39,7	
		58,6	36,6	
		57,4	35,9	
		58,1	36,3	
		58,1	36,3	

CD. Tabela 4.14. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 5%

7	0,40	67,0	41,9	40,9
		66,1	41,3	
		62,1	38,8	
		62,1	38,8	
		67,0	41,9	
		68,5	42,8	
8	0,45	62,1	38,8	37,8
		60,0	37,5	
		62,6	39,1	
		57,4	35,9	
		58,6	36,6	
		62,6	39,1	
9	0,50	50,1	31,3	32,6
		57,0	35,6	
		54,6	34,1	
		54,1	33,8	
		49,0	30,6	
		49,0	30,6	

#### 4.4.5. Zaprawa z dodatkiem pyłu krzemionkowego w ilości 15%

Tabela 4.15. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 15%

Nr	w/s	Wytrzymałość po 28 dniach		
		[kN]	[MPa]	[MPa]
1	0,21	15,7	9,8	9,6
		15,5	9,7	
		16,6	10,4	
		16,8	10,5	
		13,0	8,1	
		14,5	9,1	
2	0,24	19,2	12	10,1
		16,4	10,3	
		12,8	8	
		15,2	9,5	
		16,4	10,3	
		16,5	10,3	
3	0,27	12,2	7,7	8,7
		12,4	7,8	
		16,4	10,3	
		17,6	11	
		13,2	8,3	
		12,4	7,8	
4	0,30	24,8	15,5	13,3
		21,0	13,1	
		19,8	12,4	
		21,8	13,6	
		18,8	11,8	
		21,5	13,4	
5	0,33	23,6	14,8	14,8
		15,6	9,8	
		32,0	20	
		17,8	11,1	
		30,3	18,9	
		22,8	14,3	
6	0,36	29,5	18,4	16,8
		26,5	16,6	
		23,0	14,4	
		32,5	20,3	
		24,0	15	
		26,6	16,6	

CD. Tabela 4.15. Wytrzymałość na ściskanie zaprawy z dodatkiem pyłu krzemionkowego w ilości 15%

7	0,40	63,0	39,4	36,4
		53,4	33,4	
		64,0	40	
		62,1	38,8	
		62,1	38,8	
		45,0	28,1	
8	0,45	58,1	36,3	35,7
		53,4	33,4	
		58,1	36,3	
		56,0	35	
		59,5	37,2	
		58,1	36,3	
9	0,50	36,5	22,8	21,9
		34,1	21,3	
		36,0	22,5	
		33,0	20,6	
		34,1	21,6	
		37,0	23,1	

## 4.5. WYTRZYMAŁOŚĆ BETONU NA ŚCISKANIE

### 4.5.1. Beton bez domieszek

Tabela 4.16. Wytrzymałość na ściskanie betonu bez domieszek z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,29	101,59	10188,46	51,8	5,08	5,45
	100,44	98,00	9843,12	59,1	6,00	
0,21/0,24	100,28	99,53	9980,87	52,5	5,26	18,49
	100,26	102,04	10230,53	182,1	17,80	
0,24	100,25	102,05	10230,51	189,9	18,56	43,00
	99,69	100,64	10032,80	191,7	19,11	
0,27	100,18	103,15	10333,57	433,6	41,96	43,62
	97,27	100,94	9818,43	447,2	45,55	
0,27/0,30	100,34	103,40	10375,16	430,4	41,48	56,63
	99,62	102,38	10199,10	446,9	43,82	
0,30	100,26	102,81	10307,73	466,6	45,27	54,34
	99,94	100,38	10031,98	419,0	41,77	
0,33	100,10	103,07	10317,31	596,2	57,79	44,46
	100,12	103,05	10317,37	549,8	53,29	
0,33/0,36	100,20	99,90	10009,98	588,8	58,82	36,78
	100,24	101,91	10215,46	576,2	56,40	
0,36	100,15	102,90	10305,44	523,9	50,84	20,31
	100,21	100,76	10097,16	563,3	55,79	
0,40 x1						44,46
	100,30	102,45	10275,74	463,3	45,09	
0,40	100,15	101,72	10187,26	446,6	43,84	36,78
	100,14	101,71	10185,24	452,8	44,46	
0,45	100,23	102,01	10224,46	352,9	34,52	20,31
	99,48	98,99	9847,53	355,6	36,11	
0,45/0,50	100,52	98,78	9929,37	394,4	39,72	20,31
	100,33	99,04	9936,68	217,1	21,85	
0,50	100,69	100,94	10163,65	200,3	19,71	20,31
	100,70	102,60	10331,82	200,2	19,38	



Tabela 4.17. Wytrzymałość na ściskanie betonu bez domieszek z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,26	102,04	10230,53	45,4	4,44	4,61
	100,25	100,90	10115,23	47,2	4,67	
0,21 x1						
0,24	100,32	101,15	10147,37	47,9	4,72	13,45
	99,30	100,57	9986,60	142,6	14,28	
	99,47	101,92	10137,98	130,8	12,90	
0,24/0,27	100,85	101,60	10246,36	134,8	13,16	23,73
	100,22	100,87	10109,19	231,5	22,90	
0,27	99,99	102,85	10283,97	262,4	25,52	
	100,20	99,90	10009,98	227,9	22,77	
0,30	100,24	101,91	10215,46	540,5	52,91	53,80
	100,15	102,90	10305,44	573,1	55,61	
0,30 x1	101,71	102,30	10404,93	550,3	52,89	
0,33	100,30	102,45	10275,74	646,9	62,95	59,38
	100,01	101,33	10134,01	566,6	55,91	
0,33/0,36	100,07	104,35	10442,30	619,0	59,28	
	99,92	102,66	10257,79	772,4	75,30	
0,36	100,39	97,80	9818,14	765,4	77,96	
	100,20	103,01	10321,60	745,0	72,18	
0,40	100,32	98,29	9860,45	468,1	47,47	48,69
	100,69	100,94	10163,65	485,6	47,78	
0,40 x1	100,70	102,60	10331,82	525,0	50,81	
0,45	100,00	99,90	9990,00	423,8	42,42	42,21
	100,40	101,10	10150,44	420,4	41,42	
0,45/0,50	100,10	100,70	10080,07	431,3	42,79	
	99,90	100,20	10009,98	339,6	33,93	
0,50	100,50	98,50	9899,25	384,3	38,82	
	100,14	100,88	10102,12	368,2	36,45	

#### 4.5.2. Beton z domieszką Nr 2 w ilości 1%

Tabela 4.18. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 1% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,43	100,64	10107,28	61,2	6,06	6,10
	100,00	101,72	10172,00	62,1	6,10	
0,21/0,24	100,70	100,90	10160,63	62,4	6,14	76,80
	100,11	100,97	10108,11	796,1	78,76	
0,24	100,05	102,18	10223,11	754,1	73,76	76,80
	100,29	99,82	10010,95	779,5	77,86	
0,27	100,00	102,50	10250,00	721,1	70,35	73,04
	100,33	100,18	10051,06	791,3	78,73	
0,27/0,30	100,32	100,37	10069,12	705,1	70,03	68,98
	100,49	99,50	9998,76	703,2	70,33	
0,30	100,25	99,97	10021,99	672,2	67,07	68,98
	100,32	98,30	9861,46	685,8	69,54	
0,33	100,16	100,72	10088,12	665,4	65,96	65,39
	100,06	102,12	10218,13	675,4	66,10	
0,33/0,36	100,05	102,04	10209,10	654,6	64,12	58,72
	101,66	100,76	10243,26	585,4	57,15	
0,36	100,34	100,63	10097,21	601,9	59,61	58,72
	100,50	98,44	9893,22	587,8	59,41	
0,40	100,78	100,76	10154,59	460,8	45,38	44,01
	100,43	101,26	10169,54	402,5	39,58	
0,40/0,45	100,38	103,02	10341,15	486,7	47,06	42,90
	100,30	99,82	10011,95	443,4	44,29	
0,45	100,18	99,85	10002,97	398,6	39,85	42,90
	100,50	98,28	9877,14	440,2	44,57	
0,50	100,10	100,13	10023,01	340,2	33,94	33,95
	100,38	101,35	10173,51	333,1	32,74	
0,50 x1	100,51	98,20	9870,08	347,1	35,17	33,95

Tabela 4.19. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 1% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,12	99,38	9949,93	166,5	16,73	15,21
	100,43	101,00	10143,43	161,3	15,90	
0,21/0,24	100,36	101,71	10207,62	132,6	12,99	77,63
	99,96	103,72	10367,85	815,0	78,61	
0,24	100,40	100,77	10117,31	757,3	74,85	77,63
	100,17	102,36	10253,40	814,5	79,44	
0,27	100,04	100,97	10101,04	812,1	80,40	80,68
	100,11	101,04	10115,11	828,4	81,90	
0,27 x1	100,05	102,85	10290,14	820,6	79,75	80,68
0,30	100,40	100,77	10117,31	742,1	73,35	73,95
	100,18	101,21	10139,22	743,9	73,37	
0,30/0,33	100,41	97,99	9839,18	739,1	75,12	72,33
	100,25	100,09	10034,02	675,1	67,28	
0,33	100,30	98,79	9908,64	756,7	76,37	72,33
	100,39	100,27	10066,11	738,2	73,34	
0,36	100,15	100,37	10052,06	696,6	69,30	69,92
	99,83	101,39	10121,76	722,1	71,34	
0,36/0,40	100,03	100,60	10063,02	695,6	69,12	54,96
	100,30	102,33	10263,70	559,3	54,49	
0,40	100,14	102,40	10254,34	554,7	54,09	54,96
	100,63	101,61	10225,01	575,5	56,28	
0,45	100,49	100,73	10122,36	597,6	59,04	64,37
	101,02	99,37	10038,36	650,9	64,84	
0,45/0,50	100,18	100,36	10054,06	696,0	69,23	43,19
	100,38	101,52	10190,58	325,9	31,98	
0,50	100,34	100,68	10102,23	502,2	49,71	43,19
	100,43	100,12	10055,05	481,4	47,88	

### 4.5.3. Beton z domieszką Nr 2 w ilości 3%

Tabela 4.20. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 3% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,11	105,08	10519,56	646,4	61,45	60,78
	100,46	102,58	10305,19	634,4	61,56	
0,21	100,32	103,30	10363,06	615,0	59,35	
	100,53	101,70	10223,90	644,2	63,01	
0,24	100,33	101,38	10171,46	681,3	66,98	69,85
	100,30	101,36	10166,41	722,8	71,10	
0,24/0,27	100,36	101,40	10176,50	727,4	71,48	
	100,22	103,30	10352,73	656,8	63,44	
0,27	100,07	100,21	10028,01	715,9	71,39	
	100,19	99,36	9954,88	694,3	69,74	
0,30	100,19	99,84	10002,97	970,4	97,01	87,65
	100,23	99,96	10018,99	969,1	96,73	
0,30/0,33	100,30	98,88	9917,66	686,3	69,20	
	100,30	98,23	9852,47	586,1	59,49	
0,33	100,25	98,85	9909,71	635,8	64,16	
	100,53	98,29	9881,09	659,8	66,77	
0,36	101,00	99,55	10054,55	550,0	54,70	53,55
	100,29	95,20	9547,61	502,9	52,67	
0,36 x1	100,23	97,57	9779,44	520,9	53,26	
0,40 x1						52,07
	100,16	101,13	10129,18	672,8	66,42	
0,40	100,28	99,58	9985,88	705,9	70,69	
	100,23	100,56	10079,13	694,2	68,88	
0,45	100,49	100,73	10122,36	597,6	59,04	64,37
	101,02	99,37	10038,36	650,9	64,84	
0,45/0,50	100,18	100,36	10054,06	696,0	69,23	
	100,38	101,52	10190,58	325,9	31,98	
0,50	100,34	100,68	10102,23	502,2	49,71	
	100,43	100,12	10055,05	481,4	47,88	

Tabela 4.21. Wytrzymałość na ściskanie betonu z domieszką Nr 2 w ilości 3% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21 x1						
	100,50	100,57	10107,29	791,0	78,26	77,43
0,21	100,11	101,92	10203,21	760,8	74,56	
	100,18	101,78	10196,32	810,1	79,45	
0,24	100,63	98,71	9933,19	869,9	87,58	86,59
	100,40	99,53	9992,81	851,6	85,22	
0,24/0,27	100,30	99,67	9996,90	869,5	86,98	87,59
	100,74	99,55	10028,67	911,1	90,85	
0,27	100,95	100,12	10107,11	858,1	84,90	87,59
	100,66	97,04	9768,05	850,1	87,03	
0,30	100,38	100,77	10115,29	757,1	74,85	74,07
	100,12	102,40	10252,29	761,2	74,25	
0,30/0,33	100,68	101,00	10168,68	743,5	73,12	69,85
	100,20	100,06	10026,01	696,6	69,48	
0,33	100,33	100,93	10126,31	688,3	67,97	69,85
	100,79	102,13	10293,68	742,3	72,11	
0,36	100,60	97,98	9856,79	553,3	56,13	55,04
	101,17	101,79	10298,09	551,5	53,55	
0,36/0,40	100,67	99,70	10036,80	556,4	55,44	50,77
	100,37	100,50	10087,19	557,6	55,28	
0,40	100,14	99,80	9993,97	490,7	49,10	50,77
	100,95	102,42	10339,30	495,5	47,92	
0,45	100,60	100,60	10120,36	505,1	49,91	50,79
	102,55	100,30	10285,77	512,5	49,83	
0,45 x1	100,60	100,70	10130,42	533,1	52,62	50,79
0,50	100,22	97,33	9754,41	439,6	45,07	46,37
	100,27	101,44	10171,39	484,3	47,61	
0,50 x1	100,48	100,39	10087,19	468,2	46,42	46,37

#### 4.5.4. Beton z dodatkiem pyłu krzemionkowego w ilości 5%

Tabela 4.22. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 5% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,11	100,93	10104,10	14,0	1,39	1,30
	100,56	100,51	10107,29	12,0	1,19	
0,21/0,24	100,22	100,07	10029,02	13,4	1,34	1,66
	100,55	99,60	10014,78	17,7	1,77	
0,24	100,19	100,80	10099,15	16,5	1,63	1,66
	100,20	98,75	9894,75	15,6	1,58	
0,27	100,11	100,93	10104,10	624,0	61,76	66,30
	100,56	100,51	10107,29	678,2	67,10	
0,27/0,30	100,22	100,07	10029,02	702,6	70,06	66,76
	100,55	99,60	10014,78	677,5	67,65	
0,30	100,19	100,80	10099,15	644,5	63,82	66,76
	100,20	98,75	9894,75	681,0	68,82	
0,33	100,48	99,72	10019,87	624,2	62,30	65,05
	100,25	101,44	10169,36	672,4	66,12	
0,33/0,36	100,10	100,43	10053,04	670,9	66,74	64,32
	100,55	99,36	9990,65	626,6	62,72	
0,36	100,22	100,33	10055,07	666,4	66,28	64,32
	101,06	99,70	10075,68	644,4	63,96	
0,40	100,43	99,14	9956,63	544,7	54,71	55,65
	99,87	101,19	10105,85	564,9	55,90	
0,40/0,45	100,13	98,56	9868,81	556,2	56,36	46,62
	100,23	100,11	10034,03	477,2	47,56	
0,45	100,20	100,63	10083,13	485,7	48,17	46,62
	100,62	99,95	10056,97	443,7	44,12	
0,50	100,60	100,60	10120,36	305,1	30,15	31,14
	102,55	100,30	10285,77	312,5	30,38	
0,50 x1	100,60	100,70	10130,42	333,1	32,88	31,14

Tabela 4.23. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 5% z kruszywem łamanym

w/c	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21 x1						0,79
	99,92	102,21	10212,82	8,1	0,79	
0,21	100,43	99,93	10035,97	7,2	0,72	0,79
	100,16	100,05	10021,01	8,7	0,87	
0,24	100,20	101,60	10180,32	21,9	2,15	2,22
	100,55	102,49	10305,37	22,3	2,16	
0,24/0,27	100,44	101,37	10181,60	24,0	2,36	84,71
	100,14	102,12	10226,30	864,9	84,58	
0,27	99,77	99,27	9904,17	851,5	85,97	84,71
	100,45	101,88	10233,85	855,2	83,57	
0,30	100,41	103,45	10387,41	789,2	75,98	77,05
	99,85	100,80	10064,88	777,0	77,20	
0,30/0,33	100,33	101,47	10180,49	793,7	77,96	75,86
	100,49	102,00	10249,98	767,4	74,87	
0,33	99,93	101,62	10154,89	762,9	75,13	75,86
	100,07	99,87	9993,99	775,3	77,58	
0,36	100,37	101,37	10174,51	696,8	68,48	67,12
	100,40	102,31	10271,92	688,8	67,06	
0,36/0,40	100,35	101,27	10162,44	669,0	65,83	59,97
	100,32	100,27	10059,09	604,8	60,12	
0,40	100,05	99,75	9979,99	590,7	59,19	59,97
	100,70	98,80	9949,16	602,9	60,60	
0,45	100,42	100,27	10069,11	441,3	43,83	43,33
	100,36	99,42	9977,79	433,0	43,40	
0,45	99,58	100,08	9965,97	426,1	42,76	55,75
	100,28	100,15	10043,04	607,8	60,52	
0,50	100,03	102,30	10233,07	554,0	54,14	55,75
	100,06	101,67	10173,10	535,0	52,59	

#### 4.5.5. Beton z dodatkiem pyłu krzemionkowego w ilości 15%

Tabela 4.24. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 15% z kruszywem otoczkowym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21	100,15	101,76	10191,26	5,3	0,52	0,52
	100,11	101,28	10139,14	5,9	0,58	
0,21/0,24	100,13	100,86	10099,11	4,5	0,45	0,82
	100,31	101,79	10210,55	8,7	0,85	
0,24	100,13	101,65	10178,21	6,8	0,67	0,82
	101,15	100,84	10199,97	9,7	0,95	
0,27	100,38	101,53	10191,58	653,9	64,16	62,71
	100,21	101,60	10181,34	648,1	63,66	
0,27/0,30	100,45	103,11	10357,40	624,6	60,30	64,08
	100,17	101,23	10140,21	595,5	58,73	
0,30	100,22	101,82	10204,40	689,5	67,57	64,08
	100,35	103,23	10359,13	683,2	65,95	
0,33	100,61	101,05	10166,64	695,1	68,37	69,74
	100,11	99,79	9989,98	698,9	69,96	
0,33/0,36	99,95	99,58	9953,02	705,5	70,88	60,82
	100,12	101,52	10164,18	615,3	60,54	
0,36	100,26	101,83	10209,48	611,0	59,85	60,82
	99,95	99,68	9963,02	618,4	62,07	
0,40	100,02	101,94	10196,04	552,1	54,15	54,90
	100,16	101,15	10131,18	551,1	54,40	
0,40/0,45	100,27	100,33	10060,09	564,8	56,14	45,66
	100,28	102,10	10238,59	463,2	45,24	
0,45	100,14	101,95	10209,27	477,9	46,81	45,66
	100,26	101,19	10145,31	455,7	44,92	
0,50	99,99	102,63	10261,97	365,5	35,62	36,60
	100,6	101,58	10218,95	368,2	36,03	
0,50 x1	100,26	100,69	10095,18	385,1	38,15	36,60



Tabela 4.25. Wytrzymałość na ściskanie betonu z dodatkiem pyłu krzemionkowego w ilości 15% z kruszywem łamanym

w/s	Powierzchnia			Wytrzymałość		
	[mm]	[mm]	[mm <sup>2</sup> ]	[kN]	[MPa]	[MPa]
0,21 x1						0,10
	100,11	105,08	10519,56	1,0	0,10	
0,21	100,24	102,96	10320,71	1,0	0,10	0,10
	100,90	101,55	10246,40	1,0	0,10	
0,24	100,98	101,36	10235,33	6,5	0,64	0,60
	100,18	100,47	10065,08	5,4	0,54	
0,24/0,27	100,16	100,48	10064,08	6,3	0,63	0,60
	100,22	101,05	10127,23	696,5	68,77	
0,27	100,22	101,51	10173,33	721,9	70,96	69,97
	100,26	101,14	10140,30	711,6	70,18	
0,30	100,12	103,23	10335,39	746,7	72,25	73,08
	100,28	100,37	10065,10	726,3	72,16	
0,30/0,33	100,23	99,16	9938,81	743,8	74,84	72,62
	100,09	100,06	10015,01	709,0	70,79	
0,33	100,39	100,66	10105,26	752,9	74,51	72,62
	100,14	100,22	10036,03	728,2	72,56	
0,36	100,25	99,60	9984,90	644,3	64,53	67,31
	99,95	99,85	9980,01	700,2	70,16	
0,36/0,40	100,57	99,90	10046,94	675,5	67,23	61,71
	100,41	97,74	9814,07	617,9	62,96	
0,40	100,07	97,08	9714,80	587,0	60,42	61,71
	100,33	98,87	9919,63	612,5	61,75	
0,45	100,34	98,56	9889,51	491,4	49,69	49,57
	100,49	97,04	9751,55	491,0	50,35	
0,45/0,50	100,38	100,55	10093,21	491,1	48,66	44,55
	100,15	100,33	10048,05	444,1	44,20	
0,50	100,23	97,00	9722,31	437,8	45,03	44,55
	100,21	98,61	9881,71	439,1	44,44	

## ZAŁĄCZNIK 2 – MATRYCA DANYCH

L.p.	w/s	masa cementu	masa wody	masa piasku	masa kruszywa frakcji [2-8 mm]	masa kruszywa frakcji [8-16 mm]	rodzaj kruszywa grubego	masa domieszki	masa mikrokremionki	rodzaj cementu	wytrzymałość [MPa]
1	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM I	9,138
2	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM I	9,609
3	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM I	7,927
4	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM I	8,73
5	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM I	25,82
6	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM I	23,18
7	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM I	22,69
8	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	56,94
9	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	47,82
10	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	42,42
11	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	45,66
12	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	48,34
13	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	50,52
14	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	67,96
15	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	69,23
16	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	68,08
17	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	65,28
18	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	66,9
19	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM I	66,94
20	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	64,51
21	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	61,6
22	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	64,95
23	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	51,09
24	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	55,01
25	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	52,39
26	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	42,04
27	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	42
28	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM I	43,57
29	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM I	6,006

CD. MATRYCA DANYCH

30	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM I	5,555
31	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM I	5,99
32	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM I	6,372
33	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM I	18,25
34	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM I	21,22
35	0,2	2	0,6	1,66	2,826	2,826	grys	0	0	CEM I	22,52
36	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM I	25,74
37	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM I	23,51
38	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM I	26,24
39	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM I	52,88
40	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM I	57,43
41	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM I	52,37
42	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM I	76,72
43	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM I	71,23
44	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM I	76,28
45	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM I	89,14
46	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM I	90,46
47	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM I	88
48	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM I	84,95
49	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM I	83,91
50	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM I	84,92
51	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM I	71,65
52	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM I	73,74
53	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM I	73,8
54	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM I	57,74
55	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM I	54,85
56	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM I	55,63
57	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM I	10,78
58	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM I	9,577
59	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM I	9,299
60	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM I	71,57
61	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM I	68,53
62	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM I	72,17
63	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	80,95
64	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	80,88
65	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	78,41

CD. MATRYCA DANYCH

66	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	79,56
67	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	74,28
68	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	78,33
69	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	77,3
70	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	80,28
71	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM I	74,52
72	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM I	75,24
73	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM I	74,66
74	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM I	74,86
75	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	65,75
76	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	63,34
77	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	64,13
78	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	53,66
79	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	54,28
80	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	53,02
81	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	40,43
82	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	40,18
83	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM I	41,59
84	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM I	14,9
85	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM I	13,12
86	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM I	16,16
87	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM I	96,76
88	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM I	98,85
89	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM I	95,5
90	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	94,58
91	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	102,2
92	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	97,17
93	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	100,1
94	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	85,42
95	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	87,72
96	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	83,58
97	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	83,58
98	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	87,22
99	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	83,79
100	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM I	85,49
101	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM I	83,42

## CD. MATRYCA DANYCH

102	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM I	78,15
103	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM I	80,12
104	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	79,1
105	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	76,57
106	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	75,03
107	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	69,37
108	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	70,45
109	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	65,34
110	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	43,08
111	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	46,24
112	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM I	45,64
113	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM I	74,35
114	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM I	71,42
115	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM I	70,53
116	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM I	81,61
117	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM I	76,77
118	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM I	79,57
119	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	80,16
120	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	81,56
121	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	85,3
122	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	85,9
123	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	84,66
124	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	88,2
125	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	80,36
126	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	78,9
127	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM I	79,67
128	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM I	76
129	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM I	74,72
130	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM I	77
131	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM I	60,59
132	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM I	61,3
133	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM I	57,99
134	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM I	43,54
135	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM I	48,61
136	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM I	50,02
137	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM I	37,94
138	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM I	41,14

