



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

**RADA NAUKOWA DYSCYPLINY INFORMATYKA
TECHNICZNA I TELEKOMUNIKACJA**

ROZPRAWA DOKTORSKA

mgr inż. Marta Gackowska-Kątek

**Predyktywny model dezorganizacji roju dronów
przy przejściu intruza**

*Predictive model of drone swarm disorganization
upon intruder passage*

DZIEDZINA: NAUK INŻYNIERYJNO-TECHNICZNYCH
DYSCYPLINA: INFORMATYKA TECHNICZNA I
TELEKOMUNIKACJA

PROMOTOR

PROF. DR HAB. INŻ. PIOTR COFTA

POLITECHNIKA BYDGOSKA IM. JANA I JĘDRZEJA
ŚNIADECKICH

Bydgoszcz, 2025 rok

Podziękowania

*Serdeczne podziękowania kieruję do mojego
Promotora prof. dr. hab. inż. Piotra Cofty
za nieoceniony wkład w rozprawę, bezcenne wsparcie merytoryczne,
ekspercką wiedzę oraz inspirujące rozmowy.*

*Dziękuję Dziekanowi Wydziału Telekomunikacji Informatyki
i Elektrotechniki Politechniki Bydgoskiej
dr. inż. Tomaszowi Marciniakowi, prof. PBS
za okazaną życzliwość i motywację do realizacji pracy doktorskiej.*

*Dziękuję **dr. inż. Damianowi Ledzińskiemu**
za przekazaną wiedzę i życzliwość, które były dla mnie nieocenionym
wsparciem na początku naukowej drogi.*

*Szczególne podziękowania składam moim
Rodzicom i najbliższej Rodzinie,
za to, że nieustannie otaczają mnie wsparciem,
dodając odwagi w realizacji moich marzeń i celów.*

*Z głębi serca pragnę podziękować mojemu **Mężowi Gracjanowi,**
za wiarę we mnie oraz wsparcie, które pomaga
mi w osiągnięciu zamierzonych celów.*

SPIS TREŚCI

Streszczenia	7
1. Wstęp.....	9
1.1. Cel i zakres pracy	10
2. Przegląd literatury	12
2.1. Organizacja i dezorganizacja	12
2.2. Aspekty związane z rojami dronów.....	23
3. Model roju – formalizacja problemu badawczego	30
4. Miary	36
4.1. Entropia i entropia krzyżowa.....	36
4.2. Inne miary wykorzystane w niniejszej pracy.....	41
5. Algorytm unikania kolizji	42
6. Symulacja jako metoda uzyskania danych.....	46
6.1. Symulator	46
6.2. Miara w symulatorze	50
6.3. Generowanie zbioru danych – wstępne badania symulacyjne.....	51
6.4. Główny badania symulacyjne – generowanie oraz analiza zbiorów danych.....	59
7. Modele bazowe	67
7.1. Modele bazowe dla pierwszego zbioru danych.....	68
7.2. Modele bazowe dla drugiego zbioru danych.....	73
8. Modele predykcyjne i ich wyjaśnialność	76
8.1. Modele predykcyjne entropii krzyżowej na podstawie pierwszego zbioru danych	78
8.2. Modele predykcyjne stanów dezorganizacji na podstawie pierwszego zbioru danych	93
8.3. Modele predykcyjne na podstawie drugiego zbioru danych (kooperacja).....	109
8.4. Modele predykcyjne stanów dezorganizacji na podstawie drugiego zbioru danych	121

9. Podsumowanie i wnioski.....	131
Bibliografia.....	135
Spis rysunków	149
Spis tabel	153

STRESZCZENIE

Predyktywny model dezorganizacji roju dronów przy przejściu intruza

mgr inż. Marta Gackowska-Kątek

Słowa kluczowe: roje dronów, dezorganizacja, wyjaśnialność modeli predykcyjnych, entropia krzyżowa jako miara

Niniejsza rozprawa doktorska stanowi analizę procesów dezorganizacji w stacjonarnych formacjach rojów dronów pod wpływem zakłóceń, takich jak wtargnięcie intruza, z zastosowaniem modeli predykcyjnych opartych na entropii krzyżowej jako mierze dezorganizacji. Badania koncentrują się na opracowaniu modeli pozwalających na prognozowanie zachowania roju oraz na identyfikacji parametrów kluczowych mających wpływ na dezorganizację. Opracowano model roju w postaci probabilistycznego grafu z przejściami. W oparciu o symulacje wygenerowano dwa zestawy danych, obejmujące scenariusze zakłóceń w postaci drona intruza o zachowaniach kooperatywnych i niekooperatywnych. Modele predykcyjne osiągnęły wysokie wartości współczynnika determinacji, umożliwiając precyzyjne przewidywanie dezorganizacji oraz prawdopodobieństwa wystąpienia określonych stanów systemu. Dodatkowo, wykorzystanie technik wyjaśnialności modeli, takich jak SHAP (SHapley Additive exPlanations), umożliwiło precyzyjne określenie parametrów wpływających na poziom dezorganizacji oraz wystąpienie określonych stanów stabilności. Rezultaty badań mają istotne znaczenie praktyczne, szczególnie w kontekście rozwoju infrastruktury U-Space, wskazując na możliwości wdrożenia mechanizmów zarządzania przestrzenią powietrzną, w tym minimalizacją ryzyka kolizji w złożonych systemach rojowych oraz poprawy bezpieczeństwa i efektywności operacji w przestrzeni powietrznej o wysokim zagęszczeniu ruchu.

ABSTRACT

Predictive model of drone swarm disorganization upon intruder passage

MSc Marta Gackowska-Kątek

Key words: drone swarms, disorganization, explainability of predictive models, cross entropy as a measure

This dissertation is an analysis of disorganization processes in stationary drone swarm formations under the influence of disturbances, such as intrusion of an intruder, using predictive models based on cross entropy as a measure of disorganization. The research focuses on developing models to predict swarm behavior and identifying key parameters affecting disorganization. A swarm model in the form of a probabilistic graph with transitions was developed. Based on the simulations, two data sets were generated, including disruption scenarios in the form of an intruder drone with cooperative and non-cooperative behavior. The predictive models achieved high values of the coefficient of determination, making it possible to accurately predict disorganization and the probability of certain states of the system. In addition, the use of model explanatory techniques, such as SHAP (SHapley Additive exPlanations), made it possible to accurately determine the parameters affecting the level of disorganization and the occurrence of certain stability states. The results of the research are of significant practical importance, especially in the context of the development of U-Space infrastructure, indicating the possibility of implementing airspace management mechanisms, including minimizing the risk of collisions in complex swarm systems and improving the safety and efficiency of operations in high-density airspace.

1. WSTĘP

Współczesne technologie bezzałogowych statków powietrznych, określanych popularnie jako drony, przechodzą aktualnie dynamiczny rozwój, zarówno w kontekście technologii, możliwości ich zastosowania, a także regulacji prawnych [1]. Jednym z najbardziej intrygujących i innowacyjnych zastosowań dronów jest ich organizacja w formacje zwane rojami. W tym kontekście roje dronów są przedmiotem zaawansowanych badań oraz praktycznych wdrożeń w różnych dziedzinach życia – od przemysłu, przez rolnictwo, po działania wojskowe i ratownicze.

Interesującym zagadnieniem są stacjonarne formacje rojów dronów, to znaczy takie, które utrzymują określone pozycje w przestrzeni, tworząc pewnego rodzaju zorganizowaną sieć. Ma to swoje zastosowanie m.in. w celach wymagających stałego monitorowania i nadzoru. Jednym z kluczowych wyzwań w operowaniu rojami dronów jest zagrożenie związane z intruzami, które mogą zaburzyć funkcjonowanie całej formacji poprzez wprowadzenie jej w stan dezorganizacji, a nawet chaosu. Intruzami mogą być inne drony, które w sposób zamierzony lub przypadkowy wchodzą w obszar działania roju. Tego rodzaju zakłócenia mogą mieć poważne konsekwencje, takie jak uszkodzenie jednostek, zakłócenie misji czy nawet spowodowanie niebezpiecznych sytuacji, podczas gdy drony operują w pobliżu infrastruktury krytycznej lub w przestrzeni powietrznej o ograniczonym dostępie.

W tym kontekście kluczowe jest badanie zachowania roju w odpowiedzi na określone zakłócenia oraz zbadanie poziomu dezorganizacji, która potencjalnie może niekorzystnie wpływać na całokształt misji. Istotne jest, że problem intruzów w kontekście rojów dronów jest złożony i wymaga rozbudowanego i wieloaspektowego podejścia, aby skutecznie przeciwdziałać zagrożeniom i minimalizować ryzyko. Ponadto stanowi to wyzwanie w kontekście oddziaływania na rój czy też zarządzania rojem i ryzykiem. W tym kontekście należy również uwzględnić konieczność zastosowania określonych technologii antykolizyjnych oraz doboru parametrów lotu. Zarówno parametry roju, jak i trajektoria intruza mogą wpływać na poziom dezorganizacji. Chociaż zarządzający rojami nie mogą bezpośrednio wpływać na sposób, w jaki intruz zbliża się do roju, to mogą zmieniać parametry samego roju w oczekiwaniu na jego wtargnięcie. W tym celu niezbędne są określone wskazówki i informacje o związkach i zależnościach między różnymi parametrami i oczekiwaną średnią dezorganizacją związaną ze wtargnięciem drona intruza.

1.1. CEL I ZAKRES PRACY

W ramach rozprawy skupiono się na opracowaniu algorytmicznego modelu roju oraz serii predyktywnych modeli reakcji stacjonarnej formacji roju dronów w odpowiedzi na wtargnięcie intruza, uwzględniając zachowania kooperatywne oraz niekooperatywne. Jest to istotne zagadnienie, szczególnie dla zarządzających rojami w kontekście predykcji dezorganizacji sieci dronów oraz minimalizacji ryzyka strat. Przedstawione badania mają także na celu zrozumienie działania roju dronów w odpowiedzi na pojawienie się intruza oraz opracowanie odpowiedniego zestawu praktycznych wskazówek dla zarządzających rojami oraz ich potencjalne wdrożenie w inteligentnych miastach.