## CD. MATRYCA DANYCH

139	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM I	40,57
140	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM I	97,59
141	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM I	95,61
142	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM I	95,57
143	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM I	104,4
144	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM I	108,3
145	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM I	102,4
146	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	99,14
147	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	103,1
148	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	103,8
149	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	92,25
150	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	97,68
151	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	94,31
152	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	78,97
153	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	87,9
154	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM I	86,76
155	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM I	85,05
156	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM I	75,14
157	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM I	84,79
158	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM I	65,54
159	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM I	60,84
160	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM I	59,16
161	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,47	0	CEM I	64,87
162	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,47	0	CEM I	33,32
163	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,47	0	CEM I	47,31
164	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM I	21,27
165	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM I	24,29
166	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM I	20,82
167	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM I	0,59
168	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM I	0,64
169	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM I	0,2
170	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM I	1,55
171	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM I	1,55
172	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM I	1,56
173	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM I	1,55
174	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM I	1,56
175	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM I	83,62

## CD. MATRYCA DANYCH

176	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM I	84,35
177	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM I	78,36
178	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM I	83,16
179	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM I	88,92
180	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM I	79,67
181	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM I	86,98
182	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM I	79,15
183	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM I	79,88
184	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM I	77,55
185	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM I	68,07
186	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM I	68,11
187	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM I	68,65
188	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM I	57,49
189	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM I	59
190	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM I	55,46
191	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM I	45,92
192	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM I	44,7
193	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM I	46,29
194	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM I	0,865
195	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM I	0,782
196	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM I	0,602
197	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM I	1,898
198	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM I	1,422
199	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM I	1,127
200	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM I	92
201	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM I	96,54
202	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM I	93,09
203	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM I	82,18
204	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM I	77,7
205	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM I	82,87
206	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM I	76,46
207	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM I	85,04
208	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM I	83,32
209	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM I	68,82
210	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM I	66,82
211	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM I	71,31
212	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM I	78,91

## CD. MATRYCA DANYCH

213	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM I	68,66
214	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM I	64,35
215	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM I	38,64
216	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM I	43,48
217	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM I	39,12
218	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM I	33,17
219	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM I	31,13
220	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM I	34,38
221	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM I	0,089
222	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM I	0,079
223	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM I	0,088
224	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM I	1,022
225	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM I	1,12
226	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM I	0,848
227	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM I	3,571
228	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM I	2,76
229	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM I	3,689
230	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM I	85,92
231	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM I	84,18
232	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM I	80,27
233	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM I	82,52
234	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM I	87,54
235	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM I	79,53
236	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM I	75,17
237	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM I	71,32
238	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM I	76,97
239	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM I	68,46
240	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM I	72,57
241	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM I	62,44
242	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM I	58,59
243	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM I	56,24
244	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM I	55,28
245	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM I	39,63
246	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM I	45,63
247	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM I	44,83
248	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM I	0,118
249	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM I	0,183



CD. MATRYCA DANYCH

250	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM I	0,01
251	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM I	1,633
252	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM I	1,048
253	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM I	1,348
254	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM I	42,21
255	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM I	43
256	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM I	41,51
257	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM I	43,9
258	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,29	CEM I	89,31
259	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,29	CEM I	92,84
260	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,29	CEM I	94,37
261	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM I	90,24
262	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM I	89,1
263	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM I	95,06
264	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM I	82,2
265	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM I	74,05
266	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM I	76,44
267	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM I	86,6
268	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM I	70,86
269	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM I	72
270	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM I	35,46
271	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM I	39,24
272	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM I	47,7
273	0,5	1,2	0,7	1,66	2,826	2,826	grys	0,04	0,22	CEM I	51,72
274	0,5	1,2	0,7	1,66	2,826	2,826	grys	0,04	0,22	CEM I	54,03
275	0,5	1,2	0,7	1,66	2,826	2,826	grys	0,04	0,22	CEM I	52,92
276	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM II	12,85
277	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM II	11,6
278	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM II	8,266
279	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM II	56,9
280	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM II	63,7
281	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM II	60,2
282	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	72,79
283	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	73,97
284	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	77,73
285	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	74,45
286	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	72,1

## CD. MATRYCA DANYCH

287	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	74,72
288	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	72,35
289	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	74,14
290	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	70,72
291	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	92,06
292	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	89,6
293	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM II	90,37
294	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	81,79
295	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	86,16
296	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	84,7
297	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	55,8
298	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	47,4
299	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	52,8
300	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	47,47
301	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	47,78
302	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM II	50,81
303	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM II	18,16
304	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM II	14,49
305	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM II	13,67
306	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM II	8,248
307	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM II	8,574
308	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM II	8,546
309	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM II	87,69
310	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM II	88,52
311	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM II	82,13
312	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM II	88,76
313	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM II	92,82
314	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM II	97,84
315	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM II	87,22
316	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM II	99,07
317	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM II	95,23
318	0,4	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM II	76,08
319	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM II	93,59
320	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM II	89,54
321	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM II	80,28
322	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM II	75,03
323	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM II	70,3

## CD. MATRYCA DANYCH

324	0,5	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM II	69,68
325	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM II	71,23
326	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM II	68,51
327	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM II	50,83
328	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM II	55,12
329	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM II	52,49
330	0,2	1,5	0,7	1,66	2,826	2,34	żwir	0,02	0	CEM II	7,286
331	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM II	6,226
332	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM II	10,12
333	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM II	26,29
334	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM II	28,61
335	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM II	21,33
336	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	78,67
337	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	80,39
338	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	74,66
339	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	72,8
340	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	75,99
341	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	78,55
342	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	72,73
343	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	74,75
344	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM II	74,12
345	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM II	77,75
346	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM II	74,9
347	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM II	74,62
348	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	72,35
349	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	69,18
350	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	66,67
351	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	54,31
352	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	53,46
353	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	54,48
354	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	43,02
355	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	40,43
356	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM II	40,18
357	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM II	15,29
358	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM II	16,02
359	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM II	14,05
360	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM II	76,78

## CD. MATRYCA DANYCH

361	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM II	75,81
362	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM II	76,27
363	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	94,55
364	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	95,25
365	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	93,92
366	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	89,53
367	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	89,98
368	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	87,45
369	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	88,1
370	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	93,5
371	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM II	87,27
372	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM II	86,65
373	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM II	84,14
374	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM II	86,28
375	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	56,91
376	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	56,27
377	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	78,36
378	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	59,34
379	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	60,5
380	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	64,35
381	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	52,88
382	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	50,06
383	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM II	52,46
384	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM II	87,71
385	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM II	88,74
386	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM II	89,91
387	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM II	85,88
388	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM II	84,41
389	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM II	85,66
390	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	91,2
391	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	91,51
392	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	94,09
393	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	93,55
394	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	94,34
395	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	94,7
396	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	76,4
397	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	85,41

## CD. MATRYCA DANYCH

398	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM II	78,98
399	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM II	70,82
400	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM II	71,58
401	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM II	71,22
402	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM II	66,92
403	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM II	69,34
404	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM II	66,65
405	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM II	53,02
406	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM II	54,64
407	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM II	55,06
408	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM II	43,41
409	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM II	43,6
410	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM II	44,94
411	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM II	92,65
412	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM II	88,56
413	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM II	92,05
414	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM II	104,6
415	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM II	108,6
416	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM II	109,3
417	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	95,12
418	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	106,1
419	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	102,5
420	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	106,3
421	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	85,84
422	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	80,69
423	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	92,71
424	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	92,15
425	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM II	97,01
426	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM II	81,5
427	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM II	66,76
428	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM II	75,18
429	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM II	61,61
430	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM II	74,96
431	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM II	74,62
432	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,05	0	CEM II	62,51
433	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,05	0	CEM II	60,44
434	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,05	0	CEM II	60,05

## CD. MATRYCA DANYCH

435	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM II	31,67
436	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM II	33,75
437	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM II	30,53
438	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM II	0,979
439	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM II	0,574
440	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM II	0,687
441	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM II	1,003
442	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM II	1,239
443	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM II	1,773
444	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM II	77,03
445	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM II	77,81
446	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM II	78,27
447	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM II	76,11
448	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM II	71,42
449	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM II	74,07
450	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM II	74,74
451	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM II	73,13
452	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM II	74,15
453	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM II	72,07
454	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM II	74,02
455	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM II	74,77
456	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM II	72,7
457	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM II	69,88
458	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM II	68,07
459	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM II	58,5
460	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM II	57,36
461	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM II	59,89
462	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM II	49,91
463	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM II	49,83
464	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM II	52,62
465	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM II	0,897
466	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM II	0,816
467	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM II	0,852
468	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM II	2,779
469	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM II	2,729
470	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM II	2,941
471	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM II	93,02

## CD. MATYRCA DANYCH

472	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM II	95,54
473	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM II	93,6
474	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM II	99,22
475	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM II	94,62
476	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM II	97,1
477	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM II	95,71
478	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM II	96,8
479	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM II	93,95
480	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM II	83,74
481	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM II	84,13
482	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM II	85,33
483	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM II	79,01
484	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM II	78,47
485	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM II	77,3
486	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM II	54,74
487	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM II	48,45
488	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM II	57,26
489	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM II	45,78
490	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM II	38,68
491	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM II	35,43
492	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM II	0,089
493	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM II	0,109
494	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM II	0,117
495	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM II	0,336
496	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM II	0,41
497	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM II	0,383
498	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM II	10,48
499	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM II	12,69
500	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM II	13,74
501	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM II	67
502	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM II	66,12
503	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM II	69,2
504	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM II	74,69
505	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM II	76,3
506	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM II	73,96
507	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM II	79,6
508	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM II	79,4

## CD. MATRYCA DANYCH

509	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM II	76,84
510	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM II	72,39
511	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM II	72,44
512	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM II	69,39
513	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM II	64,92
514	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM II	60,52
515	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM II	64,42
516	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM II	54,14
517	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM II	52,59
518	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM II	48,83
519	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM II	0,512
520	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM II	0,956
521	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM II	0,903
522	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM II	1,036
523	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM II	0,951
524	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM II	1,016
525	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM II	72,76
526	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM II	69
527	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM II	64,58
528	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,29	CEM II	82,63
529	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,29	CEM II	82,5
530	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,29	CEM II	78,44
531	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM II	89,27
532	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM II	91,61
533	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM II	87,93
534	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM II	87,59
535	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM II	84,74
536	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM II	84,37
537	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM II	84,25
538	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM II	83,63
539	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM II	75,83
540	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM II	74,59
541	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM II	69,41
542	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM II	74
543	0,5	1,2	0,7	1,66	2,826	2,826	grys	0,04	0,22	CEM II	56,41
544	0,5	1,2	0,7	1,66	2,826	2,826	grys	0,04	0,22	CEM II	63,46
545	0,5	1,2	0,7	1,66	2,826	2,826	żwir	0,04	0,22	CEM II	62,86



## CD. MATRYCA DANYCH

546	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM IV	5,084
547	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM IV	6,004
548	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0	0	CEM IV	5,26
549	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM IV	17,8
550	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM IV	18,56
551	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0	0	CEM IV	19,11
552	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	41,96
553	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	45,55
554	0,3	2	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	41,48
555	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	43,82
556	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	45,27
557	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	41,77
558	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	57,79
559	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	53,29
560	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	58,82
561	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	56,4
562	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	50,84
563	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0	0	CEM IV	55,79
564	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	45,09
565	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	43,84
566	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	44,46
567	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	34,52
568	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	36,11
569	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	39,72
570	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	21,85
571	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	19,71
572	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0	0	CEM IV	19,38
573	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM IV	4,438
574	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM IV	4,666
575	0,2	2,3	0,5	1,66	2,826	2,826	grys	0	0	CEM IV	4,718
576	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM IV	14,28
577	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM IV	12,9
578	0,2	2,1	0,5	1,66	2,826	2,826	grys	0	0	CEM IV	13,16
579	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	22,9
580	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	25,52
581	0,3	2	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	22,77
582	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	52,91

## CD. MATRYCA DANYCH

583	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	55,61
584	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	52,89
585	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	62,95
586	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	55,91
587	0,3	1,9	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	59,28
588	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	75,3
589	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	77,96
590	0,4	1,8	0,6	1,66	2,826	2,826	grys	0	0	CEM IV	72,18
591	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	47,47
592	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	47,78
593	0,4	1,7	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	50,81
594	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	42,42
595	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	41,42
596	0,5	1,6	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	42,79
597	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	33,93
598	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	38,82
599	0,5	1,5	0,7	1,66	2,826	2,826	grys	0	0	CEM IV	36,45
600	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM IV	6,055
601	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM IV	6,105
602	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM IV	6,141
603	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM IV	78,76
604	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM IV	73,76
605	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,02	0	CEM IV	77,86
606	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	70,35
607	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	78,73
608	0,3	2	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	70,03
609	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	70,33
610	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	67,07
611	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	69,54
612	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	65,96
613	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	66,1
614	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,02	0	CEM IV	64,12
615	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM IV	57,15
616	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM IV	59,61
617	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,01	0	CEM IV	59,41
618	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	45,38
619	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	39,58

## CD. MATRYCA DANYCH

620	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	47,06
621	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	44,29
622	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	39,85
623	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	44,57
624	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	33,94
625	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	32,74
626	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,01	0	CEM IV	35,17
627	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM IV	16,73
628	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM IV	15,9
629	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,02	0	CEM IV	12,99
630	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM IV	78,61
631	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM IV	74,85
632	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,02	0	CEM IV	79,44
633	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	80,4
634	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	81,9
635	0,3	2	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	79,75
636	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	73,35
637	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	73,37
638	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	75,12
639	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	67,28
640	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	76,37
641	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,02	0	CEM IV	73,34
642	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM IV	69,3
643	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM IV	71,34
644	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,01	0	CEM IV	69,12
645	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	54,49
646	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	54,09
647	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	56,28
648	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	59,04
649	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	64,84
650	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	69,23
651	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	31,98
652	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	49,71
653	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,01	0	CEM IV	47,88
654	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM IV	61,45
655	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM IV	61,56
656	0,2	2,3	0,5	1,66	2,34	2,34	żwir	0,07	0	CEM IV	59,35

## CD. MATRYCA DANYCH

657	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM IV	63,01
658	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM IV	66,98
659	0,2	2,1	0,5	1,66	2,34	2,34	żwir	0,06	0	CEM IV	71,1
660	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	71,48
661	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	63,44
662	0,3	2	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	71,39
663	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	69,74
664	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	97,01
665	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	96,73
666	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	69,2
667	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	59,49
668	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0	CEM IV	64,16
669	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM IV	66,77
670	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM IV	54,7
671	0,4	1,8	0,6	1,66	2,34	2,34	żwir	0,05	0	CEM IV	52,67
672	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM IV	66,42
673	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM IV	70,69
674	0,4	1,7	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM IV	68,88
675	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM IV	59,04
676	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM IV	64,84
677	0,5	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0	CEM IV	69,23
678	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM IV	31,98
679	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM IV	49,71
680	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,04	0	CEM IV	47,88
681	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM IV	78,26
682	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM IV	74,56
683	0,2	2,3	0,5	1,66	2,826	2,826	grys	0,07	0	CEM IV	79,45
684	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM IV	87,58
685	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM IV	85,22
686	0,2	2,1	0,5	1,66	2,826	2,826	grys	0,06	0	CEM IV	86,98
687	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	90,85
688	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	84,9
689	0,3	2	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	87,03
690	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	74,85
691	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	74,25
692	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	73,12
693	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	69,48

CD. MATRYCA DANYCH

694	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	67,97
695	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0	CEM IV	72,11
696	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM IV	56,13
697	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM IV	53,55
698	0,4	1,8	0,6	1,66	2,826	2,826	grys	0,05	0	CEM IV	55,44
699	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM IV	55,28
700	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM IV	49,1
701	0,4	1,7	0,7	1,66	2,826	2,826	grys	0,05	0	CEM IV	47,92
702	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,05	0	CEM IV	49,91
703	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,05	0	CEM IV	49,83
704	0,5	1,6	0,7	1,66	2,826	2,826	grys	0,05	0	CEM IV	52,62
705	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM IV	45,07
706	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM IV	47,61
707	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,04	0	CEM IV	46,42
708	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM IV	1,386
709	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM IV	1,187
710	0,2	2,2	0,5	1,66	2,34	2,34	żwir	0,07	0,11	CEM IV	1,336
711	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM IV	1,767
712	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM IV	1,634
713	0,2	2	0,5	1,66	2,34	2,34	żwir	0,06	0,11	CEM IV	1,577
714	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM IV	61,76
715	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM IV	67,1
716	0,3	1,9	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM IV	70,06
717	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM IV	67,65
718	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM IV	63,82
719	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,1	CEM IV	68,82
720	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM IV	62,3
721	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM IV	66,12
722	0,3	1,8	0,6	1,66	2,34	2,34	żwir	0,06	0,09	CEM IV	66,74
723	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM IV	62,72
724	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM IV	66,28
725	0,4	1,7	0,6	1,66	2,34	2,34	żwir	0,05	0,09	CEM IV	63,96
726	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM IV	54,71
727	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM IV	55,9
728	0,4	1,6	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM IV	56,36
729	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM IV	47,56
730	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM IV	48,17

CD. MATRYCA DANYCH

731	0,5	1,5	0,7	1,66	2,34	2,34	żwir	0,05	0,08	CEM IV	44,12
732	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM IV	30,15
733	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM IV	30,38
734	0,5	1,4	0,7	1,66	2,34	2,34	żwir	0,04	0,07	CEM IV	32,88
735	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM IV	0,793
736	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM IV	0,717
737	0,2	2,2	0,5	1,66	2,826	2,826	grys	0,07	0,11	CEM IV	0,868
738	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM IV	2,151
739	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM IV	2,161
740	0,2	2	0,5	1,66	2,826	2,826	grys	0,06	0,11	CEM IV	2,357
741	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM IV	84,58
742	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM IV	85,97
743	0,3	1,9	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM IV	83,57
744	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM IV	75,98
745	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM IV	77,2
746	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,1	CEM IV	77,96
747	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM IV	74,87
748	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM IV	75,13
749	0,3	1,8	0,6	1,66	2,826	2,826	grys	0,06	0,09	CEM IV	77,58
750	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM IV	68,48
751	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM IV	67,06
752	0,4	1,7	0,6	1,66	2,826	2,826	grys	0,05	0,09	CEM IV	65,83
753	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM IV	60,12
754	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM IV	59,19
755	0,4	1,6	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM IV	60,6
756	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM IV	43,83
757	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM IV	43,4
758	0,5	1,5	0,7	1,66	2,826	2,826	grys	0,05	0,08	CEM IV	42,76
759	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM IV	60,52
760	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM IV	54,14
761	0,5	1,4	0,7	1,66	2,826	2,826	grys	0,04	0,07	CEM IV	52,59
762	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM IV	0,52
763	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM IV	0,582
764	0,2	1,9	0,5	1,66	2,34	2,34	żwir	0,07	0,34	CEM IV	0,446
765	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM IV	0,852
766	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM IV	0,668
767	0,2	1,8	0,5	1,66	2,34	2,34	żwir	0,06	0,32	CEM IV	0,951

CD. MATRYCA DANYCH

768	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM IV	64,16
769	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM IV	63,66
770	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,31	CEM IV	60,3
771	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM IV	58,73
772	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM IV	67,57
773	0,3	1,7	0,6	1,66	2,34	2,34	żwir	0,06	0,29	CEM IV	65,95
774	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM IV	68,37
775	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM IV	69,96
776	0,3	1,6	0,6	1,66	2,34	2,34	żwir	0,06	0,28	CEM IV	70,88
777	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM IV	60,54
778	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM IV	59,85
779	0,4	1,5	0,6	1,66	2,34	2,34	żwir	0,05	0,27	CEM IV	62,07
780	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM IV	54,15
781	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM IV	54,4
782	0,4	1,4	0,7	1,66	2,34	2,34	żwir	0,05	0,25	CEM IV	56,14
783	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM IV	45,24
784	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM IV	46,81
785	0,5	1,3	0,7	1,66	2,34	2,34	żwir	0,05	0,24	CEM IV	44,92
786	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM IV	35,62
787	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM IV	36,03
788	0,5	1,2	0,7	1,66	2,34	2,34	żwir	0,04	0,22	CEM IV	38,15
789	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM IV	0,095
790	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM IV	0,097
791	0,2	1,9	0,5	1,66	2,826	2,826	grys	0,07	0,34	CEM IV	0,098
792	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM IV	0,635
793	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM IV	0,537
794	0,2	1,8	0,5	1,66	2,826	2,826	grys	0,06	0,32	CEM IV	0,626
795	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM IV	68,77
796	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM IV	70,96
797	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,31	CEM IV	70,18
798	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,89	CEM IV	72,25
799	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,89	CEM IV	72,16
800	0,3	1,7	0,6	1,66	2,826	2,826	grys	0,06	0,89	CEM IV	74,84
801	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM IV	70,79
802	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM IV	74,51
803	0,3	1,6	0,6	1,66	2,826	2,826	grys	0,06	0,28	CEM IV	72,56
804	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM IV	64,53

## CD. MATRYCA DANYCH

805	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM IV	70,16
806	0,4	1,5	0,6	1,66	2,826	2,826	grys	0,05	0,27	CEM IV	67,23
807	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM IV	62,96
808	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM IV	60,42
809	0,4	1,4	0,7	1,66	2,826	2,826	grys	0,05	0,25	CEM IV	61,75
810	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM IV	49,69
811	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM IV	50,35
812	0,5	1,3	0,7	1,66	2,826	2,826	grys	0,05	0,24	CEM IV	48,66
813	0,5	1,2	0,7	1,66	2,826	2,826	grys	0,04	0,22	CEM IV	44,2
814	0,5	1,2	0,7	1,66	2,826	2,826	grys	0,04	0,22	CEM IV	45,03
815	0,5	1,2	0,7	1,66	2,826	2,826	żwir	0,04	0,22	CEM IV	44,44



## ZAŁĄCZNIK 3 – WAGI SIECI

### Spis treści

1.	ZADANIE 1.....	330
1.1.	Wagi neuronów dla sieci 3. MLP 12-5-1.....	330
1.2.	Wagi neuronów dla sieci 5. MLP 12-12-1.....	333
1.3.	Wagi neuronów dla sieci 11. MLP 12-11-1.....	340
2.	ZADANIE 2.....	347
2.1.	Wagi neuronów dla sieci 3. MLP 7-13-6.....	347
2.2.	Wagi neuronów dla sieci 5. MLP 7-9-6.....	354
2.3.	Wagi neuronów dla sieci 9. MLP 7-10-6.....	359

## 1. ZADANIE 1

### 1.1. WAGI NEURONÓW DLA SIECI 3. MLP 12-5-1

Tabela 1.1. Wagi dla sieci 3. MLP 12-5-1

Lp.	Połączenia	Wartości wag
1	w/s → ukryty neuron 1	-52,0103
2	masa cementu → ukryty neuron 1	84,8023
3	masa wody → ukryty neuron 1	-37,6553
4	masa kruszywa frakcji [2-8 mm] → ukryty neuron 1	-11,1727
5	masa kruszywa frakcji [8-16 mm] → ukryty neuron 1	-5,6038
6	masa domieszki → ukryty neuron 1	-57,6715
7	masa mikrokrzemionki → ukryty neuron 1	-76,0963
8	rodzaj kruszywa grubego (grys) → ukryty neuron 1	-5,5812
9	rodzaj kruszywa grubego (żwir) → ukryty neuron 1	-22,4439
10	rodzaj cementu (CEM I) → ukryty neuron 1	-9,0372
11	rodzaj cementu (CEM II) → ukryty neuron 1	-9,6320
12	rodzaj cementu (CEM IV) → ukryty neuron 1	-9,3694
13	w/s → ukryty neuron 2	20,7073
14	masa cementu → ukryty neuron 2	-11,7944
15	masa wody → ukryty neuron 2	-20,7438
16	masa kruszywa frakcji [2-8 mm] → ukryty neuron 2	16,0058
17	masa kruszywa frakcji [8-16 mm] → ukryty neuron 2	-5,4817
18	masa domieszki → ukryty neuron 2	6,3525
19	masa mikro- krzemionki → ukryty neuron 2	-14,3050
20	rodzaj kruszywa grubego (grys) → ukryty neuron 2	-5,5129
21	rodzaj kruszywa grubego (żwir) → ukryty neuron 2	5,9702
22	rodzaj cementu (CEM I) → ukryty neuron 2	-0,4575
23	rodzaj cementu (CEM II) → ukryty neuron 2	-1,2230
24	rodzaj cementu (CEM IV) → ukryty neuron 2	2,1794