Na podstawie przeprowadzonej analizy literatury oraz badań sformułowano następujące tezy badawcze:

- 1) *Dezorganizacja stacjonarnej formacji roju dronów w obliczu zakłóceń jest przewidywalna.*
- 2) *Opracowanie i porównanie serii predyktywnych modeli, opartych na analizie zmian entropii krzyżowej, pozwala na wyłonienie najbardziej skutecznego modelu zdolnego do precyzyjnego przewidywania stanów dezorganizacji w sytuacji wtargnięcia intruza.*
- 3) *Przewidywanie prawdopodobieństwa wystąpienia określonych stanów dezorganizacji pozwala na identyfikację potencjalnych zagrożeń związanych z utrzymaniem formacji.*
- 4) *Analiza wyjaśnialności predyktywnych modeli umożliwia precyzyjną identyfikację parametrów mających bezpośredni wpływ na poziom dezorganizacji.*

Celem pracy jest opracowanie oraz ocena serii modeli predyktywnych, które umożliwią analizę i przewidywanie stopnia dezorganizacji stacjonarnej formacji roju dronów w obliczu zakłóceń, takich jak wtargnięcie intruza. Dezorganizacja będzie analizowana dla zachowań kooperatywnych i niekooperatywnych zarówno w przypadku intruza, jak i roju. Istotnym celem rozprawy jest ponadto przeprowadzenie analizy wyjaśnialności modeli, tak aby uzyskać precyzyjne dane na temat wpływu parametrów na decyzyjność modeli oraz stopień dezorganizacji. Praca umożliwi także identyfikację kluczowych parametrów wpływających na poziom dezorganizacji, co pozwoli na ocenę potencjalnych zagrożeń dla utrzymania formacji oraz na bardziej efektywne zarządzanie ryzykiem w przypadku wtargnięcia intruza.

Warto zauważyć, że mimo szerokiego zakresu tematyki związanej zarówno z formacjami rojów dronów, jak i poziomem zaburzeń w pracy skoncentrowano się na konkretnych aspektach, a zakres rozprawy został

ograniczony do najistotniejszych zagadnień, które bezpośrednio wiążą się z celem badawczym oraz pozwalają na prawidłową weryfikację postawionych tez badawczych. Przede wszystkim w rozumieniu niniejszej pracy entropia krzyżowa jest wykorzystywana jako referencyjna miara dezorganizacji. Dokonano ponadto przeglądu dostępnych algorytmów antykolizyjnych, jednak badaniom został poddany autorski algorytm unikania kolizji. Dodatkowo warto podkreślić, że praca skupia się na stacjonarnej formacji roju bezzałogowych statków powietrznych, którymi w tym przypadku są popularne drony wielowirnikowe.

W kontekście zakresu pracy istotne podkreślenia jest to, że po pierwsze opracowany i przyjęty został model roju w postaci probabilistycznego grafu z przejściami, który wymaga parametryzacji dla każdego analizowanego systemu. Decyzja o jego zastosowaniu wynika z natury systemów multistabilnych, które często nie zachowują się deterministycznie, a ich przejścia między stanami mogą być wywołane losowymi zakłóceniami. Po drugie opracowane modele są modelami algorytmicznymi. Lepiej opisują rzeczywiste procesy zachodzące w złożonych systemach, jednak mają pewne ograniczenia w postaci punktowej predykcji. Zdając sobie sprawę z niniejszych ograniczeń, wprowadzono analizę wyjaśnialności modeli, aby poszerzyć zakres ich stosowalności. Ponadto zastosowano symulację jako metodę generowania danych. Pozwoliło to na powstanie dwóch rzetelnych zbiorów danych, z czego jeden związany jest z zakłóceniami w postaci drona intruza, który nie posiada algorytmu unikania kolizji, a zachowanie takie nazywane jest niekooperatywnym. Z kolei drugi ze zbiorów dotyczy zachowań kooperatywnych, gdzie intruz posiada również wdrożony algorytm unikania kolizji. Pozwala to na weryfikację zachowania tego samego systemu pod wpływem różnych zakłóceń. Modele predykcyjne zostały opracowane na podstawie tych danych.

Rozprawa zorganizowana jest w następujący sposób: w rozdziale 1 przedstawiono tezy, cel oraz zakres pracy. W rozdziale 2 dokonano przeglądu literatury związanego z organizacją, dezorganizacją, a także aspektami związanymi z rojami dronów. W rozdziale 3 zaprezentowane zostały dokładne ramy badawcze niniejszej pracy oraz przedstawiony model roju. W rozdziale 4 omówiono wykorzystywane w pracy miary. Rozdział 5 przedstawia omówienie autorskiego algorytmu unikania kolizji. W rozdziale 6 omówiono zagadnienia związane z symulacją jako metodą uzyskania danych. W kolejnym 7 rozdziale opracowano modele bazowe, tak aby uzyskać punkt odniesienia do dalszych badań mających na celu opracowanie modeli predykcyjnych, co przedstawiono w rozdziale 8. Z kolei rozdział 9 zawiera podsumowanie i wnioski.