CD. Tabela 1.1. Wagi dla sieci 3. MLP 12-5-1

25	w/s → ukryty neuron 3	63,4066
26	masa cementu → ukryty neuron 3	53,9024
27	masa wody → ukryty neuron 3	46,2661
28	masa kruszywa frakcji [2-8 mm] → ukryty neuron 3	-21,0797
29	masa kruszywa frakcji [8-16 mm] → ukryty neuron 3	-2,5772
30	masa domieszki → ukryty neuron 3	53,5762
31	masa mikrokrzemionki → ukryty neuron 3	26,4314
32	rodzaj kruszywa grubego (grys) → ukryty neuron 3	-2,4763
33	rodzaj kruszywa grubego (żwir) → ukryty neuron 3	-26,1861
34	rodzaj cementu (CEM I) → ukryty neuron 3	-9,7290
35	rodzaj cementu (CEM II) → ukryty neuron 3	-9,5431
36	rodzaj cementu (CEM IV) → ukryty neuron 3	-9,4373
37	w/s → ukryty neuron 4	7,8297
38	masa cementu → ukryty neuron 4	-25,4694
39	masa wody → ukryty neuron 4	-8,2868
40	masa kruszywa frakcji [2-8 mm] → ukryty neuron 4	29,6886
41	masa kruszywa frakcji [8-16 mm] → ukryty neuron 4	-8,6870
42	masa domieszki → ukryty neuron 4	-10,2184
43	masa mikrokrzemionki → ukryty neuron 4	-4,9503
44	rodzaj kruszywa grubego (grys) → ukryty neuron 4	-8,7045
45	rodzaj kruszywa grubego (żwir) → ukryty neuron 4	16,9875
46	rodzaj cementu (CEM I) → ukryty neuron 4	0,2046
47	rodzaj cementu (CEM II) → ukryty neuron 4	-5,3123
48	rodzaj cementu (CEM IV) → ukryty neuron 4	13,3965
49	w/s → ukryty neuron 5	-4,9863
50	masa cementu → ukryty neuron 5	12,8518
51	masa wody → ukryty neuron 5	3,3309
52	masa kruszywa frakcji [2-8 mm] → ukryty neuron 5	7,3282

CD. Tabela 1.1. Wagi dla sieci 3. MLP 12-5-1

53	masa kruszywa frakcji [8-16 mm] → ukryty neuron 5	8,4716
54	masa domieszki → ukryty neuron 5	17,4251
55	masa mikrokrzemionki → ukryty neuron 5	11,8582
56	rodzaj kruszywa grubego (grys) → ukryty neuron 5	8,5149
57	rodzaj kruszywa grubego (żwir) → ukry- ty neuron 5	6,4552
58	rodzaj cementu (CEM I) → ukryty neuron 5	15,8385
59	rodzaj cementu (CEM II) → ukryty neuron 5	21,7023
60	rodzaj cementu (CEM IV) → ukryty neuron 5	-22,5449
61	przesunięcie wejściowych → ukryty neuron 1	-28,0109
62	przesunięcie wejściowych → ukryty neuron 2	0,4986
63	przesunięcie wejściowych → ukryty neuron 3	-28,7458
64	przesunięcie wejściowych → ukryty neuron 4	8,2825
65	przesunięcie wejściowych → ukryty neuron 5	14,9822
66	ukryty neuron 1 → wytrzymałość [MPa]	54,5354
67	ukryty neuron 2 → wytrzymałość [MPa]	-1,2103
68	ukryty neuron 3 → wytrzymałość [MPa]	58,4367
69	ukryty neuron 4 → wytrzymałość [MPa]	-1,3437
70	ukryty neuron 5 → wytrzymałość [MPa]	1,9039
71	przesunięcie ukrytych → wytrzymałość [MPa]	-58,1127

## 1.2. WAGI NEURONÓW DLA SIECI 5. MLP 12-12-1

Tabela 1.2. Wagi dla sieci 5. MLP 12-12-1

Lp.	Połączenia	Wartości wag
1	w/s → ukryty neuron 1	2,0012
2	masa cementu → ukryty neuron 1	-14,0155
3	masa wody → ukryty neuron 1	3,2126
4	masa kruszywa frakcji [2-8 mm] → ukryty neuron 1	2,7727
5	masa kruszywa frakcji [8-16 mm] → ukryty neuron 1	0,5324
6	masa domieszki → ukryty neuron 1	-6,1360
7	masa mikrokrzemionki → ukryty neuron 1	11,9959
8	rodzaj kruszywa grubego (grys) → ukryty neuron 1	0,5204
9	rodzaj kruszywa grubego (żwir) → ukryty neuron 1	5,4078
10	rodzaj cementu (CEM I) → ukryty neuron 1	1,7365
11	rodzaj cementu (CEM II) → ukryty neuron 1	1,9802
12	rodzaj cementu (CEM IV) → ukryty neuron 1	2,2947
13	w/s → ukryty neuron 2	-1,3572
14	masa cementu → ukryty neuron 2	-0,7402
15	masa wody → ukryty neuron 2	0,6054
16	masa kruszywa frakcji [2-8 mm] → ukryty neuron 2	-4,5932
17	masa kruszywa frakcji [8-16 mm] → ukryty neuron 2	-0,7597
18	masa domieszki → ukryty neuron 2	-3,3290
19	masa mikrokrzemionki → ukryty neuron 2	-0,8183
20	rodzaj kruszywa grubego (grys) → ukryty neuron 2	-0,7523
21	rodzaj kruszywa grubego (żwir) → ukryty neuron 2	0,5271
22	rodzaj cementu (CEM I) → ukryty neuron 2	-1,9997
23	rodzaj cementu (CEM II) → ukryty neuron 2	-0,2682
24	rodzaj cementu (CEM IV) → ukryty neuron 2	1,9730

CD. Tabela 1.2. Wagi dla sieci 5. MLP 12-12-1

25	w/s → ukryty neuron 3	-9,8435
26	masa cementu → ukryty neuron 3	1,5985
27	masa wody → ukryty neuron 3	-8,9647
28	masa kruszywa frakcji [2-8 mm] → ukryty neuron 3	1,8500
29	masa kruszywa frakcji [8-16 mm] → ukryty neuron 3	-0,3108
30	masa domieszki → ukryty neuron 3	3,3073
31	masa mikrokrzemionki → ukryty neuron 3	3,6128
32	rodzaj kruszywa grubego (grys) → ukryty neuron 3	-0,3006
33	rodzaj kruszywa grubego (żwir) → ukryty neuron 3	0,0135
34	rodzaj cementu (CEM I) → ukryty neuron 3	0,0643
35	rodzaj cementu (CEM II) → ukryty neuron 3	0,0245
36	rodzaj cementu (CEM IV) → ukryty neuron 3	-0,4061
37	w/s → ukryty neuron 4	2,3758
38	masa cementu → ukryty neuron 4	0,3892
39	masa wody → ukryty neuron 4	5,7007
40	masa kruszywa frakcji [2-8 mm] → ukryty neuron 4	4,9817
41	masa kruszywa frakcji [8-16 mm] → ukryty neuron 4	4,6946
42	masa domieszki → ukryty neuron 4	3,0510
43	masa mikrokrzemionki → ukryty neuron 4	-4,2998
44	rodzaj kruszywa grubego (grys) → ukryty neuron 4	4,7210
45	rodzaj kruszywa grubego (żwir) → ukryty neuron 4	-2,8288
46	rodzaj cementu (CEM I) → ukryty neuron 4	-0,5320
47	rodzaj cementu (CEM II) → ukryty neuron 4	6,3996
48	rodzaj cementu (CEM IV) → ukryty neuron 4	-4,0238
49	w/s → ukryty neuron 5	1,0071
50	masa cementu → ukryty neuron 5	-0,8075
51	masa wody → ukryty neuron 5	0,4382

CD. Tabela 1.2. Wagi dla sieci 5. MLP 12-12-1

52	masa kruszywa frakcji [2-8 mm] → ukryty neuron 5	5,6513
53	masa kruszywa frakcji [8-16 mm] → ukryty neuron 5	-2,5185
54	masa domieszki → ukryty neuron 5	6,6158
55	masa mikrokrzemionki → ukryty neuron 5	-1,4018
56	rodzaj kruszywa grubego (grys) → ukryty neuron 5	-2,5358
57	rodzaj kruszywa grubego (żwir) → ukryty neuron 5	1,3327
58	rodzaj cementu (CEM I) → ukryty neuron 5	-0,8128
59	rodzaj cementu (CEM II) → ukryty neuron 5	-0,6384
60	rodzaj cementu (CEM IV) → ukryty neuron 5	0,3160
61	w/s → ukryty neuron 6	-7,3739
62	masa cementu → ukryty neuron 6	2,4238
63	masa wody → ukryty neuron 6	13,3283
64	masa kruszywa frakcji [2-8 mm] → ukryty neuron 6	-5,7513
65	masa kruszywa frakcji [8-16 mm] → ukryty neuron 6	2,0215
66	masa domieszki → ukryty neuron 6	9,6690
67	masa mikrokrzemionki → ukryty neuron 6	0,3751
68	rodzaj kruszywa grubego (grys) → ukryty neuron 6	1,9602
69	rodzaj kruszywa grubego (żwir) → ukryty neuron 6	-3,6202
70	rodzaj cementu (CEM I) → ukryty neuron 6	-0,4836
71	rodzaj cementu (CEM II) → ukryty neuron 6	-0,1505
72	rodzaj cementu (CEM IV) → ukryty neuron 6	-0,9998
73	w/s → ukryty neuron 7	-2,1032
74	masa cementu → ukryty neuron 7	4,3226
75	masa wody → ukryty neuron 7	-3,8101
76	masa kruszywa frakcji [2-8 mm] → ukryty neuron 7	-3,1388

CD. Tabela 1.2. Wagi dla sieci 5. MLP 12-12-1

77	masa kruszywa frakcji [8-16 mm] → ukryty neuron 7	-1,8924
78	masa domieszki → ukryty neuron 7	5,3603
79	masa mikrokrzemionki → ukryty neuron 7	3,8837
80	rodzaj kruszywa grubego (grys) → ukryty neuron 7	-1,9449
81	rodzaj kruszywa grubego (żwir) → ukryty neuron 7	1,2308
82	rodzaj cementu (CEM I) → ukryty neuron 7	5,4494
83	rodzaj cementu (CEM II) → ukryty neuron 7	-4,4817
84	rodzaj cementu (CEM IV) → ukryty neuron 7	-1,6988
85	w/s → ukryty neuron 8	2,4797
86	masa cementu → ukryty neuron 8	1,3183
87	masa wody → ukryty neuron 8	4,3466
88	masa kruszywa frakcji [2-8 mm] → ukryty neuron 8	1,5157
89	masa kruszywa frakcji [8-16 mm] → ukryty neuron 8	0,2930
90	masa domieszki → ukryty neuron 8	4,1821
91	masa mikrokrzemionki → ukryty neuron 8	-0,5163
92	rodzaj kruszywa grubego(grys) → ukryty neuron 8	0,3580
93	rodzaj kruszywa grubego (żwir) → ukryty neuron 8	-2,3359
94	rodzaj cementu (CEM I) → ukryty neuron 8	0,0382
95	rodzaj cementu (CEM II) → ukryty neuron 8	1,1558
96	rodzaj cementu (CEM IV) → ukryty neuron 8	-3,1666
97	w/s → ukryty neuron 9	-2,9805
98	masa cementu → ukryty neuron 9	-1,5282
99	masa wody → ukryty neuron 9	3,7740
100	masa kruszywa frakcji [2-8 mm] → ukryty neuron 9	-1,0056
101	masa kruszywa frakcji [8-16 mm] → ukryty neuron 9	0,7773
102	masa domieszki → ukryty neuron 9	18,8226



CD. Tabela 1.2. Wagi dla sieci 5. MLP 12-12-1

103	masa mikrokrzemionki → ukryty neuron 9	-2,5263
104	rodzaj kruszywa grubego (grys) → ukryty neuron 9	0,7780
105	rodzaj kruszywa grubego (żwir) → ukryty neuron 9	0,7210
106	rodzaj cementu (CEM I) → ukryty neuron 9	-0,7910
107	rodzaj cementu (CEM II) → ukryty neuron 9	3,2734
108	rodzaj cementu (CEM IV) → ukryty neuron 9	-0,8634
109	w/s → ukryty neuron 10	6,6624
110	masa cementu → ukryty neuron 10	6,8471
111	masa wody → ukryty neuron 10	7,3342
112	masa kruszywa frakcji [2-8 mm] → ukryty neuron 10	4,9913
113	masa kruszywa frakcji [8-16 mm] → ukryty neuron 10	5,6728
114	masa domieszki → ukryty neuron 10	4,5863
115	masa mikrokrzemionki → ukryty neuron 10	-1,6958
116	rodzaj kruszywa grubego (grys) → ukryty neuron 10	5,7027
117	rodzaj kruszywa grubego (żwir) → ukryty neuron 10	-7,6248
118	rodzaj cementu (CEM I) → ukryty neuron 10	3,1433
119	rodzaj cementu (CEM II) → ukryty neuron 10	3,3284
120	rodzaj cementu (CEM IV) → ukryty neuron 10	-8,4513
121	w/s → ukryty neuron 11	1,6248
122	masa cementu → ukryty neuron 11	4,7696
123	masa wody → ukryty neuron 11	2,3201
124	masa kruszywa frakcji [2-8 mm] → ukryty neuron 11	-5,0027
125	masa kruszywa frakcji [8-16 mm] → ukryty neuron 11	0,7227
126	masa domieszki → ukryty neuron 11	25,4150
127	masa mikrokrzemionki → ukryty neuron 11	5,5359

CD. Tabela 1.2. Wagi dla sieci 5. MLP 12-12-1

128	rodzaj kruszywa grubego (grys) → ukryty neuron 11	0,7401
129	rodzaj kruszywa grubego (żwir) → ukryty neuron 11	-3,3977
130	rodzaj cementu (CEM I) → ukryty neuron 11	-3,3542
131	rodzaj cementu (CEM II) → ukryty neuron 11	-1,3556
132	rodzaj cementu (CEM IV) → ukryty neuron 11	2,0378
133	w/s → ukryty neuron 12	-4,0167
134	masa cementu → ukryty neuron 12	-1,1501
135	masa wody → ukryty neuron 12	-4,0617
136	masa kruszywa frakcji [2-8 mm] → ukryty neuron 12	-1,3396
137	masa kruszywa frakcji [8-16 mm] → ukryty neuron 12	-1,6577
138	masa domieszki → ukryty neuron 12	4,1905
139	masa mikrokrzemionki → ukryty neuron 12	3,5953
140	rodzaj kruszywa grubego (grys) → ukryty neuron 12	-1,7545
141	rodzaj kruszywa grubego (żwir) → ukryty neuron 12	1,2997
142	rodzaj cementu (CEM I) → ukryty neuron 12	0,7029
143	rodzaj cementu (CEM II) → ukryty neuron 12	-4,8284
144	rodzaj cementu (CEM IV) → ukryty neuron 12	3,7478
145	przesunięcie wejściowych → ukryty neuron 1	5,9643
146	przesunięcie wejściowych → ukryty neuron 2	-0,2789
147	przesunięcie wejściowych → ukryty neuron 3	-0,3118
148	przesunięcie wejściowych → ukryty neuron 4	1,8836
149	przesunięcie wejściowych → ukryty neuron 5	-1,1877
150	przesunięcie wejściowych → ukryty neuron 6	-1,5972
151	przesunięcie wejściowych → ukryty neuron 7	-0,7149

CD. Tabela 1.2. Wagi dla sieci 5. MLP 12-12-1

152	przesunięcie wejściowych → ukryty neuron 8	-1,9940
153	przesunięcie wejściowych → ukryty neuron 9	1,5654
154	przesunięcie wejściowych → ukryty neuron 10	-1,9608
155	przesunięcie wejściowych → ukryty neuron 11	-2,6708
156	przesunięcie wejściowych → ukryty neuron 12	-0,4056
157	ukryty neuron 1 → wytrzymałość [MPa]	-14,4600
158	ukryty neuron 2 → wytrzymałość [MPa]	5,7956
159	ukryty neuron 3 → wytrzymałość [MPa]	-14,2818
160	ukryty neuron 4 → wytrzymałość [MPa]	-3,3314
161	ukryty neuron 5 → wytrzymałość [MPa]	-2,2182
162	ukryty neuron 6 → wytrzymałość [MPa]	2,4062
163	ukryty neuron 7 → wytrzymałość [MPa]	0,8408
164	ukryty neuron 8 → wytrzymałość [MPa]	-1,2394
165	ukryty neuron 9 → wytrzymałość [MPa]	4,7632
166	ukryty neuron 10 → wytrzymałość [MPa]	5,6905
167	ukryty neuron 11 → wytrzymałość [MPa]	0,8417
168	ukryty neuron 12 → wytrzymałość [MPa]	-2,4980
169	przesunięcie ukrytych → wytrzymałość [MPa]	-3,0743

### 1.3. WAGI NEURONÓW DLA SIECI 11. MLP 12-11-1

Tabela 1.3. Wagi dla sieci 11. MLP 12-11-1

Lp.	Połączenia	Wartości wag
1	w/s → ukryty neuron 1	-8,0943
2	masa cementu → ukryty neuron 1	-0,5298
3	masa wody → ukryty neuron 1	-18,2470
4	masa kruszywa frakcji [2-8 mm] → ukryty neuron 1	1,6662
5	masa kruszywa frakcji [8-16 mm] → ukryty neuron 1	0,0744
6	masa domieszki → ukryty neuron 1	-11,8782
7	masa mikrokrzemionki → ukryty neuron 1	3,1573
8	rodzaj kruszywa grubego (grys) → ukryty neuron 1	0,0897
9	rodzaj kruszywa grubego (żwir) → ukryty neuron 1	2,2012
10	rodzaj cementu (CEM I) → ukryty neuron 1	2,8808
11	rodzaj cementu (CEM II) → ukryty neuron 1	-2,2811
12	rodzaj cementu (CEM IV) → ukryty neuron 1	1,6970
13	w/s → ukryty neuron 2	3,7274
14	masa cementu → ukryty neuron 2	-0,5138
15	masa wody → ukryty neuron 2	3,6317
16	masa kruszywa frakcji [2-8 mm] → ukryty neuron 2	1,7655
17	masa kruszywa frakcji [8-16 mm] → ukryty neuron 2	-0,7067
18	masa domieszki → ukryty neuron 2	-0,7324
19	masa mikrokrzemionki → ukryty neuron 2	-6,4106
20	rodzaj kruszywa grubego (grys) → ukryty neuron 2	-0,8221
21	rodzaj kruszywa grubego (żwir) → ukryty neuron 2	1,6141
22	rodzaj cementu (CEM I) → ukryty neuron 2	-1,4289
23	rodzaj cementu (CEM II) → ukryty neuron 2	4,5288
24	rodzaj cementu (CEM IV) → ukryty neuron 2	-2,2715

CD. Tabela 1.3. Wagi dla sieci 11. MLP 12-11-1

25	w/s → ukryty neuron 3	2,5659
26	masa cementu → ukryty neuron 3	-1,9038
27	masa wody → ukryty neuron 3	-2,7265
28	masa kruszywa frakcji [2-8 mm] → ukryty neuron 3	6,3885
29	masa kruszywa frakcji [8-16 mm] → ukryty neuron 3	-1,0779
30	masa domieszki → ukryty neuron 3	0,3164
31	masa mikrokrzemionki → ukryty neuron 3	-7,1767
32	rodzaj kruszywa grubego (grys) → ukryty neuron 3	-1,0625
33	rodzaj kruszywa grubego (żwir) → ukryty neuron 3	-0,2682
34	rodzaj cementu (CEM I) → ukryty neuron 3	2,0032
35	rodzaj cementu (CEM II) → ukryty neuron 3	-1,4539
36	rodzaj cementu (CEM IV) → ukryty neuron 3	-1,9702
37	w/s → ukryty neuron 4	-2,1950
38	masa cementu → ukryty neuron 4	-1,4779
39	masa wody → ukryty neuron 4	4,7693
40	masa kruszywa frakcji [2-8 mm] → ukryty neuron 4	3,2377
41	masa kruszywa frakcji [8-16 mm] → ukryty neuron 4	-0,5773
42	masa domieszki → ukryty neuron 4	0,0770
43	masa mikrokrzemionki → ukryty neuron 4	-1,8166
44	rodzaj kruszywa grubego (grys) → ukryty neuron 4	-0,6336
45	rodzaj kruszywa grubego (żwir) → ukryty neuron 4	-0,7142
46	rodzaj cementu (CEM I) → ukryty neuron 4	-0,2596
47	rodzaj cementu (CEM II) → ukryty neuron 4	-0,3422
48	rodzaj cementu (CEM IV) → ukryty neuron 4	-0,7335
49	w/s → ukryty neuron 5	-7,9114
50	masa cementu → ukryty neuron 5	-3,2373

CD. Tabela 1.3. Wagi dla sieci 11. MLP 12-11-1

51	masa wody → ukryty neuron 5	-11,4887
52	masa kruszywa frakcji [2-8 mm] → ukryty neuron 5	2,1182
53	masa kruszywa frakcji [8-16 mm] → ukryty neuron 5	0,0051
54	masa domieszki → ukryty neuron 5	-6,3137
55	masa mikrokrzemionki → ukryty neuron 5	2,9831
56	rodzaj kruszywa grubego (grys) → ukryty neuron 5	-0,0009
57	rodzaj kruszywa grubego (żwir) → ukryty neuron 5	2,3815
58	rodzaj cementu (CEM I) → ukryty neuron 5	1,1042
59	rodzaj cementu (CEM II) → ukryty neuron 5	0,8496
60	rodzaj cementu (CEM IV) → ukryty neuron 5	0,4763
61	w/s → ukryty neuron 6	0,6417
62	masa cementu → ukryty neuron 6	-1,6994
63	masa wody → ukryty neuron 6	-6,4121
64	masa kruszywa frakcji [2-8 mm] → ukryty neuron 6	1,7388
65	masa kruszywa frakcji [8-16 mm] → ukryty neuron 6	-0,0586
66	masa domieszki → ukryty neuron 6	-22,8562
67	masa mikrokrzemionki → ukryty neuron 6	2,3514
68	rodzaj kruszywa grubego (grys) → ukryty neuron 6	-0,1094
69	rodzaj kruszywa grubego (żwir) → ukryty neuron 6	0,8195
70	rodzaj cementu (CEM I) → ukryty neuron 6	0,3788
71	rodzaj cementu (CEM II) → ukryty neuron 6	-0,2386
72	rodzaj cementu (CEM IV) → ukryty neuron 6	0,5879
73	w/s → ukryty neuron 7	-2,3336
74	masa cementu → ukryty neuron 7	-2,8587
75	masa wody → ukryty neuron 7	-8,2327
76	masa kruszywa frakcji [2-8 mm] → ukryty neuron 7	-2,0758

CD. Tabela 1.3. Wagi dla sieci 11. MLP 12-11-1

77	masa kruszywa frakcji [8-16 mm] → ukryty neuron 7	-2,7708
78	masa domieszki → ukryty neuron 7	-2,5831
79	masa mikrokrzemionki → ukryty neuron 7	3,2959
80	rodzaj kruszywa grubego (grys) → ukryty neuron 7	-2,7469
81	rodzaj kruszywa grubego (żwir) → ukryty neuron 7	0,0474
82	rodzaj cementu (CEM I) → ukryty neuron 7	-8,6922
83	rodzaj cementu (CEM II) → ukryty neuron 7	-9,8142
84	rodzaj cementu (CEM IV) → ukryty neuron 7	15,7454
85	w/s → ukryty neuron 8	2,5475
86	masa cementu → ukryty neuron 8	-4,2858
87	masa wody → ukryty neuron 8	-2,4936
88	masa kruszywa frakcji [2-8 mm] → ukryty neuron 8	5,7805
89	masa kruszywa frakcji [8-16 mm] → ukryty neuron 8	-3,1175
90	masa domieszki → ukryty neuron 8	9,1178
91	masa mikrokrzemionki → ukryty neuron 8	-5,3530
92	rodzaj kruszywa grubego (grys) → ukryty neuron 8	-3,0244
93	rodzaj kruszywa grubego (żwir) → ukryty neuron 8	4,3453
94	rodzaj cementu (CEM I) → ukryty neuron 8	-0,3886
95	rodzaj cementu (CEM II) → ukryty neuron 8	-0,5561
96	rodzaj cementu (CEM IV) → ukryty neuron 8	2,2378
97	w/s → ukryty neuron 9	1,8331
98	masa cementu → ukryty neuron 9	-1,2678
99	masa wody → ukryty neuron 9	2,1138
100	masa kruszywa frakcji [2-8 mm] → ukryty neuron 9	2,7870
101	masa kruszywa frakcji [8-16 mm] → ukryty neuron 9	2,8876
102	masa domieszki → ukryty neuron 9	-7,4938

CD. Tabela 1.3. Wagi dla sieci 11. MLP 12-11-1

103	masa mikrokrzemionki → ukryty neuron 9	-0,0760
104	rodzaj kruszywa grubego (grys) → ukryty neuron 9	2,9444
105	rodzaj kruszywa grubego (żwir) → ukryty neuron 9	-1,7531
106	rodzaj cementu (CEM I) → ukryty neuron 9	2,6632
107	rodzaj cementu (CEM II) → ukryty neuron 9	2,3005
108	rodzaj cementu (CEM IV) → ukryty neuron 9	-3,8502
109	w/s → ukryty neuron 10	-3,9926
110	masa cementu → ukryty neuron 10	16,1315
111	masa wody → ukryty neuron 10	2,3885
112	masa kruszywa frakcji [2-8 mm] → ukryty neuron 10	-5,6258
113	masa kruszywa frakcji [8-16 mm] → ukryty neuron 10	-0,1560
114	masa domieszki → ukryty neuron 10	-7,4236
115	masa mikrokrzemionki → ukryty neuron 10	-12,2348
116	rodzaj kruszywa grubego (grys) → ukryty neuron 10	-0,1814
117	rodzaj kruszywa grubego (żwir) → ukryty neuron 10	-5,7002
118	rodzaj cementu (CEM I) → ukryty neuron 10	-1,3077
119	rodzaj cementu (CEM II) → ukryty neuron 10	-2,8051
120	rodzaj cementu (CEM IV) → ukryty neuron 10	-1,8076
121	w/s → ukryty neuron 11	-4,3698
122	masa cementu → ukryty neuron 11	-0,7878
123	masa wody → ukryty neuron 11	4,0651
124	masa kruszywa frakcji [2-8 mm] → ukryty neuron 11	-1,2319
125	masa kruszywa frakcji [8-16 mm] → ukryty neuron 11	0,1824
126	masa domieszki → ukryty neuron 11	5,2808
127	masa mikrokrzemionki → ukryty neuron 11	-2,1225