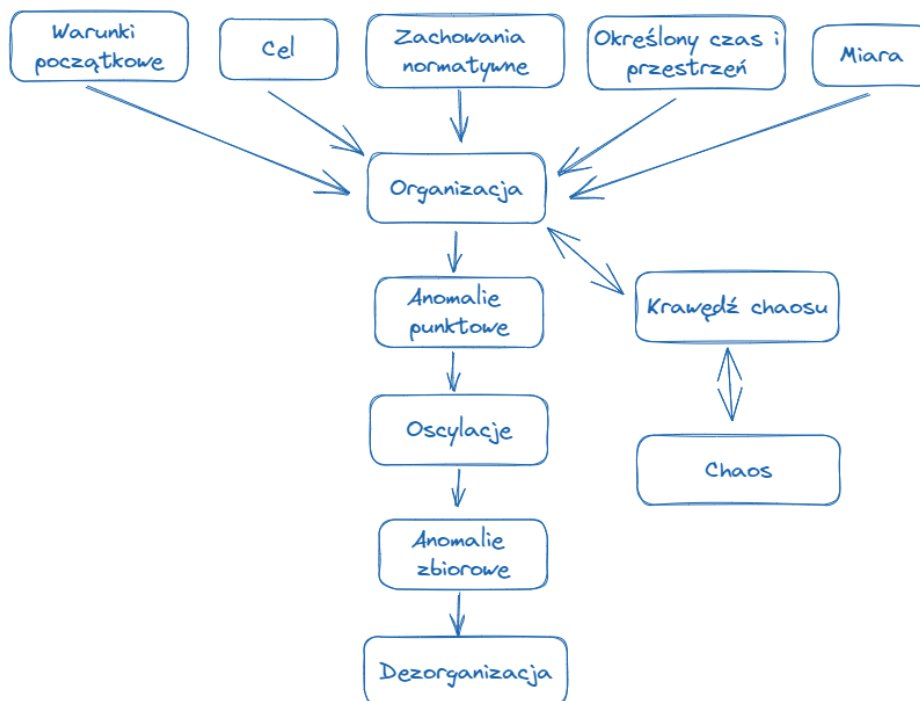
2. PRZEGLĄD LITERATURY

2.1. ORGANIZACJA I DEZORGANIZACJA

W niniejszej pracy badawczej podjęto tematykę systemu cyberfizycznego, jakim jest rój bezzałogowych statków powietrznych. Problematyka organizacji i dezorganizacji w takich systemach, choć kluczowa z punktu widzenia technologii, ma charakter interdyscyplinarny. W związku z tym przegląd literatury został celowo rozszerzony poza tradycyjne ramy techniczne, obejmując również podejścia i teorie z innych dziedzin naukowych. Taki szeroki kontekst badawczy umożliwia pełniejsze zrozumienie złożoności procesów organizacyjnych w systemach rojowych.

Przedmiot rozważań w tym rozdziale obejmuje koncepcyjne przedstawienie zagadnień związanych z zależnościami pomiędzy organizacją, a dezorganizacją. Omówiono także podstawowe pojęcia związane z organizacją oraz samoorganizacją na różnych płaszczyznach nauki. Ponadto w niniejszej sekcji przedstawiono różne formy dezorganizacji, w tym chaos i brak koordynacji działań, oraz ich wpływ na funkcjonowanie systemu. Powyższe zagadnienia omówiono w kontekście systemów, składających się z wielu elementów.

Na rysunku 1 przedstawiono schemat organizacji oraz dezorganizacji, który stanowi punkt odniesienia do dalszych analiz. Przede wszystkim na wstępie należy podkreślić, że organizacja może stopniowo przekształcać się w dezorganizację poprzez występowanie następujących po sobie: anomalii punktowych, oscylacji i ostatecznie anomalii zbiorowych. Pojęcie oscylacji oznacza tutaj jednoczesne zaburzenia wielu elementów systemu, które przez dłuższy czas wykazują odchylenia od normy, jednak nie destabilizują całkowicie systemu. Z kolei krawędź chaosu to występowanie układu na granicy pomiędzy ładem a chaosem. Chaos to specyficzny rodzaj dezorganizacji, gdzie niewielkie zmiany w układzie skutkują nieprzewidywalnymi efektami.



Rysunek 1. Koncepcyjny schemat organizacji i dezorganizacji [opracowanie własne]

W pracy organizacja jest definiowana jako stan systemu, którego struktura i funkcjonowanie są ściśle podporządkowane określonemu celowi oraz zaaranżowane na potrzeby realizacji misji. Kluczowe jest, że organizacja może być postrzegana nie tylko jako obiekt techniczny, ale również jako konstrukcja społeczna – zależna od perspektywy i oceny obserwatora. Z perspektywy obserwatora organizacja ujawnia zachowania zbiorowe, w których można dostrzec analogie do ludzkich i społecznych interakcji. Sugeruje to, że organizacje, podobnie jak jednostki, mogą przejawiać pewną formę intencji czy celów zbiorowych. Porównując organizację roju dronów do struktury społeczeństwa, należy podkreślić, że taka analogia służy lepszemu zrozumieniu zjawiska, a nie jest jedynie narzuconym modelem. Struktura systemu zarówno w przypadku roju dronów, jak i społeczeństwa kształtuje się zgodnie z wyznaczonym celem.

Według (podstawowej) definicji pochodzącej ze Słownika Języka Polskiego dezorganizacja to „brak organizacji, porządku lub dyscypliny w czymś” [2]. Należy zauważyć, że jest to nieskomplikowana definicja,

aczkolwiek stanowiąca punkt wyjścia do dalszej eksploracji problemu w zakresie dezorganizacji w systemach.

Dezorganizację można zdefiniować jako różnicę pomiędzy stanem idealnym organizacji, reprezentowanym przez jej cel, a stanem aktualnym. Ponadto organizacja podlega zaburzeniom, które mogą mieć charakter wewnętrzny lub zewnętrzny. Te pierwsze mogą mieć swoje źródło nie tylko bezpośrednio z wnętrza systemu, ale również mogą pochodzić ze źródeł zewnętrznych i przenosić się do jego wnętrza. Z kolei bezpośrednio zewnętrzne zaburzenia stanowią zagrożenie dla systemu, wymagając od niego zdolności obronnej.

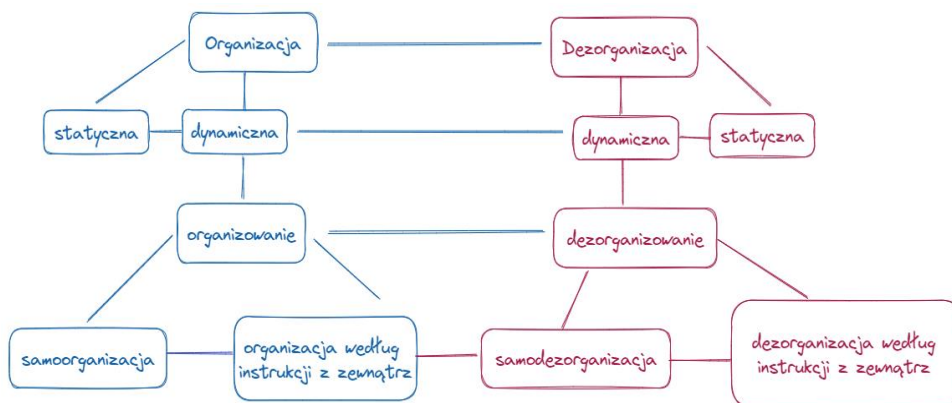
Analiza literatury wykazała, że dezorganizacja jako szeroko pojęte zaburzenia występuje w różnych dziedzinach nauki, w tym m.in. w naukach biologicznych. Przykładowo tematem poruszonym w pracy [3] są zakłócenia, różnorodność i stabilność ekosystemów. Autorzy wskazali, że zakłócenie w ekosystemach to każde stosunkowo dyskretne zdarzenie w czasie, które zakłóca strukturę ekosystemu, społeczności lub populacji i zmienia zasoby, dostępność substratu lub środowisko fizyczne. Kolejnym przykładem jest praca Norberta Weinera [4], fundamentalna pozycja, która przyczyniła się do rozwoju cybernetyki. W kontekście niniejszych rozważań zjawiska opisywane w pracy pomagają zrozumieć, że organizacja to nie tylko uporządkowanie elementów systemu, ale także zdolność do adaptacji i reagowania na zmieniające się warunki. Dezorganizacja natomiast to proces utraty tych zdolności, co prowadzi do chaosu i destabilizacji systemów. Wiener wprowadza także koncepcję sprzężenia zwrotnego, które jest podstawowym mechanizmem regulacji w cybernetyce. Sprzężenie zwrotne pozwala systemom na samokontrolę poprzez korygowanie odchylenia od zamierzonego stanu. Jest to z punktu widzenia organizacji i dezorganizacji istotne zagadnienie.

Zagadnienia dotyczące organizacji i dezorganizacji są również szeroko poruszane w naukach społecznych, gdzie znaczącą rolę odgrywa m.in. teoria Luhmanna, zwana też teorią systemów [5]. Luhmann argumentuje, że systemy społeczne są zawsze w stanie ciągłych zmian, z potencjałem zarówno do organizacji, jak i dezorganizacji. Organizacja odnosi się do stabilnych wzorców komunikacji i interakcji w ramach systemu społecznego, które pozwalają zachować jego tożsamość i kontynuować funkcjonowanie w czasie. Z drugiej strony dezorganizacja odnosi się do załamania tych wzorców komunikacji i interakcji, co może prowadzić do chaosu i niestabilności w systemie. Ostatecznie teoria Luhmanna sugeruje, że zarówno organizacja, jak i dezorganizacja są niezbędne do dalszego rozwoju i ewolucji systemów społecznych. Podczas

gdy organizacja zapewnia stabilność i ciągłość, dezorganizacja umożliwia innowacje i zmiany, co prowadzi do pojawienia się nowych wzorców komunikacji i interakcji. W tym miejscu należy podkreślić, że dezorganizacja nie zawsze jest wyłącznie negatywnym zjawiskiem. Problem pojawia się jednak, gdy dezorganizacja staje się nadmierna. Wówczas może to prowadzić do chaosu, utraty kontroli i niezdolności do efektywnego działania. Właśnie w tym momencie chaos staje się destruktywny, zakłócając nie tylko procesy, ale również osiągnięcie celów.