CD. Tabela 1.3. Wagi dla sieci 11. MLP 12-11-1

128	rodzaj kruszywa grubego (grys) → ukryty neuron 11	0,1618
129	rodzaj kruszywa grubego (żwir) → ukryty neuron 11	-1,7948
130	rodzaj cementu (CEM I) → ukryty neuron 11	-0,3169
131	rodzaj cementu (CEM II) → ukryty neuron 11	-5,1260
132	rodzaj cementu (CEM IV) → ukryty neuron 11	3,6835
133	przesunięcie wejściowych → ukryty neuron 1	2,2703
134	przesunięcie wejściowych → ukryty neuron 2	0,9021
135	przesunięcie wejściowych → ukryty neuron 3	-1,3700
136	przesunięcie wejściowych → ukryty neuron 4	-1,2379
137	przesunięcie wejściowych → ukryty neuron 5	2,4122
138	przesunięcie wejściowych → ukryty neuron 6	0,7445
139	przesunięcie wejściowych → ukryty neuron 7	-2,7597
140	przesunięcie wejściowych → ukryty neuron 8	1,2278
141	przesunięcie wejściowych → ukryty neuron 9	1,1663
142	przesunięcie wejściowych → ukryty neuron 10	-5,8844
143	przesunięcie wejściowych → ukryty neuron 11	-1,6505
144	ukryty neuron 1 → wytrzymałość [MPa]	-4,9846
145	ukryty neuron 2 → wytrzymałość [MPa]	-1,7167
146	ukryty neuron 3 → wytrzymałość [MPa]	-0,2048
147	ukryty neuron 4 → wytrzymałość [MPa]	-1,3578
148	ukryty neuron 5 → wytrzymałość [MPa]	-7,3253
149	ukryty neuron 6 → wytrzymałość [MPa]	-4,8443
150	ukryty neuron 7 → wytrzymałość [MPa]	-2,0415
151	ukryty neuron 8 → wytrzymałość [MPa]	-1,5779
152	ukryty neuron 9 → wytrzymałość [MPa]	-1,1062
153	ukryty neuron 10 → wytrzymałość [MPa]	10,8257

CD. Tabela 1.3. Wagi dla sieci 11. MLP 12-11-1

154	ukryty neuron 11 → wytrzymałość [MPa]	0,9004
155	przesunięcie ukrytych → wytrzymałość [MPa]	-3,6233

## 2. ZADANIE 2

### 2.1. WAGI NEURONÓW DLA SIECI 3. MLP 7-13-6

Tabela 2.1. Wagi dla sieci 3. MLP 7-13-6

Lp.	Połączenia	Wartości wag
1	w/s → ukryty neuron 1	-0,2909
2	wytrzymałość [MPa] → ukryty neuron 1	-5,9205
3	rodzaj kruszywa grubego (grys) → ukryty neuron 1	0,3075
4	rodzaj kruszywa grubego (żwir) → ukryty neuron 1	-0,2594
5	rodzaj cementu (CEM I) → ukryty neuron 1	-0,0201
6	rodzaj cementu (CEM II) → ukryty neuron 1	-0,0534
7	rodzaj cementu (CEM IV) → ukryty neuron 1	0,0971
8	w/s → ukryty neuron 2	-1,8301
9	wytrzymałość [MPa] → ukryty neuron 2	0,3614
10	rodzaj kruszywa grubego (grys) → ukryty neuron 2	-2,2347
11	rodzaj kruszywa grubego (żwir) → ukryty neuron 2	1,1316
12	rodzaj cementu (CEM I) → ukryty neuron 2	-0,4323
13	rodzaj cementu (CEM II) → ukryty neuron 2	-0,3586
14	rodzaj cementu (CEM IV) → ukryty neuron 2	-0,3287
15	w/s → ukryty neuron 3	0,3584
16	wytrzymałość [MPa] → ukryty neuron 3	0,1058
17	rodzaj kruszywa grubego (grys) → ukryty neuron 3	0,9287
18	rodzaj kruszywa grubego (żwir) → ukryty neuron 3	-0,2548
19	rodzaj cementu (CEM I) → ukryty neuron 3	0,2011
20	rodzaj cementu (CEM II) → ukryty neuron 3	0,1898
21	rodzaj cementu (CEM IV) → ukryty neuron 3	0,1927
22	w/s → ukryty neuron 4	-0,5883
23	wytrzymałość [MPa] → ukryty neuron 4	-0,7002
24	rodzaj kruszywa grubego (grys) → ukryty neuron 4	-1,9020

CD. Tabela 2.1. Wagi dla sieci 3. MLP 7-13-6

25	rodzaj kruszywa grubego (żwir) → ukryty neuron 4	1,5377
26	rodzaj cementu (CEM I) → ukryty neuron 4	-0,1447
27	rodzaj cementu (CEM II) → ukryty neuron 4	-0,1333
28	rodzaj cementu (CEM IV) → ukryty neuron 4	-0,1942
29	w/s → ukryty neuron 5	-1,4339
30	wytrzymałość [MPa] → ukryty neuron 5	0,1267
31	rodzaj kruszywa grubego (grys) → ukryty neuron 5	-0,2340
32	rodzaj kruszywa grubego (żwir) → ukryty neuron 5	-0,0659
33	rodzaj cementu (CEM I) → ukryty neuron 5	-0,1376
34	rodzaj cementu (CEM II) → ukryty neuron 5	-0,1350
35	rodzaj cementu (CEM IV) → ukryty neuron 5	-0,1271
36	w/s → ukryty neuron 6	0,6114
37	wytrzymałość [MPa] → ukryty neuron 6	-12,1072
38	rodzaj kruszywa grubego (grys) → ukryty neuron 6	-0,2575
39	rodzaj kruszywa grubego (żwir) → ukryty neuron 6	-0,3950
40	rodzaj cementu (CEM I) → ukryty neuron 6	-0,2479
41	rodzaj cementu (CEM II) → ukryty neuron 6	-0,3007
42	rodzaj cementu (CEM IV) → ukryty neuron 6	-0,2393
43	w/s → ukryty neuron 7	1,5863
44	wytrzymałość [MPa] → ukryty neuron 7	0,5464
45	rodzaj kruszywa grubego (grys) → ukryty neuron 7	2,1968
46	rodzaj kruszywa grubego (żwir) → ukryty neuron 7	-2,6359
47	rodzaj cementu (CEM I) → ukryty neuron 7	-0,1686
48	rodzaj cementu (CEM II) → ukryty neuron 7	-0,1497
49	rodzaj cementu (CEM IV) → ukryty neuron 7	-0,1394
50	w/s → ukryty neuron 8	2,2039
51	wytrzymałość [MPa] → ukryty neuron 8	-0,6040

CD. Tabela 2.1. Wagi dla sieci 3. MLP 7-13-6

52	rodzaj kruszywa grubego (grys) → ukryty neuron 8	0,7512
53	rodzaj kruszywa grubego (żwir) → ukryty neuron 8	-0,3509
54	rodzaj cementu (CEM I) → ukryty neuron 8	0,2034
55	rodzaj cementu (CEM II) → ukryty neuron 8	0,1379
56	rodzaj cementu (CEM IV) → ukryty neuron 8	0,1005
57	w/s → ukryty neuron 9	0,0324
58	wytrzymałość [MPa] → ukryty neuron 9	-0,0383
59	rodzaj kruszywa grubego (grys) → ukryty neuron 9	-0,2398
60	rodzaj kruszywa grubego (żwir) → ukryty neuron 9	0,3811
61	rodzaj cementu (CEM I) → ukryty neuron 9	0,1125
62	rodzaj cementu (CEM II) → ukryty neuron 9	0,1272
63	rodzaj cementu (CEM IV) → ukryty neuron 9	0,1206
64	w/s → ukryty neuron 10	0,9661
65	wytrzymałość [MPa] → ukryty neuron 10	0,6219
66	rodzaj kruszywa grubego (grys) → ukryty neuron 10	-1,5650
67	rodzaj kruszywa grubego (żwir) → ukryty neuron 10	1,3255
68	rodzaj cementu (CEM I) → ukryty neuron 10	-0,1404
69	rodzaj cementu (CEM II) → ukryty neuron 10	-0,0778
70	rodzaj cementu (CEM IV) → ukryty neuron 10	-0,0314
71	w/s → ukryty neuron 11	-0,1423
72	wytrzymałość [MPa] → ukryty neuron 11	0,0894
73	rodzaj kruszywa grubego (grys) → ukryty neuron 11	-0,4259
74	rodzaj kruszywa grubego (żwir) → ukryty neuron 11	-0,3656
75	rodzaj cementu (CEM I) → ukryty neuron 11	-0,2960
76	rodzaj cementu (CEM II) → ukryty neuron 11	-0,2972
77	rodzaj cementu (CEM IV) → ukryty neuron 11	-0,3303
78	w/s → ukryty neuron 12	0,1341

CD. Tabela 2.1. Wagi dla sieci 3. MLP 7-13-6

79	wytrzymałość [MPa] → ukryty neuron 12	-0,0190
80	rodzaj kruszywa grubego (grys) → ukryty neuron 12	-0,7077
81	rodzaj kruszywa grubego (żwir) → ukryty neuron 12	1,0632
82	rodzaj cementu (CEM I) → ukryty neuron 12	0,1323
83	rodzaj cementu (CEM II) → ukryty neuron 12	0,1209
84	rodzaj cementu (CEM IV) → ukryty neuron 12	0,1184
85	w/s → ukryty neuron 13	-0,7339
86	wytrzymałość [MPa] → ukryty neuron 13	-0,0405
87	rodzaj kruszywa grubego (grys) → ukryty neuron 13	-0,1661
88	rodzaj kruszywa grubego (żwir) → ukryty neuron 13	-0,4649
89	rodzaj cementu (CEM I) → ukryty neuron 13	-0,1775
90	rodzaj cementu (CEM II) → ukryty neuron 13	-0,2333
91	rodzaj cementu (CEM IV) → ukryty neuron 13	-0,2171
92	przesunięcie wejściowych → ukryty neuron 1	-0,0434
93	przesunięcie wejściowych → ukryty neuron 2	-1,0166
94	przesunięcie wejściowych → ukryty neuron 3	0,5831
95	przesunięcie wejściowych → ukryty neuron 4	-0,3729
96	przesunięcie wejściowych → ukryty neuron 5	-0,3386
97	przesunięcie wejściowych → ukryty neuron 6	-0,7005
98	przesunięcie wejściowych → ukryty neuron 7	-0,4091
99	przesunięcie wejściowych → ukryty neuron 8	0,5255
100	przesunięcie wejściowych → ukryty neuron 9	0,1690
101	przesunięcie wejściowych → ukryty neuron 10	-0,1608
102	przesunięcie wejściowych → ukryty neuron 11	-0,8971
103	przesunięcie wejściowych → ukryty neuron 12	0,3065

CD. Tabela 2.1. Wagi dla sieci 3. MLP 7-13-6

104	przesunięcie wejściowych → ukryty neuron 13	-0,6699
105	ukryty neuron 1 → masa cementu	0,2966
106	ukryty neuron 2 → masa cementu	-1,0013
107	ukryty neuron 3 → masa cementu	-1,6775
108	ukryty neuron 4 → masa cementu	0,1037
109	ukryty neuron 5 → masa cementu	0,0722
110	ukryty neuron 6 → masa cementu	-3,2107
111	ukryty neuron 7 → masa cementu	-1,2104
112	ukryty neuron 8 → masa cementu	-1,0647
113	ukryty neuron 9 → masa cementu	-1,4088
114	ukryty neuron 10 → masa cementu	-0,3607
115	ukryty neuron 11 → masa cementu	0,8362
116	ukryty neuron 12 → masa cementu	-1,4143
117	ukryty neuron 13 → masa cementu	0,3797
118	ukryty neuron 1 → masa wody	0,0142
119	ukryty neuron 2 → masa wody	-0,5181
120	ukryty neuron 3 → masa wody	-0,1635
121	ukryty neuron 4 → masa wody	-0,0204
122	ukryty neuron 5 → masa wody	-1,5403
123	ukryty neuron 6 → masa wody	-0,1382
124	ukryty neuron 7 → masa wody	1,9402
125	ukryty neuron 8 → masa wody	-0,5152
126	ukryty neuron 9 → masa wody	0,9758
127	ukryty neuron 10 → masa wody	0,4068
128	ukryty neuron 11 → masa wody	-1,0220
129	ukryty neuron 12 → masa wody	2,3944
130	ukryty neuron 13 → masa wody	0,7398
131	ukryty neuron 1 → masa kruszywa frakcji [2-8 mm]	-0,0551
132	ukryty neuron 2 → masa kruszywa frakcji [2-8 mm]	0,3792
133	ukryty neuron 3 → masa kruszywa frakcji [2-8 mm]	-0,5548
134	ukryty neuron 4 → masa kruszywa frakcji [2-8 mm]	-0,2783
135	ukryty neuron 5 → masa kruszywa frakcji [2-8 mm]	0,3529
136	ukryty neuron 6 → masa kruszywa frakcji [2-8 mm]	0,2877

CD. Tabela 2.1. Wagi dla sieci 3. MLP 7-13-6

137	ukryty neuron 7 → masa kruszywa frakcji [2-8 mm]	0,9061
138	ukryty neuron 8 → masa kruszywa frakcji [2-8 mm]	0,4787
139	ukryty neuron 9 → masa kruszywa frakcji [2-8 mm]	0,7215
140	ukryty neuron 10 → masa kruszywa frakcji [2-8 mm]	0,1580
141	ukryty neuron 11 → masa kruszywa frakcji [2-8 mm]	0,2886
142	ukryty neuron 12 → masa kruszywa frakcji [2-8 mm]	0,2675
143	ukryty neuron 13 → masa kruszywa frakcji [2-8 mm]	0,6164
144	ukryty neuron 1 → masa kruszywa frakcji [8-16 mm]	-0,0375
145	ukryty neuron 2 → masa kruszywa frakcji [8-16 mm]	0,1537
146	ukryty neuron 3 → masa kruszywa frakcji [8-16 mm]	-1,3314
147	ukryty neuron 4 → masa kruszywa frakcji [8-16 mm]	-0,3883
148	ukryty neuron 5 → masa kruszywa frakcji [8-16 mm]	0,2308
149	ukryty neuron 6 → masa kruszywa frakcji [8-16 mm]	0,1567
150	ukryty neuron 7 → masa kruszywa frakcji [8-16 mm]	1,0527
151	ukryty neuron 8 → masa kruszywa frakcji [8-16 mm]	0,3161
152	ukryty neuron 9 → masa kruszywa frakcji [8-16 mm]	0,7969
153	ukryty neuron 10 → masa kruszywa frakcji [8-16 mm]	0,1729
154	ukryty neuron 11 → masa kruszywa frakcji [8-16 mm]	0,2816
155	ukryty neuron 12 → masa kruszywa frakcji [8-16 mm]	0,4093
156	ukryty neuron 13 → masa kruszywa frakcji [8-16 mm]	0,7721
157	ukryty neuron 1 → masa domieszki	-0,1345
158	ukryty neuron 2 → masa domieszki	-0,3693
159	ukryty neuron 3 → masa domieszki	-0,1795
160	ukryty neuron 4 → masa domieszki	-0,2394
161	ukryty neuron 5 → masa domieszki	0,6888
162	ukryty neuron 6 → masa domieszki	1,7604
163	ukryty neuron 7 → masa domieszki	-0,2931



CD. Tabela 2.1. Wagi dla sieci 3. MLP 7-13-6

164	ukryty neuron 8 → masa domieszki	-0,2321
165	ukryty neuron 9 → masa domieszki	-1,3029
166	ukryty neuron 10 → masa domieszki	-0,6570
167	ukryty neuron 11 → masa domieszki	0,0349
168	ukryty neuron 12 → masa domieszki	1,1853
169	ukryty neuron 13 → masa domieszki	-2,9719
170	ukryty neuron 1 → masa mikrokrzemionki	-0,4468
171	ukryty neuron 2 → masa mikrokrzemionki	2,4258
172	ukryty neuron 3 → masa mikrokrzemionki	3,5649
173	ukryty neuron 4 → masa mikrokrzemionki	-0,0154
174	ukryty neuron 5 → masa mikrokrzemionki	1,7782
175	ukryty neuron 6 → masa mikrokrzemionki	4,1606
176	ukryty neuron 7 → masa mikrokrzemionki	-0,6428
177	ukryty neuron 8 → masa mikrokrzemionki	2,3938
178	ukryty neuron 9 → masa mikrokrzemionki	0,7061
179	ukryty neuron 10 → masa mikrokrzemionki	-0,0214
180	ukryty neuron 11 → masa mikrokrzemionki	-1,3345
181	ukryty neuron 12 → masa mikrokrzemionki	-0,6765
182	ukryty neuron 13 → masa mikrokrzemionki	-1,2094
183	przesunięcie ukrytych → masa cementu	1,1517
184	przesunięcie ukrytych → masa wody	-2,1736
185	przesunięcie ukrytych → masa kruszywa frakcji [2-8 mm]	1,7697
186	przesunięcie ukrytych → masa kruszywa frakcji [8-16 mm]	2,1428
187	przesunięcie ukrytych → masa domieszki	-0,3885
188	przesunięcie ukrytych → masa mikrokrzemionki	0,1409

## 2.2. WAGI NEURONÓW DLA SIECI 5. MLP 7-9-6

Tabela 2.2. Wagi dla sieci 5. MLP 7-9-6

Lp.	Połączenia	Wartości wag
1	w/s → ukryty neuron 1	0,68120
2	wytrzymałość [MPa] → ukryty neuron 1	-2,60580
3	rodzaj kruszywa grubego (grys) → ukryty neuron 1	-1,61550
4	rodzaj kruszywa grubego (żwir) → ukryty neuron 1	3,69010
5	rodzaj cementu (CEM I) → ukryty neuron 1	0,49610
6	rodzaj cementu (CEM II) → ukryty neuron 1	0,65740
7	rodzaj cementu (CEM IV) → ukryty neuron 1	0,65310
8	w/s → ukryty neuron 2	-0,16020
9	wytrzymałość [MPa] → ukryty neuron 2	1,45210
10	rodzaj kruszywa grubego (grys) → ukryty neuron 2	-0,59550
11	rodzaj kruszywa grubego (żwir) → ukryty neuron 2	-0,35430
12	rodzaj cementu (CEM I) → ukryty neuron 2	-0,33180
13	rodzaj cementu (CEM II) → ukryty neuron 2	-0,36280
14	rodzaj cementu (CEM IV) → ukryty neuron 2	-0,25990
15	w/s → ukryty neuron 3	-0,87310
16	wytrzymałość [MPa] → ukryty neuron 3	0,92540
17	rodzaj kruszywa grubego (grys) → ukryty neuron 3	-0,07970
18	rodzaj kruszywa grubego (żwir) → ukryty neuron 3	0,47930
19	rodzaj cementu (CEM I) → ukryty neuron 3	0,13510
20	rodzaj cementu (CEM II) → ukryty neuron 3	0,15130
21	rodzaj cementu (CEM IV) → ukryty neuron 3	0,18130
22	w/s → ukryty neuron 4	2,56220
23	wytrzymałość [MPa] → ukryty neuron 4	1,30560
24	rodzaj kruszywa grubego (grys) → ukryty neuron 4	-2,95520
25	rodzaj kruszywa grubego (żwir) → ukryty neuron 4	0,14720

CD. Tabela 2.2. Wagi dla sieci 5. MLP 7-9-6

26	rodzaj cementu (CEM I) → ukryty neuron 4	-0,91630
27	rodzaj cementu (CEM II) → ukryty neuron 4	-0,98960
28	rodzaj cementu (CEM IV) → ukryty neuron 4	-0,89450
29	w/s → ukryty neuron 5	0,37580
30	wytrzymałość [MPa] → ukryty neuron 5	0,40510
31	rodzaj kruszywa grubego (grys) → ukryty neuron 5	4,55060
32	rodzaj kruszywa grubego (żwir) → ukryty neuron 5	-4,50870
33	rodzaj cementu (CEM I) → ukryty neuron 5	0,06390
34	rodzaj cementu (CEM II) → ukryty neuron 5	-0,02790
35	rodzaj cementu (CEM IV) → ukryty neuron 5	-0,13450
36	w/s → ukryty neuron 6	1,17790
37	wytrzymałość [MPa] → ukryty neuron 6	0,17550
38	rodzaj kruszywa grubego (grys) → ukryty neuron 6	-0,98180
39	rodzaj kruszywa grubego (żwir) → ukryty neuron 6	0,71630
40	rodzaj cementu (CEM I) → ukryty neuron 6	-0,09820
41	rodzaj cementu (CEM II) → ukryty neuron 6	-0,06800
42	rodzaj cementu (CEM IV) → ukryty neuron 6	-0,04280
43	w/s → ukryty neuron 7	7,24730
44	wytrzymałość [MPa] → ukryty neuron 7	-0,14940
45	rodzaj kruszywa grubego (grys) → ukryty neuron 7	0,12120
46	rodzaj kruszywa grubego (żwir) → ukryty neuron 7	0,19700
47	rodzaj cementu (CEM I) → ukryty neuron 7	0,12460
48	rodzaj cementu (CEM II) → ukryty neuron 7	0,17920
49	rodzaj cementu (CEM IV) → ukryty neuron 7	0,04970
50	w/s → ukryty neuron 8	0,25480
51	wytrzymałość [MPa] → ukryty neuron 8	3,37350
52	rodzaj kruszywa grubego (grys) → ukryty neuron 8	4,14510

CD. Tabela 2.2. Wagi dla sieci 5. MLP 7-9-6

53	rodzaj kruszywa grubego (żwir) → ukryty neuron 8	0,45570
54	rodzaj cementu (CEM I) → ukryty neuron 8	0,42880
55	rodzaj cementu (CEM II) → ukryty neuron 8	2,97730
56	rodzaj cementu (CEM IV) → ukryty neuron 8	1,32770
57	w/s → ukryty neuron 9	-4,73940
58	wytrzymałość [MPa] → ukryty neuron 9	-23,98200
59	rodzaj kruszywa grubego (grys) → ukryty neuron 9	-0,01130
60	rodzaj kruszywa grubego (żwir) → ukryty neuron 9	-0,07390
61	rodzaj cementu (CEM I) → ukryty neuron 9	-0,01220
62	rodzaj cementu (CEM II) → ukryty neuron 9	-0,07220
63	rodzaj cementu (CEM IV) → ukryty neuron 9	0,05110
64	przesunięcie wejściowych → ukryty neuron 1	1,93430
65	przesunięcie wejściowych → ukryty neuron 2	-0,89530
66	przesunięcie wejściowych → ukryty neuron 3	0,40730
67	przesunięcie wejściowych → ukryty neuron 4	-2,72700
68	przesunięcie wejściowych → ukryty neuron 5	0,00860
69	przesunięcie wejściowych → ukryty neuron 6	-0,27180
70	przesunięcie wejściowych → ukryty neuron 7	0,27150
71	przesunięcie wejściowych → ukryty neuron 8	4,81060
72	przesunięcie wejściowych → ukryty neuron 9	-0,09890
73	ukryty neuron 1 → masa cementu	0,13900
74	ukryty neuron 2 → masa cementu	1,36760
75	ukryty neuron 3 → masa cementu	-0,70510
76	ukryty neuron 4 → masa cementu	-2,38200
77	ukryty neuron 5 → masa cementu	-2,55050
78	ukryty neuron 6 → masa cementu	-3,73670
79	ukryty neuron 7 → masa cementu	-6,99820
80	ukryty neuron 8 → masa cementu	0,21710