Pojęcie dezorganizacji nie jest również obce środowisku biznesowemu i zarządzaniu zasobami. Według autorów [6] organizacja (firma) mogłaby stać się wysoce elastyczna i szybko reagować na zmiany, jeśli przyjęłaby podejście aktywnego i dynamicznego przyjmowania dezorganizacji. Pozwoliłoby to na zwiększenie zdolności instytucji do radzenia sobie w nieprzewidywalnym środowisku i z elementami zewnętrznymi oddziałującymi na nie.

Nad zagadnieniem organizacji i dezorganizacji szeroko pochyłono się w artykule [7], a przedstawione w nim zależności schematycznie przedstawiono na rysunku 2. Według powyższych autorów pojęcia organizacja i dezorganizacja związane są ze stanami struktury systemu, z kolei organizowanie i dezorganizowanie dotyczą procesu doprowadzającego do poszczególnych stanów. Autorzy w tym zakresie wyróżniają statyczną organizację, gdzie stabilność systemu sprowadza się do uporządkowanej struktury sieci, oraz organizację dynamiczną, którą można uogólnić do dynamicznego porządku, gdzie występuje ogólny tryb uporządkowania, a elementy systemu wymieniają się pomiędzy sobą. Oprócz samoorganizacji autorzy wskazali również na aspekt organizowania i dezorganizowania układu/systemu według instrukcji pochodzących z zewnątrz. Sprowadza się to do założenia, że układ zaczyna się organizować w momencie, kiedy czynnik zewnętrzny wyda odpowiednie instrukcje postępowania.



Rysunek 2. Podział dezorganizacji i organizacji na podstawie [7]

Organizowanie można rozważać w aspekcie koordynacji. W [8] koordynacja jest rozpatrywana jako cykl składający się z czterech faz: „Faza definicyjna, faza rozwiązywania konfliktów, faza działania i faza adaptacji”. Jak opisano w [9], koordynacja to porządek przestrzenny i czasowy, również odnoszący do różnych rodzajów i stopni funkcjonalnego porządku między oddziałującymi elementami systemu i procesami w przestrzeni i czasie. Na podstawie szczegółowego przeglądu przedstawionego w [10] koordynację można podzielić na statyczną i dynamiczną. Statyczna cechuje się przyjęciem pewnych zasad przed podjęciem się wykonania określonego zadania. Z kolei dynamiczna określa w sposób jawny bądź niejawnym sposób analizy i syntezy informacji w trakcie wykonywania zadań, a do uzyskiwania informacji może dochodzić za pośrednictwem środowiska.

Dezorganizacja to również występowanie anomalii. Anomalie to wzorce w danych lub zachowaniu, które nie są zgodne z dobrze zdefiniowanym pojęciem normalnego i oczekiwanego zachowania [11]. Ponadto w pracy [11] wyróżniono następujące typy anomalii:

- anomalie punktowe
- anomalie kontekstowe
- anomalie zbiorowe

Anomalie punktowe są jednymi z najczęściej występujących. Mowa jest o nich wtedy, gdy pojedyncza próbka danych jest nietypowa i nienormalna w kontekście pozostałych próbek. Anomalie zbiorowe występują wtedy, gdy powiązane ze sobą elementy w odniesieniu do całego zbioru danych są nietypowe, nieprawidłowe lub też posiadają odstające wartości. Istnieją prace, w których wykorzystuje się teorię

grafów do modelowania systemów rojowych komunikacji oraz interakcji, które zachodzą pomiędzy elementami systemu. W tym kontekście rozważa się również występowanie anomalii, które dezorganizują strukturę grafu. W podejściu przedstawionym w [12] wykrywano anomalie punktowe w systemie rojowym, identyfikując wartości odstające, potencjalnie dezorganizacyjne poprzez zastosowanie grafowej transformaty Fouriera (GFT-ang. Graph Fourier Transform).

Podgrupą organizowania jest samoorganizacja. Wiele gatunków zwierząt, takich jak: mrówki [13], pszczoły [14], ryby [15] wykazuje zdolność do samoorganizacji, co pozwala im na skuteczne przystosowanie się do zmiennych warunków środowiskowych i przetrwanie w trudnych warunkach, a także na przeżycie. Samoorganizacja jest dla nich jednym z podstawowych mechanizmów, który umożliwia zachowanie się w sposób zorganizowany i koordynowany, bez centralnego zarządzania [16].

Bazowa definicja systemu samoorganizującego się została po raz pierwszy wprowadzona w pracy [17], gdzie posłużyła do opisanie zjawisk, w których lokalne interakcje między niezależnymi elementami prowadziły do globalnych zachowań lub wzorców. Z kolei właściwością często używaną do scharakteryzowania samoorganizacji jest wzrost porządku układu, który nie jest determinowany czynnikami zewnętrznymi, w tym interakcjami środowiskowymi [18]. Wzrost porządku układu formalizuje się najczęściej za pośrednictwem entropii i negentropii, co szczegółowo omówione zostanie w rozdziale 5. Autorzy w pracy [6] zwracają uwagę na fakt, że zarówno w matematycznych, jak i fizycznych modelach systemów samoorganizujących się to obserwator przypisuje właściwości, aspekty, stany i prawdopodobieństwa, a organizacja to nie tylko m.in. niska entropia, ale przede wszystkim struktura, która ma funkcję lub cel. W zależności od rozważanych aspektów elementy systemu mogą się samoorganizować lub samodezorganizować.

Jak podkreślają autorzy pracy [19], istotne jest, aby zidentyfikować mechanizmy, które leżą u podstaw samoorganizacji i zdefiniować ich wpływ na organizację systemu. Mechanizmy te odnoszą się do wzorców zachowań, modalności interakcji pomiędzy elementami systemu, zdolności do wzmacniania bądź tłumienia informacji, oczywiście również kluczową rolę ma tu obserwator. Dodatkowo interakcje w kontekście samoorganizacji czy koordynacji to według założeń przedstawionych w [20] wszelkiego rodzaju mechanizmy, które pozwalają niektórym jednostkom organizować i wpływać na działania innych.

Jak wskazano w [21], w systemach informacyjno-komunikacyjnych głównym zagrożeniem jest niezdolność systemu do radzenia sobie z intruzami i nieoczekiwanymi zdarzeniami losowymi. W związku z tym identyfikacja sposobów reakcji na powyższe ingerencje powinna być zaprogramowana w odpowiedni sposób, tak aby zapewnić możliwie jak największe bezpieczeństwo systemu. Na podstawie teorii Luhmanna [22] wyróżniono 3 główne grupy zagrożeń na podstawie efektów ich oddziaływań:

- a. efekty chaosu
- b. efekty interferencyjne
- c. jednorazowe przypadki

Efekty chaosu zdefiniowane są jako lokalnie występujące, o niewielkim charakterze incydenty, które wywołują nieprzewidywalne efekty łańcuchowe rozprzestrzeniające się na cały system. Przykładem takiego efektu mogą być incydenty w systemach nawigacji lotniczej.

Efekty interferencyjne według autorów dotyczą trudnych do przewidzenia skutków, które mogą być wywołane przez człowieka. Natomiast po ich wystąpieniu, na ich podstawie można opracować metodykę postępowania w analogicznych sytuacjach, podlegają one więc nauce. Oczywiście biorąc pod uwagę system jako całość, można wysnuć przesłanki do poszerzenia powyższej definicji o skutki wywołane przez ingerencję środowiska zewnętrznego. Dla systemów informatycznych czy technologicznych może to być nadmiar przesyłanych informacji, rozprzestrzenianie się wirusów.

Z kolei wymienione w punkcie c jednorazowe przypadki mają charakter wyjątkowy i przypadkowy, przez co nie będą podlegały efektom uznawanym za interferencyjne.

Istotną kwestią zarówno w organizacji, jak i w organizowaniu jest przepływ informacji. Zgodnie z teorią Lindy [23], [24] elementy systemu zwane agentami we współdzielonej przestrzeni danych pozostawiają informacje w postaci krotek oraz mogą uzyskiwać dostęp do krotek pozostawionych przez inne elementy i dopasowywać się do wzorców. W przypadku samoorganizacji można wywnioskować, że komunikacja pomiędzy elementami odbywa się nieoczekiwanie, a komunikaty nie są skierowane bezpośrednio do konkretnego odbiorcy. Z drugiej strony według autorów [20] przepływ informacji może być wykonywany na zasadzie „dyfuzji”, gdzie dane są rozpowszechniane do dużej liczby agentów, co przypomina komunikację rozgłoszeniową.

Wartymi uwagi w kontekście organizacji są zagadnienia związane z teorią chaosu oraz zjawiskiem polegającym na występowaniu układu na