CD. Tabela 2.2. Wagi dla sieci 5. MLP 7-9-6

81	ukryty neuron 9 → masa cementu	-4,55160
82	ukryty neuron 1 → masa wody	-0,68630
83	ukryty neuron 2 → masa wody	0,31910
84	ukryty neuron 3 → masa wody	-3,49520
85	ukryty neuron 4 → masa wody	3,46300
86	ukryty neuron 5 → masa wody	1,41640
87	ukryty neuron 6 → masa wody	3,16150
88	ukryty neuron 7 → masa wody	5,64520
89	ukryty neuron 8 → masa wody	0,70290
90	ukryty neuron 9 → masa wody	-1,46990
91	ukryty neuron 1 → masa kruszywa frakcji [2-8 mm]	-2,43940
92	ukryty neuron 2 → masa kruszywa frakcji [2-8 mm]	-2,37050
93	ukryty neuron 3 → masa kruszywa frakcji [2-8 mm]	-0,85000
94	ukryty neuron 4 → masa kruszywa frakcji [2-8 mm]	-0,11290
95	ukryty neuron 5 → masa kruszywa frakcji [2-8 mm]	5,18330
96	ukryty neuron 6 → masa kruszywa frakcji [2-8 mm]	-2,58430
97	ukryty neuron 7 → masa kruszywa frakcji [2-8 mm]	1,76540
98	ukryty neuron 8 → masa kruszywa frakcji [2-8 mm]	-0,48180
99	ukryty neuron 9 → masa kruszywa frakcji [2-8 mm]	-0,68260
100	ukryty neuron 1 → masa kruszywa frakcji [8-16 mm]	-2,31830
101	ukryty neuron 2 → masa kruszywa frakcji [8-16 mm]	-2,28750
102	ukryty neuron 3 → masa kruszywa frakcji [8-16 mm]	-1,09880
103	ukryty neuron 4 → masa kruszywa frakcji [8-16 mm]	1,24730
104	ukryty neuron 5 → masa kruszywa frakcji [8-16 mm]	4,69610
105	ukryty neuron 6 → masa kruszywa frakcji [8-16 mm]	-2,16650
106	ukryty neuron 7 → masa kruszywa frakcji [8-16 mm]	1,70970
107	ukryty neuron 8 → masa kruszywa frakcji [8-16 mm]	0,01770
108	ukryty neuron 9 → masa kruszywa frakcji [8-16 mm]	-0,93680

CD. Tabela 2.2. Wagi dla sieci 5. MLP 7-9-6

109	ukryty neuron 1 → masa domieszki	-0,51480
110	ukryty neuron 2 → masa domieszki	3,97600
111	ukryty neuron 3 → masa domieszki	-4,12690
112	ukryty neuron 4 → masa domieszki	-0,16450
113	ukryty neuron 5 → masa domieszki	-2,10660
114	ukryty neuron 6 → masa domieszki	-2,26620
115	ukryty neuron 7 → masa domieszki	0,52690
116	ukryty neuron 8 → masa domieszki	5,96210
117	ukryty neuron 9 → masa domieszki	1,70950
118	ukryty neuron 1 → masa mikrokrzemionki	0,42910
119	ukryty neuron 2 → masa mikrokrzemionki	-2,33000
120	ukryty neuron 3 → masa mikrokrzemionki	3,06200
121	ukryty neuron 4 → masa mikrokrzemionki	1,88010
122	ukryty neuron 5 → masa mikrokrzemionki	0,40710
123	ukryty neuron 6 → masa mikrokrzemionki	-0,51460
124	ukryty neuron 7 → masa mikrokrzemionki	10,51000
125	ukryty neuron 8 → masa mikrokrzemionki	-1,73930
126	ukryty neuron 9 → masa mikrokrzemionki	7,72330
127	przesunięcie ukrytych → masa cementu	1,64350
128	przesunięcie ukrytych → masa wody	-1,66810
129	przesunięcie ukrytych → masa kruszywa frakcji [2-8 mm]	-0,37600
130	przesunięcie ukrytych → masa kruszywa frakcji [8-16 mm]	0,76110
131	przesunięcie ukrytych → masa domieszki	-1,55020
132	przesunięcie ukrytych → masa mikro- krzemionki	-5,38550

## 2.3. WAGI NEURONÓW DLA SIECI 9. MLP 7-10-6

Tabela 2.3. Wagi dla sieci 9. MLP 7-10-6

Lp.	Połączenia	Wartości wag
1	w/s → ukryty neuron 1	-0,45346
2	wytrzymałość [MPa] → ukryty neuron 1	-2,10429
3	rodzaj kruszywa grubego (grys) → ukryty neuron 1	-0,22925
4	rodzaj kruszywa grubego (żwir) → ukryty neuron 1	-0,08938
5	rodzaj cementu (CEM I) → ukryty neuron 1	-0,14448
6	rodzaj cementu (CEM II) → ukryty neuron 1	-0,13119
7	rodzaj cementu (CEM IV) → ukryty neuron 1	-0,10049
8	w/s → ukryty neuron 2	0,66055
9	wytrzymałość [MPa] → ukryty neuron 2	0,59969
10	rodzaj kruszywa grubego (grys) → ukryty neuron 2	-0,73061
11	rodzaj kruszywa grubego (żwir) → ukryty neuron 2	-0,07334
12	rodzaj cementu (CEM I) → ukryty neuron 2	-0,32766
13	rodzaj cementu (CEM II) → ukryty neuron 2	-0,34524
14	rodzaj cementu (CEM IV) → ukryty neuron 2	-0,29853
15	w/s → ukryty neuron 3	-0,11709
16	wytrzymałość [MPa] → ukryty neuron 3	0,03928
17	rodzaj kruszywa grubego (grys) → ukryty neuron 3	-0,37152
18	rodzaj kruszywa grubego (żwir) → ukryty neuron 3	0,34422
19	rodzaj cementu (CEM I) → ukryty neuron 3	-0,01609
20	rodzaj cementu (CEM II) → ukryty neuron 3	-0,02601
21	rodzaj cementu (CEM IV) → ukryty neuron 3	-0,01744
22	w/s → ukryty neuron 4	-1,10076
23	wytrzymałość [MPa] → ukryty neuron 4	0,02412
24	rodzaj kruszywa grubego (grys) → ukryty neuron 4	2,02123
25	rodzaj kruszywa grubego (żwir) → ukryty neuron 4	-1,52192

CD. Tabela 2.3. Wagi dla sieci 9. MLP 7-10-6

26	rodzaj cementu (CEM I) → ukryty neuron 4	0,20623
27	rodzaj cementu (CEM II) → ukryty neuron 4	0,20792
28	rodzaj cementu (CEM IV) → ukryty neuron 4	0,19965
29	w/s → ukryty neuron 5	0,54418
30	wytrzymałość [MPa] → ukryty neuron 5	0,05142
31	rodzaj kruszywa grubego (grys) → ukryty neuron 5	0,01901
32	rodzaj kruszywa grubego (żwir) → ukryty neuron 5	-0,24645
33	rodzaj cementu (CEM I) → ukryty neuron 5	-0,05251
34	rodzaj cementu (CEM II) → ukryty neuron 5	-0,05977
35	rodzaj cementu (CEM IV) → ukryty neuron 5	-0,05989
36	w/s → ukryty neuron 6	1,06770
37	wytrzymałość [MPa] → ukryty neuron 6	-0,01753
38	rodzaj kruszywa grubego (grys) → ukryty neuron 6	1,62916
39	rodzaj kruszywa grubego (żwir) → ukryty neuron 6	-2,38551
40	rodzaj cementu (CEM I) → ukryty neuron 6	-0,21354
41	rodzaj cementu (CEM II) → ukryty neuron 6	-0,21822
42	rodzaj cementu (CEM IV) → ukryty neuron 6	-0,21845
43	w/s → ukryty neuron 7	-1,02508
44	wytrzymałość [MPa] → ukryty neuron 7	-0,80920
45	rodzaj kruszywa grubego (grys) → ukryty neuron 7	0,87798
46	rodzaj kruszywa grubego (żwir) → ukryty neuron 7	0,29602
47	rodzaj cementu (CEM I) → ukryty neuron 7	0,41696
48	rodzaj cementu (CEM II) → ukryty neuron 7	0,44486
49	rodzaj cementu (CEM IV) → ukryty neuron 7	0,37185
50	w/s → ukryty neuron 8	-0,75393
51	wytrzymałość [MPa] → ukryty neuron 8	-0,35177
52	rodzaj kruszywa grubego (grys) → ukryty neuron 8	0,55566



CD. Tabela 2.3. Wagi dla sieci 9. MLP 7-10-6

53	rodzaj kruszywa grubego (żwir) → ukryty neuron 8	-0,00473
54	rodzaj cementu (CEM I) → ukryty neuron 8	0,23166
55	rodzaj cementu (CEM II) → ukryty neuron 8	0,24075
56	rodzaj cementu (CEM IV) → ukryty neuron 8	0,22188
57	w/s → ukryty neuron 9	-0,23600
58	wytrzymałość [MPa] → ukryty neuron 9	-6,25380
59	rodzaj kruszywa grubego (grys) → ukryty neuron 9	-0,31603
60	rodzaj kruszywa grubego (żwir) → ukryty neuron 9	-0,30941
61	rodzaj cementu (CEM I) → ukryty neuron 9	-0,23736
62	rodzaj cementu (CEM II) → ukryty neuron 9	-0,24938
63	rodzaj cementu (CEM IV) → ukryty neuron 9	-0,20355
64	w/s → ukryty neuron 10	-3,93670
65	wytrzymałość [MPa] → ukryty neuron 10	2,35914
66	rodzaj kruszywa grubego (grys) → ukryty neuron 10	-0,46382
67	rodzaj kruszywa grubego (żwir) → ukryty neuron 10	-2,18824
68	rodzaj cementu (CEM I) → ukryty neuron 10	-1,16304
69	rodzaj cementu (CEM II) → ukryty neuron 10	-0,90663
70	rodzaj cementu (CEM IV) → ukryty neuron 10	-0,50436
71	przesunięcie wejściowych → ukryty neuron 1	-0,27098
72	przesunięcie wejściowych → ukryty neuron 2	-0,82222
73	przesunięcie wejściowych → ukryty neuron 3	-0,08206
74	przesunięcie wejściowych → ukryty neuron 4	0,53745
75	przesunięcie wejściowych → ukryty neuron 5	-0,16194
76	przesunięcie wejściowych → ukryty neuron 6	-0,67245
77	przesunięcie wejściowych → ukryty neuron 7	1,14332
78	przesunięcie wejściowych → ukryty neuron 8	0,64022

CD. Tabela 2.3. Wagi dla sieci 9. MLP 7-10-6

79	przesunięcie wejściowych → ukryty neuron 9	-0,62800
80	przesunięcie wejściowych → ukryty neuron 10	-2,59726
81	ukryty neuron 1 → masa cementu	1,61204
82	ukryty neuron 2 → masa cementu	3,17762
83	ukryty neuron 3 → masa cementu	1,43076
84	ukryty neuron 4 → masa cementu	3,28318
85	ukryty neuron 5 → masa cementu	0,41779
86	ukryty neuron 6 → masa cementu	-2,43850
87	ukryty neuron 7 → masa cementu	3,86963
88	ukryty neuron 8 → masa cementu	-0,91451
89	ukryty neuron 9 → masa cementu	-3,63945
90	ukryty neuron 10 → masa cementu	2,35386
91	ukryty neuron 1 → masa wody	-0,25057
92	ukryty neuron 2 → masa wody	-0,15951
93	ukryty neuron 3 → masa wody	-1,14273
94	ukryty neuron 4 → masa wody	-2,09628
95	ukryty neuron 5 → masa wody	0,84478
96	ukryty neuron 6 → masa wody	1,43306
97	ukryty neuron 7 → masa wody	-0,58008
98	ukryty neuron 8 → masa wody	0,68965
99	ukryty neuron 9 → masa wody	0,16594
100	ukryty neuron 10 → masa wody	-0,89262
101	ukryty neuron 1 → masa kruszywa frakcji [2-8 mm]	-0,25284
102	ukryty neuron 2 → masa kruszywa frakcji [2-8 mm]	-0,45246
103	ukryty neuron 3 → masa kruszywa frakcji [2-8 mm]	-1,01831
104	ukryty neuron 4 → masa kruszywa frakcji [2-8 mm]	-0,29095
105	ukryty neuron 5 → masa kruszywa frakcji [2-8 mm]	-0,43700
106	ukryty neuron 6 → masa kruszywa frakcji [2-8 mm]	0,46647
107	ukryty neuron 7 → masa kruszywa frakcji [2-8 mm]	-1,12378
108	ukryty neuron 8 → masa kruszywa frakcji [2-8 mm]	0,43677
109	ukryty neuron 9 → masa kruszywa frakcji [2-8 mm]	0,37636

CD. Tabela 2.3. Wagi dla sieci 9. MLP 7-10-6

110	ukryty neuron 10 → masa kruszywa frakcji [2-8 mm]	0,50321
111	ukryty neuron 1 → masa kruszywa frakcji [8-16 mm]	-0,26920
112	ukryty neuron 2 → masa kruszywa frakcji [8-16 mm]	0,06813
113	ukryty neuron 3 → masa kruszywa frakcji [8-16 mm]	-1,39892
114	ukryty neuron 4 → masa kruszywa frakcji [8-16 mm]	-0,16498
115	ukryty neuron 5 → masa kruszywa frakcji [8-16 mm]	0,01191
116	ukryty neuron 6 → masa kruszywa frakcji [8-16 mm]	0,08555
117	ukryty neuron 7 → masa kruszywa frakcji [8-16 mm]	-0,95107
118	ukryty neuron 8 → masa kruszywa frakcji [8-16 mm]	1,02261
119	ukryty neuron 9 → masa kruszywa frakcji [8-16 mm]	0,37360
120	ukryty neuron 10 → masa kruszywa frakcji [8-16 mm]	0,26327
121	ukryty neuron 1 → masa domieszki	-0,70213
122	ukryty neuron 2 → masa domieszki	3,91512
123	ukryty neuron 3 → masa domieszki	-1,53144
124	ukryty neuron 4 → masa domieszki	1,20311
125	ukryty neuron 5 → masa domieszki	4,25967
126	ukryty neuron 6 → masa domieszki	-2,89309
127	ukryty neuron 7 → masa domieszki	0,47587
128	ukryty neuron 8 → masa domieszki	5,41188
129	ukryty neuron 9 → masa domieszki	1,90921
130	ukryty neuron 10 → masa domieszki	0,93056
131	ukryty neuron 1 → masa mikrokrzemionki	-1,76679
132	ukryty neuron 2 → masa mikrokrzemionki	-4,19111
133	ukryty neuron 3 → masa mikrokrzemionki	-0,92067
134	ukryty neuron 4 → masa mikrokrzemionki	-2,26475
135	ukryty neuron 5 → masa mikrokrzemionki	-1,73465
136	ukryty neuron 6 → masa mikrokrzemionki	1,83873
137	ukryty neuron 7 → masa mikrokrzemionki	-4,31663

CD. Tabela 2.3. Wagi dla sieci 9. MLP 7-10-6

138	ukryty neuron 8 → masa mikrokrzemionki	0,10931
139	ukryty neuron 9 → masa mikrokrzemionki	4,07632
140	ukryty neuron 10 → masa mikrokrzemionki	-2,55506
141	przesunięcie ukrytych → masa cementu	0,03130
142	przesunięcie ukrytych → masa wody	-0,24472
143	przesunięcie ukrytych → masa kruszywa frakcji [2-8 mm]	1,42080
144	przesunięcie ukrytych → masa kruszywa frakcji [8-16 mm]	1,01811
145	przesunięcie ukrytych → masa domieszki	1,50349
146	przesunięcie ukrytych → masa mikrokrzemionki	0,59748

## ZAŁĄCZNIK 4 – KODY ALGORYTMÓW SSN DLA POSZCZEGÓLNYCH ZADAŃ

### Spis treści

1.	ZADANIE 1.....	3666
1.1.	Sieć 3. MLP 12-5-1 .....	366
1.2.	Sieć 5. MLP 12-12-1 .....	371
1.3.	Sieć 11. MLP 12-11-1.....	378
2.	ZADANIE 2.....	386
2.1.	Sieć 3. MLP 7-13-6 .....	386
2.2.	Sieć 5. MLP 7-9-6 .....	394
2.3.	Sieć 9. MLP 7-10-6 .....	400

## 1. ZADANIE 1

### 1.1. SIEĆ 3. MLP 12-5-1

```
<PMML version="3.0">
<Header copyright="Copyright (c) StatSoft, Inc. All Rights
Reserved.">
<Application name="STATISTICA Automated Neural Networks
(SANN) " version="2.0"/>
</Header>
<DataDictionary numberOfFields="10">
<DataField name="wytrzymałość [MPa]" optype="continuous"/>
<DataField name="w/s" optype="continuous"/>
<DataField name="masa cementu" optype="continuous"/>
<DataField name="masa wody" optype="continuous"/>
<DataField name="masa kruszywa frakcji [2-
8mm]" optype="continuous"/>
<DataField name="masa kruszywa frakcji [8-
16mm]" optype="continuous"/>
<DataField name="masa domieszki" optype="continuous"/>
<DataField name="masa mikro- krzemion-
ki" optype="continuous"/>
<DataField name="rodzaj kruszywa grube-
go" optype="categorical">
<Value value="grys"/>
<Value value="żwir"/>
</DataField>
<DataField name="rodzaj cementu" optype="categorical">
<Value value="CEM I"/>
<Value value="CEM II"/>
<Value value="CEM IV"/>
</DataField>
</DataDictionary>
<NeuralNetwork modelName="Arku_MLP 12-5-
1" functionName="regression">
<MiningSchema>
<MiningField name="wytrzymałość
[MPa]" usageType="predicted"/>
<Mining-
Field name="w/s" lowValue="0.210000" highValue="0.500000"/>
<MiningField name="masa cemen-
tu" lowValue="1.249000" highValue="2.270000"/>
<MiningField name="masa
wody" lowValue="0.477000" highValue="0.735000"/>
<MiningField name="masa kruszywa frakcji [2-
8mm]" lowValue="2.340000" highValue="2.826000"/>
<MiningField name="masa kruszywa frakcji [8-
16mm]" lowValue="2.340000" highValue="2.826000"/>
```

```

<MiningField name="masa
domieszki" lowValue="0.000000" highValue="0.470000"/>
<MiningField name="masa mikro- krzemion-
ki" lowValue="0.000000" highValue="0.891000"/>
<MiningField name="rodzaj kruszywa grubego"/>
<MiningField name="rodzaj cementu"/>
</MiningSchema>
<NeuralInputs numberOfInputs="12">
<NeuralInput id="0">
<DerivedField>
<NormContinuous field="w/s" shift="-7,24137931034483e-
001" scale="3,44827586206897e+000">
<LinearNorm orig="2.10000000000000e-001" norm="0.000000"/>
<LinearNorm orig="5.00000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="1">
<DerivedField>
<NormContinuous field="masa cementu" shift="-
1,22331047992165e+000" scale="9,79431929480901e-001">
<LinearNorm orig="1.24900000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.27000000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="2">
<DerivedField>
<NormContinuous field="masa wody" shift="-
1,84883720930233e+000" scale="3,87596899224806e+000">
<LinearNorm orig="4.77000000000000e-001" norm="0.000000"/>
<LinearNorm orig="7.35000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="3">
<DerivedField>
<NormContinuous field="masa kruszywa frakcji [2-
8mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<LinearNorm orig="2.34000000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.82600000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="4">
<DerivedField>

```

```

<NormContinuous field="masa kruszywa frakcji [8-
16mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<LinearNorm orig="2.34000000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.82600000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="5">
<DerivedField>
<NormContinuous field="masa domieszki" shift="-
0,00000000000000e+000" scale="2,12765957446809e+000">
<LinearNorm orig="0.00000000000000e+000" norm="0.000000"/>
<LinearNorm orig="4.70000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="6">
<DerivedField>
<NormContinuous field="masa mikro- krzemionki" shift="-
0,00000000000000e+000" scale="1,12233445566779e+000">
<LinearNorm orig="0.00000000000000e+000" norm="0.000000"/>
<LinearNorm orig="8.91000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="7">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="grys"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="8">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="żwir"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="9">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM I"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="10">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM II"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="11">

```



```

<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM IV"/>
</DerivedField>
</NeuralInput>
</NeuralInputs>
<NeuralLayer
  numberOfNeurons="5" activationFunction="logistic">
  <Neuron id="12" bias="-2.80109300476045e+001">
    <Con from="0" weight="-5.20102998761122e+001"/>
    <Con from="1" weight="8.48023092571675e+001"/>
    <Con from="2" weight="-3.76552583256460e+001"/>
    <Con from="3" weight="-1.11727054838796e+001"/>
    <Con from="4" weight="-5.60382941564829e+000"/>
    <Con from="5" weight="-5.76715443838144e+001"/>
    <Con from="6" weight="-7.60963421859346e+001"/>
    <Con from="7" weight="-5.58117913179036e+000"/>
    <Con from="8" weight="-2.24439286881774e+001"/>
    <Con from="9" weight="-9.03720818846951e+000"/>
    <Con from="10" weight="-9.63201019626763e+000"/>
    <Con from="11" weight="-9.36936235626101e+000"/>
  </Neuron>
  <Neuron id="13" bias="4.98634491848000e-001">
    <Con from="0" weight="2.07073062205633e+001"/>
    <Con from="1" weight="-1.17943946706419e+001"/>
    <Con from="2" weight="-2.07437792590154e+001"/>
    <Con from="3" weight="1.60058307274563e+001"/>
    <Con from="4" weight="-5.48166749590317e+000"/>
    <Con from="5" weight="6.35246895267873e+000"/>
    <Con from="6" weight="-1.43050153603136e+001"/>
    <Con from="7" weight="-5.51290181090000e+000"/>
    <Con from="8" weight="5.97018459458229e+000"/>
    <Con from="9" weight="-4.57534870266319e-001"/>
    <Con from="10" weight="-1.22304951072398e+000"/>
    <Con from="11" weight="2.17935685705549e+000"/>
  </Neuron>
  <Neuron id="14" bias="-2.87457609773331e+001">
    <Con from="0" weight="6.34066194745852e+001"/>
    <Con from="1" weight="5.39023950724062e+001"/>
    <Con from="2" weight="4.62660701135301e+001"/>
    <Con from="3" weight="-2.10797408949780e+001"/>
    <Con from="4" weight="-2.57721268077237e+000"/>
    <Con from="5" weight="5.35761502879118e+001"/>
    <Con from="6" weight="2.64314407402989e+001"/>
    <Con from="7" weight="-2.47634481245886e+000"/>
    <Con from="8" weight="-2.61861255913711e+001"/>
    <Con from="9" weight="-9.72904666359103e+000"/>
    <Con from="10" weight="-9.54309150818118e+000"/>
    <Con from="11" weight="-9.43728462170219e+000"/>
  </Neuron>

```

```

<Neuron id="15" bias="8.28245518074023e+000">
<Con from="0" weight="7.82965789861442e+000"/>
<Con from="1" weight="-2.54693669779229e+001"/>
<Con from="2" weight="-8.28678858009081e+000"/>
<Con from="3" weight="2.96885853245569e+001"/>
<Con from="4" weight="-8.68697863010908e+000"/>
<Con from="5" weight="-1.02184432615823e+001"/>
<Con from="6" weight="-4.95029674601849e+000"/>
<Con from="7" weight="-8.70451139577812e+000"/>
<Con from="8" weight="1.69874927749901e+001"/>
<Con from="9" weight="2.04615332215835e-001"/>
<Con from="10" weight="-5.31233507041257e+000"/>
<Con from="11" weight="1.33965249401274e+001"/>
</Neuron>
<Neuron id="16" bias="1.49822296554407e+001">
<Con from="0" weight="-4.98626115045887e+000"/>
<Con from="1" weight="1.28517868427389e+001"/>
<Con from="2" weight="3.33088706708967e+000"/>
<Con from="3" weight="7.32823746484580e+000"/>
<Con from="4" weight="8.47163752950163e+000"/>
<Con from="5" weight="1.74250785960279e+001"/>
<Con from="6" weight="1.18582149306052e+001"/>
<Con from="7" weight="8.51487924008219e+000"/>
<Con from="8" weight="6.45522418763021e+000"/>
<Con from="9" weight="1.58384713225076e+001"/>
<Con from="10" weight="2.17023126957220e+001"/>
<Con from="11" weight="-2.25448784145773e+001"/>
</Neuron>
</NeuralLayer>
<NeuralLayer
numberOfNeurons="1" activationFunction="logistic">
<Neuron id="17" bias="-5.81127161711909e+001">
<Con from="12" weight="5.45354330407870e+001"/>
<Con from="13" weight="-1.21031244051263e+000"/>
<Con from="14" weight="5.84367229975872e+001"/>
<Con from="15" weight="-1.34369960122383e+000"/>
<Con from="16" weight="1.90386629179733e+000"/>
</Neuron>
</NeuralLayer>
<NeuralOutputs numberOfOutputs="1">
<NeuralOutput outputNeuron="17">
<DerivedField optype="continuous">
<NormContinuous field="wytrzymałość [MPa]" shift="-
9,13980911373612e-005" scale="9,20652972026639e-003">
<LinearNorm orig="9.92752903802244e-
003" norm="0.00000000000000e+000"/>
<Linear-
Norm orig="1.08628487440781e+002" norm="1.00000000000000e+0
00"/>

```

```

</NormContinuous>
</DerivedField>
</NeuralOutput>
</NeuralOutputs>
</NeuralNetwork>
</PMML>

```

## 1.2. SIEĆ 5. MLP 12-12-1

```

<PMML version="3.0">
<Header copyright="Copyright (c) StatSoft, Inc. All Rights
Reserved.">
<Application name="STATISTICA Automated Neural Networks
(SANN)" version="2.0"/>
</Header>
<DataDictionary numberOfFields="10">
<DataField name="wytrzymałość [MPa]" optype="continuous"/>
<DataField name="w/s" optype="continuous"/>
<DataField name="masa cementu" optype="continuous"/>
<DataField name="masa wody" optype="continuous"/>
<DataField name="masa kruszywa frakcji [2-
8mm]" optype="continuous"/>
<DataField name="masa kruszywa frakcji [8-
16mm]" optype="continuous"/>
<DataField name="masa domieszki" optype="continuous"/>
<DataField name="masa mikro- krzemion-
ki" optype="continuous"/>
<DataField name="rodzaj kruszywa grube-
go" optype="categorical">
<Value value="grys"/>
<Value value="żwir"/>
</DataField>
<DataField name="rodzaj cementu" optype="categorical">
<Value value="CEM I"/>
<Value value="CEM II"/>
<Value value="CEM IV"/>
</DataField>
</DataDictionary>
<NeuralNetwork modelName="Arku_MLP 12-12-
1" functionName="regression">
<MiningSchema>
<MiningField name="wytrzymałość
[MPa]" usageType="predicted"/>
<Mining-
Field name="w/s" lowValue="0.210000" highValue="0.500000"/>
<MiningField name="masa cemen-
tu" lowValue="1.249000" highValue="2.270000"/>

```

```

<MiningField name="masa
wody" lowValue="0.477000" highValue="0.735000"/>
<MiningField name="masa kruszywa frakcji [2-
8mm]" lowValue="2.340000" highValue="2.826000"/>
<MiningField name="masa kruszywa frakcji [8-
16mm]" lowValue="2.340000" highValue="2.826000"/>
<MiningField name="masa
domieszki" lowValue="0.000000" highValue="0.470000"/>
<MiningField name="masa mikro- krzemion-
ki" lowValue="0.000000" highValue="0.891000"/>
<MiningField name="rodzaj kruszywa grubego"/>
<MiningField name="rodzaj cementu"/>
</MiningSchema>
<NeuralInputs numberOfInputs="12">
<NeuralInput id="0">
<DerivedField>
<NormContinuous field="w/s" shift="-7,24137931034483e-
001" scale="3,44827586206897e+000">
<LinearNorm orig="2.100000000000000e-001" norm="0.000000"/>
<LinearNorm orig="5.000000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="1">
<DerivedField>
<NormContinuous field="masa cementu" shift="-
1,22331047992165e+000" scale="9,79431929480901e-001">
<LinearNorm orig="1.249000000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.270000000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="2">
<DerivedField>
<NormContinuous field="masa wody" shift="-
1,84883720930233e+000" scale="3,87596899224806e+000">
<LinearNorm orig="4.770000000000000e-001" norm="0.000000"/>
<LinearNorm orig="7.350000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="3">
<DerivedField>
<NormContinuous field="masa kruszywa frakcji [2-
8mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<LinearNorm orig="2.340000000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.826000000000000e+000" norm="1.000000"/>
</NormContinuous>

```

```

</DerivedField>
</NeuralInput>
<NeuralInput id="4">
<DerivedField>
<NormContinuous field="masa kruszywa frakcji [8-
16mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<LinearNorm orig="2.34000000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.82600000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="5">
<DerivedField>
<NormContinuous field="masa domieszki" shift="-
0,00000000000000e+000" scale="2,12765957446809e+000">
<LinearNorm orig="0.00000000000000e+000" norm="0.000000"/>
<LinearNorm orig="4.70000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="6">
<DerivedField>
<NormContinuous field="masa mikro- krzemionki" shift="-
0,00000000000000e+000" scale="1,12233445566779e+000">
<LinearNorm orig="0.00000000000000e+000" norm="0.000000"/>
<LinearNorm orig="8.91000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="7">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="grys"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="8">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="żwir"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="9">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM I"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="10">
<DerivedField>

```

```

<NormDiscrete field="rodzaj cementu" value="CEM II"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="11">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM IV"/>
</DerivedField>
</NeuralInput>
</NeuralInputs>
<NeuralLayer
numberOfNeurons="12" activationFunction="tanh">
<Neuron id="12" bias="5.96426725250078e+000">
<Con from="0" weight="2.00118634693405e+000"/>
<Con from="1" weight="-1.40155263798953e+001"/>
<Con from="2" weight="3.21261839856963e+000"/>
<Con from="3" weight="2.77273778910526e+000"/>
<Con from="4" weight="5.32434028121516e-001"/>
<Con from="5" weight="-6.13600307664847e+000"/>
<Con from="6" weight="1.19958725197991e+001"/>
<Con from="7" weight="5.20396243100551e-001"/>
<Con from="8" weight="5.40780698323224e+000"/>
<Con from="9" weight="1.73650161485387e+000"/>
<Con from="10" weight="1.98020633563697e+000"/>
<Con from="11" weight="2.29466183389057e+000"/>
</Neuron>
<Neuron id="13" bias="-2.78880107581711e-001">
<Con from="0" weight="-1.35718366317130e+000"/>
<Con from="1" weight="-7.40206432166136e-001"/>
<Con from="2" weight="6.05441830807978e-001"/>
<Con from="3" weight="-4.59321588289776e+000"/>
<Con from="4" weight="-7.59703833493678e-001"/>
<Con from="5" weight="-3.32901783453432e+000"/>
<Con from="6" weight="-8.18346363009618e-001"/>
<Con from="7" weight="-7.52289666064755e-001"/>
<Con from="8" weight="5.27125785928295e-001"/>
<Con from="9" weight="-1.99966423114097e+000"/>
<Con from="10" weight="-2.68160218496879e-001"/>
<Con from="11" weight="1.97301682585924e+000"/>
</Neuron>
<Neuron id="14" bias="-3.11768485566131e-001">
<Con from="0" weight="-9.84352591893058e+000"/>
<Con from="1" weight="1.59847402451356e+000"/>
<Con from="2" weight="-8.96467284200551e+000"/>
<Con from="3" weight="1.85000780487328e+000"/>
<Con from="4" weight="-3.10790651701444e-001"/>
<Con from="5" weight="3.30731159399133e+000"/>
<Con from="6" weight="3.61280569175784e+000"/>
<Con from="7" weight="-3.00581957633007e-001"/>
<Con from="8" weight="1.34511756784497e-002"/>

```

```

<Con from="9" weight="6.43227076418948e-002"/>
<Con from="10" weight="2.44870702019829e-002"/>
<Con from="11" weight="-4.06120476630276e-001"/>
</Neuron>
<Neuron id="15" bias="1.88362829395969e+000">
<Con from="0" weight="2.37575087561929e+000"/>
<Con from="1" weight="3.89246209488892e-001"/>
<Con from="2" weight="5.70071112149999e+000"/>
<Con from="3" weight="4.98168945995689e+000"/>
<Con from="4" weight="4.69462837285228e+000"/>
<Con from="5" weight="3.05100362387960e+000"/>
<Con from="6" weight="-4.29983578350003e+000"/>
<Con from="7" weight="4.72101243112037e+000"/>
<Con from="8" weight="-2.82883353958123e+000"/>
<Con from="9" weight="-5.32038971036762e-001"/>
<Con from="10" weight="6.39956838673210e+000"/>
<Con from="11" weight="-4.02379894115386e+000"/>
</Neuron>
<Neuron id="16" bias="-1.18769081170698e+000">
<Con from="0" weight="1.00707418407366e+000"/>
<Con from="1" weight="-8.07495030874389e-001"/>
<Con from="2" weight="4.38181009996451e-001"/>
<Con from="3" weight="5.65133756931817e+000"/>
<Con from="4" weight="-2.51845545691244e+000"/>
<Con from="5" weight="6.61575974376225e+000"/>
<Con from="6" weight="-1.40180815007519e+000"/>
<Con from="7" weight="-2.53581012131961e+000"/>
<Con from="8" weight="1.33268047906069e+000"/>
<Con from="9" weight="-8.12805445424125e-001"/>
<Con from="10" weight="-6.38396122450813e-001"/>
<Con from="11" weight="3.15997242582422e-001"/>
</Neuron>
<Neuron id="17" bias="-1.59718857715200e+000">
<Con from="0" weight="-7.37385293786711e+000"/>
<Con from="1" weight="2.42377040237172e+000"/>
<Con from="2" weight="1.33283312031755e+001"/>
<Con from="3" weight="-5.75131271097333e+000"/>
<Con from="4" weight="2.02148428289489e+000"/>
<Con from="5" weight="9.66903652937740e+000"/>
<Con from="6" weight="3.75134174206641e-001"/>
<Con from="7" weight="1.96021869156323e+000"/>
<Con from="8" weight="-3.62022399313910e+000"/>
<Con from="9" weight="-4.83589989727499e-001"/>
<Con from="10" weight="-1.50491710925385e-001"/>
<Con from="11" weight="-9.99848246943906e-001"/>
</Neuron>
<Neuron id="18" bias="-7.14904664992883e-001">
<Con from="0" weight="-2.10316975005036e+000"/>
<Con from="1" weight="4.32261629463801e+000"/>

```

```

<Con from="2" weight="-3.81012022794947e+000"/>
<Con from="3" weight="-3.13879951770457e+000"/>
<Con from="4" weight="-1.89242568314463e+000"/>
<Con from="5" weight="5.36026186705236e+000"/>
<Con from="6" weight="3.88373210367387e+000"/>
<Con from="7" weight="-1.94493532510707e+000"/>
<Con from="8" weight="1.23078049098950e+000"/>
<Con from="9" weight="5.44940717655616e+000"/>
<Con from="10" weight="-4.48168354276385e+000"/>
<Con from="11" weight="-1.69881311338985e+000"/>
</Neuron>
<Neuron id="19" bias="-1.99397340305261e+000">
<Con from="0" weight="2.47970888330722e+000"/>
<Con from="1" weight="1.31831171555385e+000"/>
<Con from="2" weight="4.34660433122305e+000"/>
<Con from="3" weight="1.51566367402963e+000"/>
<Con from="4" weight="2.93037003022318e-001"/>
<Con from="5" weight="4.18206556639981e+000"/>
<Con from="6" weight="-5.16290870794182e-001"/>
<Con from="7" weight="3.58046569345817e-001"/>
<Con from="8" weight="-2.33594325198346e+000"/>
<Con from="9" weight="3.81590041253258e-002"/>
<Con from="10" weight="1.15582310043294e+000"/>
<Con from="11" weight="-3.16662130438553e+000"/>
</Neuron>
<Neuron id="20" bias="1.56544823015519e+000">
<Con from="0" weight="-2.98054658908859e+000"/>
<Con from="1" weight="-1.52818749252892e+000"/>
<Con from="2" weight="3.77404806020689e+000"/>
<Con from="3" weight="-1.00557008970971e+000"/>
<Con from="4" weight="7.77308506194961e-001"/>
<Con from="5" weight="1.88225948518257e+001"/>
<Con from="6" weight="-2.52629534192070e+000"/>
<Con from="7" weight="7.78019903942347e-001"/>
<Con from="8" weight="7.20953380297725e-001"/>
<Con from="9" weight="-7.91002500254232e-001"/>
<Con from="10" weight="3.27344815952061e+000"/>
<Con from="11" weight="-8.63389411885581e-001"/>
</Neuron>
<Neuron id="21" bias="-1.96079840086755e+000">
<Con from="0" weight="6.66243053943602e+000"/>
<Con from="1" weight="6.84710549113338e+000"/>
<Con from="2" weight="7.33420285890629e+000"/>
<Con from="3" weight="4.99128925510188e+000"/>
<Con from="4" weight="5.67278041965726e+000"/>
<Con from="5" weight="4.58633570868154e+000"/>
<Con from="6" weight="-1.69581946037414e+000"/>
<Con from="7" weight="5.70269828265206e+000"/>
<Con from="8" weight="-7.62484034503891e+000"/>

```



```

<Con from="9" weight="3.14329443143604e+000"/>
<Con from="10" weight="3.32839444449047e+000"/>
<Con from="11" weight="-8.45133504874011e+000"/>
</Neuron>
<Neuron id="22" bias="-2.67080726459857e+000">
<Con from="0" weight="1.62482357855614e+000"/>
<Con from="1" weight="4.76959290936032e+000"/>
<Con from="2" weight="2.32008307176275e+000"/>
<Con from="3" weight="-5.00269838106490e+000"/>
<Con from="4" weight="7.22729152448300e-001"/>
<Con from="5" weight="2.54149992893872e+001"/>
<Con from="6" weight="5.53591306975562e+000"/>
<Con from="7" weight="7.40142132686886e-001"/>
<Con from="8" weight="-3.39767582415366e+000"/>
<Con from="9" weight="-3.35419799832504e+000"/>
<Con from="10" weight="-1.35557064620396e+000"/>
<Con from="11" weight="2.03777238958127e+000"/>
</Neuron>
<Neuron id="23" bias="-4.05644711295984e-001">
<Con from="0" weight="-4.01666549101228e+000"/>
<Con from="1" weight="-1.15005334710282e+000"/>
<Con from="2" weight="-4.06168476087648e+000"/>
<Con from="3" weight="-1.33957001517177e+000"/>
<Con from="4" weight="-1.65772115562975e+000"/>
<Con from="5" weight="4.19053148608239e+000"/>
<Con from="6" weight="3.59529135695104e+000"/>
<Con from="7" weight="-1.75451393113294e+000"/>
<Con from="8" weight="1.29966465950749e+000"/>
<Con from="9" weight="7.02891663036555e-001"/>
<Con from="10" weight="-4.82838697639339e+000"/>
<Con from="11" weight="3.74780920994948e+000"/>
</Neuron>
</NeuralLayer>
<NeuralLayer
er numberOfNeurons="1" activationFunction="logistic">
<Neuron id="24" bias="-3.07427136135305e+000">
<Con from="12" weight="-1.44599909280854e+001"/>
<Con from="13" weight="5.79558553578036e+000"/>
<Con from="14" weight="-1.42817588923766e+001"/>
<Con from="15" weight="-3.33142185585635e+000"/>
<Con from="16" weight="-2.21815058218972e+000"/>
<Con from="17" weight="2.40618596855763e+000"/>
<Con from="18" weight="8.40815469566571e-001"/>
<Con from="19" weight="-1.23942058536943e+000"/>
<Con from="20" weight="4.76318345057989e+000"/>
<Con from="21" weight="5.69054778998594e+000"/>
<Con from="22" weight="8.41662750910806e-001"/>
<Con from="23" weight="-2.49797966966901e+000"/>
</Neuron>

```

```

</NeuralLayer>
<NeuralOutputs numberOfOutputs="1">
<NeuralOutput outputNeuron="24">
<DerivedField optype="continuous">
<NormContinuous field="wytrzymałość [MPa]" shift="-
9,13980911373612e-005" scale="9,20652972026639e-003">
<LinearNorm orig="9.92752903802244e-
003" norm="0.000000000000000e+000"/>
<Linear-
Norm orig="1.08628487440781e+002" norm="1.000000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
</NeuralOutputs>
</NeuralNetwork>
</PMML>

```

### 1.3. SIEĆ 11. MLP 12-11-1

```

<PMML version="3.0">
<Header copyright="Copyright (c) StatSoft, Inc. All Rights
Reserved.">
<Application name="STATISTICA Automated Neural Networks
(SANN)" version="2.0"/>
</Header>
<DataDictionary numberOfFields="10">
<DataField name="wytrzymałość [MPa]" optype="continuous"/>
<DataField name="w/s" optype="continuous"/>
<DataField name="masa cementu" optype="continuous"/>
<DataField name="masa wody" optype="continuous"/>
<DataField name="masa kruszywa frakcji [2-
8mm]" optype="continuous"/>
<DataField name="masa kruszywa frakcji [8-
16mm]" optype="continuous"/>
<DataField name="masa domieszki" optype="continuous"/>
<DataField name="masa mikro- krzemion-
ki" optype="continuous"/>
<DataField name="rodzaj kruszywa grube-
go" optype="categorical">
<Value value="grys"/>
<Value value="żwir"/>
</DataField>
<DataField name="rodzaj cementu" optype="categorical">
<Value value="CEM I"/>
<Value value="CEM II"/>
<Value value="CEM IV"/>
</DataField>

```

```

</DataDictionary>
<NeuralNetwork modelName="Arku_MLP 12-11-1" functionName="regression">
<MiningSchema>
<MiningField name="wytrzymałość [MPa]" usageType="predicted"/>
<MiningField name="w/s" lowValue="0.210000" highValue="0.500000"/>
<MiningField name="masa cementu" lowValue="1.249000" highValue="2.270000"/>
<MiningField name="masa wody" lowValue="0.477000" highValue="0.735000"/>
<MiningField name="masa kruszywa frakcji [2-8mm]" lowValue="2.340000" highValue="2.826000"/>
<MiningField name="masa kruszywa frakcji [8-16mm]" lowValue="2.340000" highValue="2.826000"/>
<MiningField name="masa domieszki" lowValue="0.000000" highValue="0.470000"/>
<MiningField name="masa mikro-krzemionki" lowValue="0.000000" highValue="0.891000"/>
<MiningField name="rodzaj kruszywa grubego"/>
<MiningField name="rodzaj cementu"/>
</MiningSchema>
<NeuralInputs numberOfInputs="12">
<NeuralInput id="0">
<DerivedField>
<NormContinuous field="w/s" shift="-7,24137931034483e-001" scale="3,44827586206897e+000">
<LinearNorm orig="2.10000000000000e-001" norm="0.000000"/>
<LinearNorm orig="5.00000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="1">
<DerivedField>
<NormContinuous field="masa cementu" shift="-1,22331047992165e+000" scale="9,79431929480901e-001">
<LinearNorm orig="1.24900000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.27000000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="2">
<DerivedField>
<NormContinuous field="masa wody" shift="-1,84883720930233e+000" scale="3,87596899224806e+000">
<LinearNorm orig="4.77000000000000e-001" norm="0.000000"/>
<LinearNorm orig="7.35000000000000e-001" norm="1.000000"/>
</NormContinuous>

```

```

</DerivedField>
</NeuralInput>
<NeuralInput id="3">
<DerivedField>
<NormContinuous field="masa kruszywa frakcji [2-
8mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<LinearNorm orig="2.34000000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.82600000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="4">
<DerivedField>
<NormContinuous field="masa kruszywa frakcji [8-
16mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<LinearNorm orig="2.34000000000000e+000" norm="0.000000"/>
<LinearNorm orig="2.82600000000000e+000" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="5">
<DerivedField>
<NormContinuous field="masa domieszki" shift="-
0,00000000000000e+000" scale="2,12765957446809e+000">
<LinearNorm orig="0.00000000000000e+000" norm="0.000000"/>
<LinearNorm orig="4.70000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="6">
<DerivedField>
<NormContinuous field="masa mikro- krzemionki" shift="-
0,00000000000000e+000" scale="1,12233445566779e+000">
<LinearNorm orig="0.00000000000000e+000" norm="0.000000"/>
<LinearNorm orig="8.91000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="7">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="grys"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="8">
<DerivedField>

```

```

<NormDiscrete field="rodzaj kruszywa grube-
go" value="żwir"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="9">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM I"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="10">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM II"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="11">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM IV"/>
</DerivedField>
</NeuralInput>
</NeuralInputs>
<NeuralLay-
er numberOfNeurons="11" activationFunction="tanh">
<Neuron id="12" bias="2.27028136893515e+000">
<Con from="0" weight="-8.09429374244849e+000"/>
<Con from="1" weight="-5.29759063131867e-001"/>
<Con from="2" weight="-1.82470007527750e+001"/>
<Con from="3" weight="1.66622143278189e+000"/>
<Con from="4" weight="7.43635181014224e-002"/>
<Con from="5" weight="-1.18781524193763e+001"/>
<Con from="6" weight="3.15733329732258e+000"/>
<Con from="7" weight="8.96922411394082e-002"/>
<Con from="8" weight="2.20117346072997e+000"/>
<Con from="9" weight="2.88079697446608e+000"/>
<Con from="10" weight="-2.28107189133263e+000"/>
<Con from="11" weight="1.69702085940175e+000"/>
</Neuron>
<Neuron id="13" bias="9.02062666735284e-001">
<Con from="0" weight="3.72735410224504e+000"/>
<Con from="1" weight="-5.13798176993423e-001"/>
<Con from="2" weight="3.63170322424424e+000"/>
<Con from="3" weight="1.76551754230833e+000"/>
<Con from="4" weight="-7.06686161272401e-001"/>
<Con from="5" weight="-7.32407016560976e-001"/>
<Con from="6" weight="-6.41059502369934e+000"/>
<Con from="7" weight="-8.22058515253121e-001"/>
<Con from="8" weight="1.61414241177252e+000"/>
<Con from="9" weight="-1.42893953738359e+000"/>
<Con from="10" weight="4.52882286259371e+000"/>
<Con from="11" weight="-2.27147547472371e+000"/>

```

```

</Neuron>
<Neuron id="14" bias="-1.37003943648987e+000">
<Con from="0" weight="2.56585402390672e+000"/>
<Con from="1" weight="-1.90376624239656e+000"/>
<Con from="2" weight="-2.72648587143651e+000"/>
<Con from="3" weight="6.38847162871805e+000"/>
<Con from="4" weight="-1.07791534200356e+000"/>
<Con from="5" weight="3.16397229047240e-001"/>
<Con from="6" weight="-7.17669390403187e+000"/>
<Con from="7" weight="-1.06251263401736e+000"/>
<Con from="8" weight="-2.68179155888412e-001"/>
<Con from="9" weight="2.00320690062195e+000"/>
<Con from="10" weight="-1.45394824123077e+000"/>
<Con from="11" weight="-1.97018495339264e+000"/>
</Neuron>
<Neuron id="15" bias="-1.23793881527616e+000">
<Con from="0" weight="-2.19497451112818e+000"/>
<Con from="1" weight="-1.47794842598959e+000"/>
<Con from="2" weight="4.76929816906834e+000"/>
<Con from="3" weight="3.23773253181808e+000"/>
<Con from="4" weight="-5.77266717128613e-001"/>
<Con from="5" weight="7.69786506001645e-002"/>
<Con from="6" weight="-1.81661340259503e+000"/>
<Con from="7" weight="-6.33613147637343e-001"/>
<Con from="8" weight="-7.14157877868077e-001"/>
<Con from="9" weight="-2.59553027497845e-001"/>
<Con from="10" weight="-3.42174331370666e-001"/>
<Con from="11" weight="-7.33465017739012e-001"/>
</Neuron>
<Neuron id="16" bias="2.41223140578555e+000">
<Con from="0" weight="-7.91144132886694e+000"/>
<Con from="1" weight="-3.23732711759368e+000"/>
<Con from="2" weight="-1.14886646169016e+001"/>
<Con from="3" weight="2.11815978005627e+000"/>
<Con from="4" weight="5.07371125462500e-003"/>
<Con from="5" weight="-6.31368600276018e+000"/>
<Con from="6" weight="2.98312494631813e+000"/>
<Con from="7" weight="-8.58259125438643e-004"/>
<Con from="8" weight="2.38148164178719e+000"/>
<Con from="9" weight="1.10423125188006e+000"/>
<Con from="10" weight="8.49599288871201e-001"/>
<Con from="11" weight="4.76340552671527e-001"/>
</Neuron>
<Neuron id="17" bias="7.44518766111898e-001">
<Con from="0" weight="6.41695956777526e-001"/>
<Con from="1" weight="-1.69937523687104e+000"/>
<Con from="2" weight="-6.41209357010466e+000"/>
<Con from="3" weight="1.73883875788981e+000"/>
<Con from="4" weight="-5.85760579187697e-002"/>

```

```

<Con from="5" weight="-2.28561807247772e+001"/>
<Con from="6" weight="2.35136414158884e+000"/>
<Con from="7" weight="-1.09351989358822e-001"/>
<Con from="8" weight="8.19499162667317e-001"/>
<Con from="9" weight="3.78777361119432e-001"/>
<Con from="10" weight="-2.38574114780825e-001"/>
<Con from="11" weight="5.87855096327437e-001"/>
</Neuron>
<Neuron id="18" bias="-2.75968324955889e+000">
<Con from="0" weight="-2.33358933027912e+000"/>
<Con from="1" weight="-2.85872328862234e+000"/>
<Con from="2" weight="-8.23274758858117e+000"/>
<Con from="3" weight="-2.07578780113173e+000"/>
<Con from="4" weight="-2.77081664791931e+000"/>
<Con from="5" weight="-2.58307607081784e+000"/>
<Con from="6" weight="3.29589832432555e+000"/>
<Con from="7" weight="-2.74685778623021e+000"/>
<Con from="8" weight="4.74130105120207e-002"/>
<Con from="9" weight="-8.69217507032668e+000"/>
<Con from="10" weight="-9.81423012775023e+000"/>
<Con from="11" weight="1.57454171716882e+001"/>
</Neuron>
<Neuron id="19" bias="1.22777485349641e+000">
<Con from="0" weight="2.54749852660413e+000"/>
<Con from="1" weight="-4.28578006591872e+000"/>
<Con from="2" weight="-2.49362453388145e+000"/>
<Con from="3" weight="5.78046481089832e+000"/>
<Con from="4" weight="-3.11750963308224e+000"/>
<Con from="5" weight="9.11781252649707e+000"/>
<Con from="6" weight="-5.35297055929338e+000"/>
<Con from="7" weight="-3.02439900758127e+000"/>
<Con from="8" weight="4.34529986347616e+000"/>
<Con from="9" weight="-3.88582886920924e-001"/>
<Con from="10" weight="-5.56114655289311e-001"/>
<Con from="11" weight="2.23782326745246e+000"/>
</Neuron>
<Neuron id="20" bias="1.16634433785533e+000">
<Con from="0" weight="1.83313610788756e+000"/>
<Con from="1" weight="-1.26782992172938e+000"/>
<Con from="2" weight="2.11384605431980e+000"/>
<Con from="3" weight="2.78697995845973e+000"/>
<Con from="4" weight="2.88764147643233e+000"/>
<Con from="5" weight="-7.49375977507142e+000"/>
<Con from="6" weight="-7.60495044295066e-002"/>
<Con from="7" weight="2.94441398090111e+000"/>
<Con from="8" weight="-1.75309477096257e+000"/>
<Con from="9" weight="2.66318771811213e+000"/>
<Con from="10" weight="2.30050996422531e+000"/>
<Con from="11" weight="-3.85022332065857e+000"/>

```

```

</Neuron>
<Neuron id="21" bias="-5.88442497821134e+000">
<Con from="0" weight="-3.99257780569421e+000"/>
<Con from="1" weight="1.61314886726322e+001"/>
<Con from="2" weight="2.38852585722690e+000"/>
<Con from="3" weight="-5.62584928915523e+000"/>
<Con from="4" weight="-1.56015260051832e-001"/>
<Con from="5" weight="-7.42356770627197e+000"/>
<Con from="6" weight="-1.22347639850030e+001"/>
<Con from="7" weight="-1.81402593784141e-001"/>
<Con from="8" weight="-5.70022105281935e+000"/>
<Con from="9" weight="-1.30765317837624e+000"/>
<Con from="10" weight="-2.80510145895656e+000"/>
<Con from="11" weight="-1.80760116734533e+000"/>
</Neuron>
<Neuron id="22" bias="-1.65050230828226e+000">
<Con from="0" weight="-4.36984231698183e+000"/>
<Con from="1" weight="-7.87836060845316e-001"/>
<Con from="2" weight="4.06507726883648e+000"/>
<Con from="3" weight="-1.23191518176518e+000"/>
<Con from="4" weight="1.82365284302130e-001"/>
<Con from="5" weight="5.28081110923558e+000"/>
<Con from="6" weight="-2.12245588131665e+000"/>
<Con from="7" weight="1.61751067551191e-001"/>
<Con from="8" weight="-1.79482009990998e+000"/>
<Con from="9" weight="-3.16921731663178e-001"/>
<Con from="10" weight="-5.12595801525166e+000"/>
<Con from="11" weight="3.68347247125452e+000"/>
</Neuron>
</NeuralLayer>
<NeuralLayer
numberOfNeurons="1" activationFunction="logistic">
<Neuron id="23" bias="-3.62332070670438e+000">
<Con from="12" weight="-4.98463360293182e+000"/>
<Con from="13" weight="-1.71667016366258e+000"/>
<Con from="14" weight="-2.04780380745809e-001"/>
<Con from="15" weight="-1.35779153321218e+000"/>
<Con from="16" weight="-7.32528101833513e+000"/>
<Con from="17" weight="-4.84432662200739e+000"/>
<Con from="18" weight="-2.04149968307727e+000"/>
<Con from="19" weight="-1.57789781359501e+000"/>
<Con from="20" weight="-1.10624227871463e+000"/>
<Con from="21" weight="1.08257317466288e+001"/>
<Con from="22" weight="9.00367821252434e-001"/>
</Neuron>
</NeuralLayer>
<NeuralOutputs numberOfOutputs="1">
<NeuralOutput outputNeuron="23">
<DerivedField optype="continuous">

```



```
<NormContinuous field="wytrzymałość [MPa]" shift="-
9,13980911373612e-005" scale="9,20652972026639e-003">
<LinearNorm orig="9.92752903802244e-
003" norm="0.00000000000000e+000"/>
<Linear-
Norm orig="1.08628487440781e+002" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
</NeuralOutputs>
</NeuralNetwork>
</PMML>
```

## 2. ZADANIE 2

### 2.1. SIEĆ 3. MLP 7-13-6

```
<PMML version="3.0">
<Header copyright="Copyright (c) StatSoft, Inc. All Rights
Reserved.">
<Application name="STATISTICA Automated Neural Networks
(SANN) " version="2.0"/>
</Header>
<DataDictionary numberOfFields="10">
<DataField name="masa cementu" optype="continuous"/>
<DataField name="masa wody" optype="continuous"/>
<DataField name="masa kruszywa frakcji [2-
8mm]" optype="continuous"/>
<DataField name="masa kruszywa frakcji [8-
16mm]" optype="continuous"/>
<DataField name="masa domieszki" optype="continuous"/>
<DataField name="masa mikro- krzemion-
ki" optype="continuous"/>
<DataField name="w/s" optype="continuous"/>
<DataField name="wytrzymałość [MPa]" optype="continuous"/>
<DataField name="rodzaj kruszywa grube-
go" optype="categorical">
<Value value="grys"/>
<Value value="żwir"/>
</DataField>
<DataField name="rodzaj cementu" optype="categorical">
<Value value="CEM I"/>
<Value value="CEM II"/>
<Value value="CEM IV"/>
</DataField>
</DataDictionary>
<NeuralNetwork modelName="Arkus_MLP 7-13-
6" functionName="regression">
<MiningSchema>
<MiningField name="masa cementu" usageType="predicted"/>
<MiningField name="masa wody" usageType="predicted"/>
<MiningField name="masa kruszywa frakcji [2-
8mm]" usageType="predicted"/>
<MiningField name="masa kruszywa frakcji [8-
16mm]" usageType="predicted"/>
<MiningField name="masa domieszki" usageType="predicted"/>
<MiningField name="masa mikro- krzemion-
ki" usageType="predicted"/>
<Mining-
Field name="w/s" lowValue="0.210000" highValue="0.500000"/>
```

```

<MiningField name="wytrzymałość
[MPa]" lowValue="0.079467" highValue="108.628487"/>
<MiningField name="rodzaj kruszywa grubego"/>
<MiningField name="rodzaj cementu"/>
</MiningSchema>
<NeuralInputs numberOfInputs="7">
<NeuralInput id="0">
<DerivedField>
<NormContinuous field="w/s" shift="-7,24137931034483e-
001" scale="3,44827586206897e+000">
<LinearNorm orig="2.100000000000000e-001" norm="0.000000"/>
<LinearNorm orig="5.000000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="1">
<DerivedField>
<NormContinuous field="wytrzymałość [MPa]" shift="-
9,08202945086172e-005" scale="9,14832826585301e-003">
<LinearNorm orig="7.94672783845844e-002" norm="0.000000"/>
<LinearNorm orig="1.08628487440781e+002" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="2">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="grys"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="3">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="żwir"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="4">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM I"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="5">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM II"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="6">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM IV"/>

```

```

</DerivedField>
</NeuralInput>
</NeuralInputs>
<NeuralLayer
  numberOfNeurons="13" activationFunction="tanh">
  <Neuron id="7" bias="-4.34356870469340e-002">
    <Con from="0" weight="-2.90945750518205e-001"/>
    <Con from="1" weight="-5.92053946757964e+000"/>
    <Con from="2" weight="3.07534292061604e-001"/>
    <Con from="3" weight="-2.59427024113192e-001"/>
    <Con from="4" weight="-2.01282961737904e-002"/>
    <Con from="5" weight="-5.33631111464357e-002"/>
    <Con from="6" weight="9.71402026529313e-002"/>
  </Neuron>
  <Neuron id="8" bias="-1.01660604520178e+000">
    <Con from="0" weight="-1.83006014357507e+000"/>
    <Con from="1" weight="3.61440788949492e-001"/>
    <Con from="2" weight="-2.23467806179769e+000"/>
    <Con from="3" weight="1.13158168758229e+000"/>
    <Con from="4" weight="-4.32327365472231e-001"/>
    <Con from="5" weight="-3.58576605019311e-001"/>
    <Con from="6" weight="-3.28692747974719e-001"/>
  </Neuron>
  <Neuron id="9" bias="5.83133351792718e-001">
    <Con from="0" weight="3.58416349106968e-001"/>
    <Con from="1" weight="1.05803209311679e-001"/>
    <Con from="2" weight="9.28698500818229e-001"/>
    <Con from="3" weight="-2.54783782156083e-001"/>
    <Con from="4" weight="2.01131242635627e-001"/>
    <Con from="5" weight="1.89846346363875e-001"/>
    <Con from="6" weight="1.92671612440260e-001"/>
  </Neuron>
  <Neuron id="10" bias="-3.72942969890355e-001">
    <Con from="0" weight="-5.88288330696181e-001"/>
    <Con from="1" weight="-7.00243995780720e-001"/>
    <Con from="2" weight="-1.90201895332612e+000"/>
    <Con from="3" weight="1.53769575409162e+000"/>
    <Con from="4" weight="-1.44748784104233e-001"/>
    <Con from="5" weight="-1.33346180054349e-001"/>
    <Con from="6" weight="-1.94213392039907e-001"/>
  </Neuron>
  <Neuron id="11" bias="-3.38638987010829e-001">
    <Con from="0" weight="-1.43390267818181e+000"/>
    <Con from="1" weight="1.26729342664414e-001"/>
    <Con from="2" weight="-2.33976627901041e-001"/>
    <Con from="3" weight="-6.59234442118521e-002"/>
    <Con from="4" weight="-1.37609597633818e-001"/>
    <Con from="5" weight="-1.35000518265499e-001"/>
    <Con from="6" weight="-1.27066117248687e-001"/>
  </Neuron>
  <Neuron id="12" bias="1.01660604520178e+000">
    <Con from="0" weight="1.83006014357507e+000"/>
    <Con from="1" weight="-3.61440788949492e-001"/>
    <Con from="2" weight="2.23467806179769e+000"/>
    <Con from="3" weight="-1.13158168758229e+000"/>
    <Con from="4" weight="4.32327365472231e-001"/>
    <Con from="5" weight="3.58576605019311e-001"/>
    <Con from="6" weight="3.28692747974719e-001"/>
  </Neuron>
  <Neuron id="13" bias="4.34356870469340e-002">
    <Con from="0" weight="2.90945750518205e-001"/>
    <Con from="1" weight="5.92053946757964e+000"/>
    <Con from="2" weight="-3.07534292061604e-001"/>
    <Con from="3" weight="2.59427024113192e-001"/>
    <Con from="4" weight="2.01282961737904e-002"/>
    <Con from="5" weight="5.33631111464357e-002"/>
    <Con from="6" weight="-9.71402026529313e-002"/>
  </Neuron>
</NeuralLayer>

```

```

</Neuron>
<Neuron id="12" bias="-7.00455752092839e-001">
<Con from="0" weight="6.11364370026680e-001"/>
<Con from="1" weight="-1.21071524021702e+001"/>
<Con from="2" weight="-2.57451398560408e-001"/>
<Con from="3" weight="-3.94957898223810e-001"/>
<Con from="4" weight="-2.47869563982401e-001"/>
<Con from="5" weight="-3.00700867497727e-001"/>
<Con from="6" weight="-2.39324450072321e-001"/>
</Neuron>
<Neuron id="13" bias="-4.09079825743079e-001">
<Con from="0" weight="1.58632866315493e+000"/>
<Con from="1" weight="5.46356457583952e-001"/>
<Con from="2" weight="2.19683376726602e+000"/>
<Con from="3" weight="-2.63585992762386e+000"/>
<Con from="4" weight="-1.68568360400215e-001"/>
<Con from="5" weight="-1.49727983411061e-001"/>
<Con from="6" weight="-1.39402365351511e-001"/>
</Neuron>
<Neuron id="14" bias="5.25538122336722e-001">
<Con from="0" weight="2.20388240019169e+000"/>
<Con from="1" weight="-6.04020647896553e-001"/>
<Con from="2" weight="7.51151596508670e-001"/>
<Con from="3" weight="-3.50906025050591e-001"/>
<Con from="4" weight="2.03366781353113e-001"/>
<Con from="5" weight="1.37904958730112e-001"/>
<Con from="6" weight="1.00464373137017e-001"/>
</Neuron>
<Neuron id="15" bias="1.68972605228355e-001">
<Con from="0" weight="3.23760810563765e-002"/>
<Con from="1" weight="-3.82714705601078e-002"/>
<Con from="2" weight="-2.39840255827237e-001"/>
<Con from="3" weight="3.81059781895191e-001"/>
<Con from="4" weight="1.12456696771131e-001"/>
<Con from="5" weight="1.27188444562038e-001"/>
<Con from="6" weight="1.20580964189451e-001"/>
</Neuron>
<Neuron id="16" bias="-1.60810967611174e-001">
<Con from="0" weight="9.66066659980882e-001"/>
<Con from="1" weight="6.21913389608369e-001"/>
<Con from="2" weight="-1.56502936637455e+000"/>
<Con from="3" weight="1.32546539312973e+000"/>
<Con from="4" weight="-1.40412534992100e-001"/>
<Con from="5" weight="-7.78061989903461e-002"/>
<Con from="6" weight="-3.14488879385012e-002"/>
</Neuron>
<Neuron id="17" bias="-8.97081284433945e-001">
<Con from="0" weight="-1.42273617935689e-001"/>
<Con from="1" weight="8.93885200410153e-002"/>

```

```

<Con from="2" weight="-4.25923982477383e-001"/>
<Con from="3" weight="-3.65598174676289e-001"/>
<Con from="4" weight="-2.95982699214254e-001"/>
<Con from="5" weight="-2.97215833497010e-001"/>
<Con from="6" weight="-3.30311283452994e-001"/>
</Neuron>
<Neuron id="18" bias="3.06510504449340e-001">
<Con from="0" weight="1.34091895419495e-001"/>
<Con from="1" weight="-1.89718135484585e-002"/>
<Con from="2" weight="-7.07694719909041e-001"/>
<Con from="3" weight="1.06318811091579e+000"/>
<Con from="4" weight="1.32281435473693e-001"/>
<Con from="5" weight="1.20869587558905e-001"/>
<Con from="6" weight="1.18404295439579e-001"/>
</Neuron>
<Neuron id="19" bias="-6.69865893088013e-001">
<Con from="0" weight="-7.33881051273904e-001"/>
<Con from="1" weight="-4.04672348611693e-002"/>
<Con from="2" weight="-1.66058592915815e-001"/>
<Con from="3" weight="-4.64938860036548e-001"/>
<Con from="4" weight="-1.77522394561811e-001"/>
<Con from="5" weight="-2.33325465144745e-001"/>
<Con from="6" weight="-2.17139556821385e-001"/>
</Neuron>
</NeuralLayer>
<NeuralLayer
  numberOfNeurons="6" activationFunction="identity">
<Neuron id="20" bias="1.15165985446437e+000">
<Con from="7" weight="2.96562464699995e-001"/>
<Con from="8" weight="-1.00125809055394e+000"/>
<Con from="9" weight="-1.67745729901216e+000"/>
<Con from="10" weight="1.03743314974701e-001"/>
<Con from="11" weight="7.22339522065590e-002"/>
<Con from="12" weight="-3.21070969453087e+000"/>
<Con from="13" weight="-1.21043380191058e+000"/>
<Con from="14" weight="-1.06470684140384e+000"/>
<Con from="15" weight="-1.40883536996166e+000"/>
<Con from="16" weight="-3.60692714474406e-001"/>
<Con from="17" weight="8.36152563721326e-001"/>
<Con from="18" weight="-1.41426558241877e+000"/>
<Con from="19" weight="3.79716388407599e-001"/>
</Neuron>
<Neuron id="21" bias="-2.17356901535004e+000">
<Con from="7" weight="1.42073877417436e-002"/>
<Con from="8" weight="-5.18116614892470e-001"/>
<Con from="9" weight="-1.63517262829644e-001"/>
<Con from="10" weight="-2.04357079850152e-002"/>
<Con from="11" weight="-1.54027596633676e+000"/>
<Con from="12" weight="-1.38157941416912e-001"/>

```

```

<Con from="13" weight="1.94016208695836e+000"/>
<Con from="14" weight="-5.15212543910663e-001"/>
<Con from="15" weight="9.75771260670835e-001"/>
<Con from="16" weight="4.06848617701886e-001"/>
<Con from="17" weight="-1.02201508358469e+000"/>
<Con from="18" weight="2.39437840971307e+000"/>
<Con from="19" weight="7.39791849949742e-001"/>
</Neuron>
<Neuron id="22" bias="1.76967265139517e+000">
<Con from="7" weight="-5.51084536034879e-002"/>
<Con from="8" weight="3.79216158105248e-001"/>
<Con from="9" weight="-5.54767734744499e-001"/>
<Con from="10" weight="-2.78316236041274e-001"/>
<Con from="11" weight="3.52869908678136e-001"/>
<Con from="12" weight="2.87676263242988e-001"/>
<Con from="13" weight="9.06112214939168e-001"/>
<Con from="14" weight="4.78657864618818e-001"/>
<Con from="15" weight="7.21473629522866e-001"/>
<Con from="16" weight="1.58049643549810e-001"/>
<Con from="17" weight="2.88613733719911e-001"/>
<Con from="18" weight="2.67493561925012e-001"/>
<Con from="19" weight="6.16423894058238e-001"/>
</Neuron>
<Neuron id="23" bias="2.14281385266640e+000">
<Con from="7" weight="-3.75243689926078e-002"/>
<Con from="8" weight="1.53731107193582e-001"/>
<Con from="9" weight="-1.33142511239654e+000"/>
<Con from="10" weight="-3.88327267914278e-001"/>
<Con from="11" weight="2.30818480527100e-001"/>
<Con from="12" weight="1.56739241646095e-001"/>
<Con from="13" weight="1.05265801053538e+000"/>
<Con from="14" weight="3.16081047455433e-001"/>
<Con from="15" weight="7.96857483197667e-001"/>
<Con from="16" weight="1.72877895638096e-001"/>
<Con from="17" weight="2.81567620615674e-001"/>
<Con from="18" weight="4.09314735542050e-001"/>
<Con from="19" weight="7.72119364792291e-001"/>
</Neuron>
<Neuron id="24" bias="-3.88549779596086e-001">
<Con from="7" weight="-1.34472438061266e-001"/>
<Con from="8" weight="-3.69323299724454e-001"/>
<Con from="9" weight="-1.79504562762397e-001"/>
<Con from="10" weight="-2.39384307329874e-001"/>
<Con from="11" weight="6.88767143120009e-001"/>
<Con from="12" weight="1.76041844763467e+000"/>
<Con from="13" weight="-2.93128439462691e-001"/>
<Con from="14" weight="-2.32092936830426e-001"/>
<Con from="15" weight="-1.30290898539664e+000"/>
<Con from="16" weight="-6.56965985188945e-001"/>

```

```

<Con from="17" weight="3.48988086169100e-002"/>
<Con from="18" weight="1.18531139047889e+000"/>
<Con from="19" weight="-2.97187055336175e+000"/>
</Neuron>
<Neuron id="25" bias="1.40945586535400e-001">
<Con from="7" weight="-4.46819120567539e-001"/>
<Con from="8" weight="2.42579778492733e+000"/>
<Con from="9" weight="3.56486438959547e+000"/>
<Con from="10" weight="-1.54281813966733e-002"/>
<Con from="11" weight="1.77822740657017e+000"/>
<Con from="12" weight="4.16061084058643e+000"/>
<Con from="13" weight="-6.42813522331532e-001"/>
<Con from="14" weight="2.39384244903523e+000"/>
<Con from="15" weight="7.06076833213194e-001"/>
<Con from="16" weight="-2.13927435133461e-002"/>
<Con from="17" weight="-1.33447314259075e+000"/>
<Con from="18" weight="-6.76463299971110e-001"/>
<Con from="19" weight="-1.209366661110611e+000"/>
</Neuron>
</NeuralLayer>
<NeuralOutputs numberOfOutputs="6">
<NeuralOutput outputNeuron="20">
<DerivedField optype="continuous">
<NormContinuous field="masa cementu" shift="-
1,22331047992165e+000" scale="9,79431929480901e-001">
<Linear-
Norm orig="1.24900000000000e+000" norm="0.00000000000000e+0
00"/>
<Linear-
Norm orig="2.27000000000000e+000" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="21">
<DerivedField optype="continuous">
<NormContinuous field="masa wody" shift="-
1,84883720930233e+000" scale="3,87596899224806e+000">
<LinearNorm orig="4.77000000000000e-
001" norm="0.00000000000000e+000"/>
<LinearNorm orig="7.35000000000000e-
001" norm="1.00000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="22">
<DerivedField optype="continuous">

```



```

<NormContinuous field="masa kruszywa frakcji [2-
8mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<Linear-
Norm orig="2.34000000000000e+000" norm="0.00000000000000e+0
00"/>
<Linear-
Norm orig="2.82600000000000e+000" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="23">
<DerivedField optype="continuous">
<NormContinuous field="masa kruszywa frakcji [8-
16mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<Linear-
Norm orig="2.34000000000000e+000" norm="0.00000000000000e+0
00"/>
<Linear-
Norm orig="2.82600000000000e+000" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="24">
<DerivedField optype="continuous">
<NormContinuous field="masa domieszki" shift="-
0,00000000000000e+000" scale="2,12765957446809e+000">
<Linear-
Norm orig="0.00000000000000e+000" norm="0.00000000000000e+0
00"/>
<LinearNorm orig="4.70000000000000e-
001" norm="1.00000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="25">
<DerivedField optype="continuous">
<NormContinuous field="masa mikro- krzemionki" shift="-
0,00000000000000e+000" scale="1,12233445566779e+000">
<Linear-
Norm orig="0.00000000000000e+000" norm="0.00000000000000e+0
00"/>
<LinearNorm orig="8.91000000000000e-
001" norm="1.00000000000000e+000"/>
</NormContinuous>
</DerivedField>

```

```

</NeuralOutput>
</NeuralOutputs>
</NeuralNetwork>
</PMML>

```

## 2.2. SIEĆ 5. MLP 7-9-6

```

<PMML version="3.0">
<Header copyright="Copyright (c) StatSoft, Inc. All Rights
Reserved.">
<Application name="STATISTICA Automated Neural Networks
(SANN)" version="2.0"/>
</Header>
<DataDictionary numberOfFields="10">
<DataField name="masa cementu" optype="continuous"/>
<DataField name="masa wody" optype="continuous"/>
<DataField name="masa kruszywa frakcji [2-
8mm]" optype="continuous"/>
<DataField name="masa kruszywa frakcji [8-
16mm]" optype="continuous"/>
<DataField name="masa domieszki" optype="continuous"/>
<DataField name="masa mikro- krzemion-
ki" optype="continuous"/>
<DataField name="w/s" optype="continuous"/>
<DataField name="wytrzymałość [MPa]" optype="continuous"/>
<DataField name="rodzaj kruszywa grube-
go" optype="categorical">
<Value value="grys"/>
<Value value="żwir"/>
</DataField>
<DataField name="rodzaj cementu" optype="categorical">
<Value value="CEM I"/>
<Value value="CEM II"/>
<Value value="CEM IV"/>
</DataField>
</DataDictionary>
<NeuralNetwork modelName="Arkus_MLP 7-9-
6" functionName="regression">
<MiningSchema>
<MiningField name="masa cementu" usageType="predicted"/>
<MiningField name="masa wody" usageType="predicted"/>
<MiningField name="masa kruszywa frakcji [2-
8mm]" usageType="predicted"/>
<MiningField name="masa kruszywa frakcji [8-
16mm]" usageType="predicted"/>
<MiningField name="masa domieszki" usageType="predicted"/>
<MiningField name="masa mikro- krzemion-
ki" usageType="predicted"/>

```

```

<Mining-
Field name="w/s" lowValue="0.210000" highValue="0.500000"/>
<MiningField name="wytrzymałość
[MPa]" lowValue="0.079467" highValue="108.628487"/>
<MiningField name="rodzaj kruszywa grubego"/>
<MiningField name="rodzaj cementu"/>
</MiningSchema>
<NeuralInputs numberOfInputs="7">
<NeuralInput id="0">
<DerivedField>
<NormContinuous field="w/s" shift="-7,24137931034483e-
001" scale="3,44827586206897e+000">
<LinearNorm orig="2.100000000000000e-001" norm="0.000000"/>
<LinearNorm orig="5.000000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="1">
<DerivedField>
<NormContinuous field="wytrzymałość [MPa]" shift="-
9,08202945086172e-005" scale="9,14832826585301e-003">
<LinearNorm orig="7.94672783845844e-002" norm="0.000000"/>
<LinearNorm orig="1.08628487440781e+002" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="2">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="grys"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="3">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="żwir"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="4">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM I"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="5">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM II"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="6">

```

```

<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM IV"/>
</DerivedField>
</NeuralInput>
</NeuralInputs>
<NeuralLayer numberOfNeurons="9" activationFunction="tanh">
<Neuron id="7" bias="1.93427430248398e+000">
<Con from="0" weight="6.81223148689240e-001"/>
<Con from="1" weight="-2.60580814158953e+000"/>
<Con from="2" weight="-1.61554626885118e+000"/>
<Con from="3" weight="3.69011670869031e+000"/>
<Con from="4" weight="4.96104913837606e-001"/>
<Con from="5" weight="6.57414409764666e-001"/>
<Con from="6" weight="6.53073938596652e-001"/>
</Neuron>
<Neuron id="8" bias="-8.95322280027385e-001">
<Con from="0" weight="-1.60225004348049e-001"/>
<Con from="1" weight="1.45210115719969e+000"/>
<Con from="2" weight="-5.95491243159898e-001"/>
<Con from="3" weight="-3.54290391375448e-001"/>
<Con from="4" weight="-3.31767837845530e-001"/>
<Con from="5" weight="-3.62789125130847e-001"/>
<Con from="6" weight="-2.59878279011180e-001"/>
</Neuron>
<Neuron id="9" bias="4.07307865099260e-001">
<Con from="0" weight="-8.73127568302075e-001"/>
<Con from="1" weight="9.25412570535317e-001"/>
<Con from="2" weight="-7.96607872194433e-002"/>
<Con from="3" weight="4.79270398897526e-001"/>
<Con from="4" weight="1.35064184814588e-001"/>
<Con from="5" weight="1.51344445030558e-001"/>
<Con from="6" weight="1.81312594777323e-001"/>
</Neuron>
<Neuron id="10" bias="-2.72703047225708e+000">
<Con from="0" weight="2.56215456699769e+000"/>
<Con from="1" weight="1.30560303908830e+000"/>
<Con from="2" weight="-2.95516414974825e+000"/>
<Con from="3" weight="1.47228835137438e-001"/>
<Con from="4" weight="-9.16297318665618e-001"/>
<Con from="5" weight="-9.89636294649312e-001"/>
<Con from="6" weight="-8.94459080194193e-001"/>
</Neuron>
<Neuron id="11" bias="8.64651580158387e-003">
<Con from="0" weight="3.75808513102451e-001"/>
<Con from="1" weight="4.05052637507622e-001"/>
<Con from="2" weight="4.55058300448178e+000"/>
<Con from="3" weight="-4.50872105455254e+000"/>
<Con from="4" weight="6.38509399056854e-002"/>
<Con from="5" weight="-2.78839695430374e-002"/>

```

```

<Con from="6" weight="-1.34534111857426e-001"/>
</Neuron>
<Neuron id="12" bias="-2.71789148696383e-001">
<Con from="0" weight="1.17792243730923e+000"/>
<Con from="1" weight="1.75546547425683e-001"/>
<Con from="2" weight="-9.81777592393514e-001"/>
<Con from="3" weight="7.16310276790555e-001"/>
<Con from="4" weight="-9.81747739422204e-002"/>
<Con from="5" weight="-6.80410729024431e-002"/>
<Con from="6" weight="-4.28130972744282e-002"/>
</Neuron>
<Neuron id="13" bias="2.71459034577651e-001">
<Con from="0" weight="7.24732576459689e+000"/>
<Con from="1" weight="-1.49397051348631e-001"/>
<Con from="2" weight="1.21178880837951e-001"/>
<Con from="3" weight="1.96956623555232e-001"/>
<Con from="4" weight="1.24617028781788e-001"/>
<Con from="5" weight="1.79194567092656e-001"/>
<Con from="6" weight="4.96832989868879e-002"/>
</Neuron>
<Neuron id="14" bias="4.81060515794253e+000">
<Con from="0" weight="2.54845456572375e-001"/>
<Con from="1" weight="3.37353851605683e+000"/>
<Con from="2" weight="4.14506880794053e+000"/>
<Con from="3" weight="4.55696536264358e-001"/>
<Con from="4" weight="4.28806685842835e-001"/>
<Con from="5" weight="2.97729933417910e+000"/>
<Con from="6" weight="1.32774270150945e+000"/>
</Neuron>
<Neuron id="15" bias="-9.89192999332474e-002">
<Con from="0" weight="-4.73940682225686e+000"/>
<Con from="1" weight="-2.39819786708163e+001"/>
<Con from="2" weight="-1.13195382815522e-002"/>
<Con from="3" weight="-7.39077602689308e-002"/>
<Con from="4" weight="-1.21687100911719e-002"/>
<Con from="5" weight="-7.22187487383782e-002"/>
<Con from="6" weight="5.11391544673005e-002"/>
</Neuron>
</NeuralLayer>
<NeuralLayer
er numberOfNeurons="6" activationFunction="logistic">
<Neuron id="16" bias="1.64348314997717e+000">
<Con from="7" weight="1.39024401342676e-001"/>
<Con from="8" weight="1.36756996443782e+000"/>
<Con from="9" weight="-7.05136131985120e-001"/>
<Con from="10" weight="-2.38197532201054e+000"/>
<Con from="11" weight="-2.55047355413665e+000"/>
<Con from="12" weight="-3.73674776920819e+000"/>
<Con from="13" weight="-6.99817562444863e+000"/>

```

```

<Con from="14" weight="2.17074425911751e-001"/>
<Con from="15" weight="-4.55161375319121e+000"/>
</Neuron>
<Neuron id="17" bias="-1.66812532504156e+000">
<Con from="7" weight="-6.86274772594237e-001"/>
<Con from="8" weight="3.19091781162816e-001"/>
<Con from="9" weight="-3.49518569093466e+000"/>
<Con from="10" weight="3.46304865697858e+000"/>
<Con from="11" weight="1.41636613317622e+000"/>
<Con from="12" weight="3.16149331904634e+000"/>
<Con from="13" weight="5.64524049184591e+000"/>
<Con from="14" weight="7.02908985954066e-001"/>
<Con from="15" weight="-1.46992096797653e+000"/>
</Neuron>
<Neuron id="18" bias="-3.75969904950758e-001">
<Con from="7" weight="-2.43940856537509e+000"/>
<Con from="8" weight="-2.37046423862409e+000"/>
<Con from="9" weight="-8.49999774914862e-001"/>
<Con from="10" weight="-1.12925160189546e-001"/>
<Con from="11" weight="5.18325235839460e+000"/>
<Con from="12" weight="-2.58430146410388e+000"/>
<Con from="13" weight="1.76538977290287e+000"/>
<Con from="14" weight="-4.81831350942045e-001"/>
<Con from="15" weight="-6.82607533093961e-001"/>
</Neuron>
<Neuron id="19" bias="7.61095168651608e-001">
<Con from="7" weight="-2.31826740356240e+000"/>
<Con from="8" weight="-2.28751046986536e+000"/>
<Con from="9" weight="-1.09882890282623e+000"/>
<Con from="10" weight="1.24729778523221e+000"/>
<Con from="11" weight="4.69614841753773e+000"/>
<Con from="12" weight="-2.16645131816976e+000"/>
<Con from="13" weight="1.70965738505974e+000"/>
<Con from="14" weight="1.76902360972485e-002"/>
<Con from="15" weight="-9.36761499677069e-001"/>
</Neuron>
<Neuron id="20" bias="-1.55020866771990e+000">
<Con from="7" weight="-5.14815754102131e-001"/>
<Con from="8" weight="3.97598666811111e+000"/>
<Con from="9" weight="-4.12691902681959e+000"/>
<Con from="10" weight="-1.64479289027756e-001"/>
<Con from="11" weight="-2.10658669585566e+000"/>
<Con from="12" weight="-2.26617219583625e+000"/>
<Con from="13" weight="5.26940063477885e-001"/>
<Con from="14" weight="5.96207849747989e+000"/>
<Con from="15" weight="1.70948036917993e+000"/>
</Neuron>
<Neuron id="21" bias="-5.38550301291453e+000">
<Con from="7" weight="4.29093341995388e-001"/>

```

```

<Con from="8" weight="-2.33003031063794e+000"/>
<Con from="9" weight="3.06198512697791e+000"/>
<Con from="10" weight="1.88009318008533e+000"/>
<Con from="11" weight="4.07087065498227e-001"/>
<Con from="12" weight="-5.14607047077974e-001"/>
<Con from="13" weight="1.05100126252125e+001"/>
<Con from="14" weight="-1.73926325243591e+000"/>
<Con from="15" weight="7.72334024153863e+000"/>
</Neuron>
</NeuralLayer>
<NeuralOutputs numberOfOutputs="6">
<NeuralOutput outputNeuron="16">
<DerivedField optype="continuous">
<NormContinuous field="masa cementu" shift="-
1,22331047992165e+000" scale="9,79431929480901e-001">
<Linear-
Norm orig="1.24900000000000e+000" norm="0.00000000000000e+0
00"/>
<Linear-
Norm orig="2.27000000000000e+000" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="17">
<DerivedField optype="continuous">
<NormContinuous field="masa wody" shift="-
1,84883720930233e+000" scale="3,87596899224806e+000">
<LinearNorm orig="4.77000000000000e-
001" norm="0.00000000000000e+000"/>
<LinearNorm orig="7.35000000000000e-
001" norm="1.00000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="18">
<DerivedField optype="continuous">
<NormContinuous field="masa kruszywa frakcji [2-
8mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<Linear-
Norm orig="2.34000000000000e+000" norm="0.00000000000000e+0
00"/>
<Linear-
Norm orig="2.82600000000000e+000" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>

```

```

<NeuralOutput outputNeuron="19">
<DerivedField optype="continuous">
<NormContinuous field="masa kruszywa frakcji [8-
16mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<Linear-
Norm orig="2.34000000000000e+000" norm="0.00000000000000e+0
00"/>
<Linear-
Norm orig="2.82600000000000e+000" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="20">
<DerivedField optype="continuous">
<NormContinuous field="masa domieszki" shift="-
0,00000000000000e+000" scale="2,12765957446809e+000">
<Linear-
Norm orig="0.00000000000000e+000" norm="0.00000000000000e+0
00"/>
<LinearNorm orig="4.70000000000000e-
001" norm="1.00000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="21">
<DerivedField optype="continuous">
<NormContinuous field="masa mikro- krzemionki" shift="-
0,00000000000000e+000" scale="1,12233445566779e+000">
<Linear-
Norm orig="0.00000000000000e+000" norm="0.00000000000000e+0
00"/>
<LinearNorm orig="8.91000000000000e-
001" norm="1.00000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
</NeuralOutputs>
</NeuralNetwork>
</PMML>

```

### 2.3. SIEĆ 9. MLP 7-10-6

```

<PMML version="3.0">
<Header copyright="Copyright (c) StatSoft, Inc. All Rights
Reserved.">

```



```

<Application name="STATISTICA Automated Neural Networks
(SANN)" version="2.0"/>
</Header>
<DataDictionary numberOfFields="10">
<DataField name="masa cementu" optype="continuous"/>
<DataField name="masa wody" optype="continuous"/>
<DataField name="masa kruszywa frakcji [2-
8mm]" optype="continuous"/>
<DataField name="masa kruszywa frakcji [8-
16mm]" optype="continuous"/>
<DataField name="masa domieszki" optype="continuous"/>
<DataField name="masa mikro- krzemion-
ki" optype="continuous"/>
<DataField name="w/s" optype="continuous"/>
<DataField name="wytrzymałość [MPa]" optype="continuous"/>
<DataField name="rodzaj kruszywa grube-
go" optype="categorical">
<Value value="grys"/>
<Value value="żwir"/>
</DataField>
<DataField name="rodzaj cementu" optype="categorical">
<Value value="CEM I"/>
<Value value="CEM II"/>
<Value value="CEM IV"/>
</DataField>
</DataDictionary>
<NeuralNetwork modelName="Arkus_MLP 7-10-
6" functionName="regression">
<MiningSchema>
<MiningField name="masa cementu" usageType="predicted"/>
<MiningField name="masa wody" usageType="predicted"/>
<MiningField name="masa kruszywa frakcji [2-
8mm]" usageType="predicted"/>
<MiningField name="masa kruszywa frakcji [8-
16mm]" usageType="predicted"/>
<MiningField name="masa domieszki" usageType="predicted"/>
<MiningField name="masa mikro- krzemion-
ki" usageType="predicted"/>
<Mining-
Field name="w/s" lowValue="0.210000" highValue="0.500000"/>
<MiningField name="wytrzymałość
[MPa]" lowValue="0.079467" highValue="108.628487"/>
<MiningField name="rodzaj kruszywa grubego"/>
<MiningField name="rodzaj cementu"/>
</MiningSchema>
<NeuralInputs numberOfInputs="7">
<NeuralInput id="0">
<DerivedField>

```

```

<NormContinuous field="w/s" shift="-7,24137931034483e-
001" scale="3,44827586206897e+000">
<LinearNorm orig="2.100000000000000e-001" norm="0.000000"/>
<LinearNorm orig="5.000000000000000e-001" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="1">
<DerivedField>
<NormContinuous field="wytrzymałość [MPa]" shift="-
9,08202945086172e-005" scale="9,14832826585301e-003">
<LinearNorm orig="7.94672783845844e-002" norm="0.000000"/>
<LinearNorm orig="1.08628487440781e+002" norm="1.000000"/>
</NormContinuous>
</DerivedField>
</NeuralInput>
<NeuralInput id="2">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="grys"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="3">
<DerivedField>
<NormDiscrete field="rodzaj kruszywa grube-
go" value="żwir"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="4">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM I"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="5">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM II"/>
</DerivedField>
</NeuralInput>
<NeuralInput id="6">
<DerivedField>
<NormDiscrete field="rodzaj cementu" value="CEM IV"/>
</DerivedField>
</NeuralInput>
</NeuralInputs>
<NeuralLay-
er numberOfNeurons="10" activationFunction="tanh">
<Neuron id="7" bias="-2.70979977901975e-001">
<Con from="0" weight="-4.53458050736187e-001"/>
<Con from="1" weight="-2.10428647861322e+000"/>

```

```

<Con from="2" weight="-2.29251817573438e-001"/>
<Con from="3" weight="-8.938357056566693e-002"/>
<Con from="4" weight="-1.44482211725129e-001"/>
<Con from="5" weight="-1.31185298888846e-001"/>
<Con from="6" weight="-1.00488432758605e-001"/>
</Neuron>
<Neuron id="8" bias="-8.22218767044386e-001">
<Con from="0" weight="6.60554850915838e-001"/>
<Con from="1" weight="5.99689663574631e-001"/>
<Con from="2" weight="-7.30614043895976e-001"/>
<Con from="3" weight="-7.33439817521737e-002"/>
<Con from="4" weight="-3.27656576514078e-001"/>
<Con from="5" weight="-3.45244293468482e-001"/>
<Con from="6" weight="-2.98532771708077e-001"/>
</Neuron>
<Neuron id="9" bias="-8.20585604933031e-002">
<Con from="0" weight="-1.17089032941014e-001"/>
<Con from="1" weight="3.92789687130429e-002"/>
<Con from="2" weight="-3.71519769625043e-001"/>
<Con from="3" weight="3.44219794919891e-001"/>
<Con from="4" weight="-1.60900979289532e-002"/>
<Con from="5" weight="-2.60114025294232e-002"/>
<Con from="6" weight="-1.74377723811055e-002"/>
</Neuron>
<Neuron id="10" bias="5.37450963052761e-001">
<Con from="0" weight="-1.10075701817401e+000"/>
<Con from="1" weight="2.41172315299708e-002"/>
<Con from="2" weight="2.02123288904743e+000"/>
<Con from="3" weight="-1.52191502853124e+000"/>
<Con from="4" weight="2.06231128904104e-001"/>
<Con from="5" weight="2.07921490855013e-001"/>
<Con from="6" weight="1.99652195010873e-001"/>
</Neuron>
<Neuron id="11" bias="-1.61938009150365e-001">
<Con from="0" weight="5.44179200495102e-001"/>
<Con from="1" weight="5.14178247160559e-002"/>
<Con from="2" weight="1.90080419417512e-002"/>
<Con from="3" weight="-2.46454764144338e-001"/>
<Con from="4" weight="-5.25053803661169e-002"/>
<Con from="5" weight="-5.97738496536895e-002"/>
<Con from="6" weight="-5.98946338186080e-002"/>
</Neuron>
<Neuron id="12" bias="-6.72445264766243e-001">
<Con from="0" weight="1.06770247112135e+000"/>
<Con from="1" weight="-1.75307322060729e-002"/>
<Con from="2" weight="1.62916354151216e+000"/>
<Con from="3" weight="-2.38551222195309e+000"/>
<Con from="4" weight="-2.13543647896750e-001"/>
<Con from="5" weight="-2.18223848244507e-001"/>

```

```

<Con from="6" weight="-2.18447858579667e-001"/>
</Neuron>
<Neuron id="13" bias="1.14332014211349e+000">
<Con from="0" weight="-1.02507606431225e+000"/>
<Con from="1" weight="-8.09203015877044e-001"/>
<Con from="2" weight="8.77979643385645e-001"/>
<Con from="3" weight="2.96018788382667e-001"/>
<Con from="4" weight="4.16963265612337e-001"/>
<Con from="5" weight="4.44861982949096e-001"/>
<Con from="6" weight="3.71847697509707e-001"/>
</Neuron>
<Neuron id="14" bias="6.40220011667739e-001">
<Con from="0" weight="-7.53929950723336e-001"/>
<Con from="1" weight="-3.51767241242269e-001"/>
<Con from="2" weight="5.55663458864891e-001"/>
<Con from="3" weight="-4.72615773867437e-003"/>
<Con from="4" weight="2.31656308733967e-001"/>
<Con from="5" weight="2.40749565596759e-001"/>
<Con from="6" weight="2.21877866253656e-001"/>
</Neuron>
<Neuron id="15" bias="-6.28004280277142e-001">
<Con from="0" weight="-2.35996906933767e-001"/>
<Con from="1" weight="-6.25380343016762e+000"/>
<Con from="2" weight="-3.16031183431481e-001"/>
<Con from="3" weight="-3.09406718975533e-001"/>
<Con from="4" weight="-2.37357373531642e-001"/>
<Con from="5" weight="-2.49375789260816e-001"/>
<Con from="6" weight="-2.03552250411251e-001"/>
</Neuron>
<Neuron id="16" bias="-2.59725889512826e+000">
<Con from="0" weight="-3.93669680937344e+000"/>
<Con from="1" weight="2.35913924369868e+000"/>
<Con from="2" weight="-4.63820286174651e-001"/>
<Con from="3" weight="-2.18824264774031e+000"/>
<Con from="4" weight="-1.16303624804377e+000"/>
<Con from="5" weight="-9.06629114989093e-001"/>
<Con from="6" weight="-5.04362069709263e-001"/>
</Neuron>
</NeuralLayer>
<NeuralLayer
er numberOfNeurons="6" activationFunction="identity">
<Neuron id="17" bias="3.13020877340657e-002">
<Con from="7" weight="1.61204260519452e+000"/>
<Con from="8" weight="3.17762142239241e+000"/>
<Con from="9" weight="1.43076049212468e+000"/>
<Con from="10" weight="3.28318001319566e+000"/>
<Con from="11" weight="4.17786038757419e-001"/>
<Con from="12" weight="-2.43849904290802e+000"/>
<Con from="13" weight="3.86963471717367e+000"/>

```

```

<Con from="14" weight="-9.14506167336033e-001"/>
<Con from="15" weight="-3.63945318056831e+000"/>
<Con from="16" weight="2.35385568531889e+000"/>
</Neuron>
<Neuron id="18" bias="-2.44718450948985e-001">
<Con from="7" weight="-2.50569217469187e-001"/>
<Con from="8" weight="-1.59507926940109e-001"/>
<Con from="9" weight="-1.14272632802688e+000"/>
<Con from="10" weight="-2.09628413604121e+000"/>
<Con from="11" weight="8.44783929423553e-001"/>
<Con from="12" weight="1.43305669012454e+000"/>
<Con from="13" weight="-5.80076585521249e-001"/>
<Con from="14" weight="6.89650796084494e-001"/>
<Con from="15" weight="1.65942460781132e-001"/>
<Con from="16" weight="-8.92617538286128e-001"/>
</Neuron>
<Neuron id="19" bias="1.42079672287836e+000">
<Con from="7" weight="-2.52840293074825e-001"/>
<Con from="8" weight="-4.52462276289076e-001"/>
<Con from="9" weight="-1.01830860300840e+000"/>
<Con from="10" weight="-2.90952862581829e-001"/>
<Con from="11" weight="-4.37000841243093e-001"/>
<Con from="12" weight="4.66465418675713e-001"/>
<Con from="13" weight="-1.12378490403273e+000"/>
<Con from="14" weight="4.36768995452657e-001"/>
<Con from="15" weight="3.76356310965753e-001"/>
<Con from="16" weight="5.03206548877414e-001"/>
</Neuron>
<Neuron id="20" bias="1.01811428868874e+000">
<Con from="7" weight="-2.69196637821701e-001"/>
<Con from="8" weight="6.81283546774322e-002"/>
<Con from="9" weight="-1.39891811996286e+000"/>
<Con from="10" weight="-1.64984433545053e-001"/>
<Con from="11" weight="1.19142550106202e-002"/>
<Con from="12" weight="8.55536357498758e-002"/>
<Con from="13" weight="-9.51065616763413e-001"/>
<Con from="14" weight="1.02260572210551e+000"/>
<Con from="15" weight="3.73601736232088e-001"/>
<Con from="16" weight="2.63273438706052e-001"/>
</Neuron>
<Neuron id="21" bias="1.50349124719726e+000">
<Con from="7" weight="-7.02133731124979e-001"/>
<Con from="8" weight="3.91512280542192e+000"/>
<Con from="9" weight="-1.53144229409270e+000"/>
<Con from="10" weight="1.20310581968353e+000"/>
<Con from="11" weight="4.25967262048358e+000"/>
<Con from="12" weight="-2.89309448263122e+000"/>
<Con from="13" weight="4.75873454619322e-001"/>
<Con from="14" weight="5.41187762773184e+000"/>

```

```

<Con from="15" weight="1.90921398778809e+000"/>
<Con from="16" weight="9.30558566225493e-001"/>
</Neuron>
<Neuron id="22" bias="5.97482636921899e-001">
<Con from="7" weight="-1.76678855821188e+000"/>
<Con from="8" weight="-4.19110847719899e+000"/>
<Con from="9" weight="-9.20673374878600e-001"/>
<Con from="10" weight="-2.26474808078772e+000"/>
<Con from="11" weight="-1.73464956939451e+000"/>
<Con from="12" weight="1.83872806659077e+000"/>
<Con from="13" weight="-4.31662520799973e+000"/>
<Con from="14" weight="1.09313618111898e-001"/>
<Con from="15" weight="4.07632086278089e+000"/>
<Con from="16" weight="-2.55506397772286e+000"/>
</Neuron>
</NeuralLayer>
<NeuralOutputs numberOfOutputs="6">
<NeuralOutput outputNeuron="17">
<DerivedField optype="continuous">
<NormContinuous field="masa cementu" shift="-
1,22331047992165e+000" scale="9,79431929480901e-001">
<Linear-
Norm orig="1.24900000000000e+000" norm="0.00000000000000e+0
00"/>
<Linear-
Norm orig="2.27000000000000e+000" norm="1.00000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="18">
<DerivedField optype="continuous">
<NormContinuous field="masa wody" shift="-
1,84883720930233e+000" scale="3,87596899224806e+000">
<LinearNorm orig="4.77000000000000e-
001" norm="0.00000000000000e+000"/>
<LinearNorm orig="7.35000000000000e-
001" norm="1.00000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="19">
<DerivedField optype="continuous">
<NormContinuous field="masa kruszywa frakcji [2-
8mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<Linear-
Norm orig="2.34000000000000e+000" norm="0.00000000000000e+0
00"/>

```

```

<Linear-
Norm orig="2.826000000000000e+000" norm="1.000000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="20">
<DerivedField optype="continuous">
<NormContinuous field="masa kruszywa frakcji [8-
16mm]" shift="-
4,81481481481481e+000" scale="2,05761316872428e+000">
<Linear-
Norm orig="2.340000000000000e+000" norm="0.000000000000000e+0
00"/>
<Linear-
Norm orig="2.826000000000000e+000" norm="1.000000000000000e+0
00"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="21">
<DerivedField optype="continuous">
<NormContinuous field="masa domieszki" shift="-
0,000000000000000e+000" scale="2,12765957446809e+000">
<Linear-
Norm orig="0.000000000000000e+000" norm="0.000000000000000e+0
00"/>
<LinearNorm orig="4.700000000000000e-
001" norm="1.000000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
<NeuralOutput outputNeuron="22">
<DerivedField optype="continuous">
<NormContinuous field="masa mikro- krzemionki" shift="-
0,000000000000000e+000" scale="1,12233445566779e+000">
<Linear-
Norm orig="0.000000000000000e+000" norm="0.000000000000000e+0
00"/>
<LinearNorm orig="8.910000000000000e-
001" norm="1.000000000000000e+000"/>
</NormContinuous>
</DerivedField>
</NeuralOutput>
</NeuralOutputs>
</NeuralNetwork>
</PMML>

```