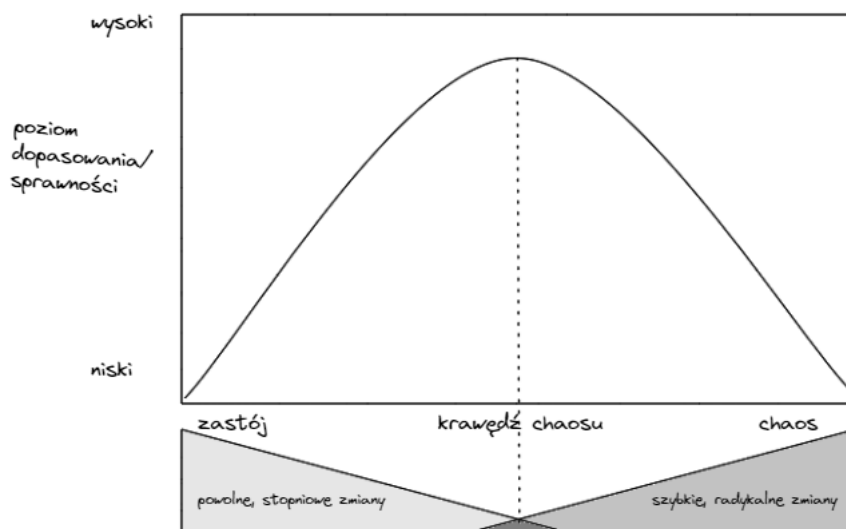
krawędzi chaosu. W powyższych przypadkach może dojść do znacznego zakłócenia działalności i organizacji systemów. Oczywiście nie należy równoważyć chaosu jedynie z przypadkowymi zachowaniami, które znacząco zaburzają system, ale również czynią to w sposób nieprzewidywalny. Warto nadmienić, iż chaos może występować zarówno w układach dyskretnych, jak i ciągłych. Zgodnie z powszechnie wykorzystywaną definicją [25] chaos dotyczy zachowania systemów deterministycznych, przy braku wpływu stochastycznego, a ich reakcja jest bardzo wrażliwa na niewielkie zmiany warunków początkowych, powodując duże, ale ograniczone różnice w wyniku [26]. Systemy i układy chaotyczne są znane w wielu gałęziach nauki, w tym w elektronice, gdzie najbardziej popularny jest obwód Chua–Matsumoto [27], uznany za paradygmat chaosu [28]. Z kolei teoria chaosu dotyczy dynamicznych systemów nieliniowych, a oprócz zachowań chaotycznych skupia się nad wszelkimi zachowaniami systemów nieliniowych [29].

W symulowanym środowisku, aby postawić hipotezę, iż system jest chaotyczny, należy kilkakrotnie wykonać symulacje z nieznacznie różniącymi się warunkami początkowymi. Jeśli ostatecznie występują znaczące rozbieżności pomiędzy wynikami końcowymi, można domniemać, że system jest chaotyczny [30]. W pracy [31] skupiono się na detekcji chaosu w bezzałogowych statkach powietrznych znajdujących się w roju bezzałogowych statków powietrznych. Na podstawie danych dotyczących położenia dronów oraz prędkości – pochodzących z sensorów i zaplanowanej trajektorii identyfikowano 4 stany układu: norma, chaos, niepewny chaos, niepewna norma. Gdy czas powrotu drona na pozycję przekraczał 85 sekund, wówczas formacja nie spełniała początkowych założeń, funkcjonowała w sposób nieprawidłowy i pojawiał się chaos.

Należy mieć na uwadze, że teoria chaosu nie zawsze jest wykorzystywana jedynie do definiowania i analizy zjawisk niepożądanych. Naukowcy wykorzystują ją również do ulepszania i modyfikacji istniejących algorytmów. W [32] teoria chaosu znajduje swoje zastosowanie w celu zmniejszenia ryzyka uwięzienia w lokalnych problemach optymalnych i poprawienia zróżnicowania populacji w algorytmie EO (ang. Equilibrium Optimizer (EO)), z kolei w [33] teoria chaosu została wykorzystana do przewidywania szeregów czasowych przepływu ruchu zmotoryzowanego w sieci transportu miejskiego.

Ciekawym zagadnieniem w kontekście dezorganizacji jest zjawisko występowania układu na krawędzi chaosu. Jest to sytuacja, w której jak opisano w [34], system znajduje się pomiędzy skrajnymi stanami ładu i chaosu, gdzie sprawność/dopasowanie jest zmaksymalizowane.

Dodatkowo, jak schematycznie przedstawiono na rysunku 3, krawędź chaosu to sytuacja, gdzie istnieje niewielka granica pomiędzy powolnymi i stopniowymi zmianami, a szybkimi i radykalnymi, które mogą przejść w chaos. Jak zauważano w [35], wiele systemów przechodzi fazowe przejście między porządkiem a nieporządkiem, między stabilnością a chaosem.



Rysunek 3. Schemat krawędzi chaosu na podstawie McKinsey [36]

Należy mieć na uwadze, że znajdowanie się na krawędzi chaosu nie oznacza tylko dążenia do umiarkowanego poziomu zmian. Już pierwsze prace dotyczące tego zagadnienia dowodzą, że system dynamiczny ma największą moc obliczeniową, znajdując się właśnie na krawędzi chaosu [37]. Wynika to z faktu, że system na granicy przejścia fazowego pomiędzy ładem a chaosem wykazuje najbardziej złożone zachowanie dla dowolnego zakresu parametrów, a tym samym posiada największą zdolność obliczeniową. Z kolei w pracy [38] wieloagentowy model ewolucji ruchu został celowo wprowadzony w fazę krawędzi chaosu ze względu na zwiększenie efektywności systemu i skrócenia czasu podróży agentów. Ponadto obserwuje się dla powyższego systemu, że zarówno zbyt mała, jak i zbyt duża intensywność interakcji niekorzystnie wpływa na efektywność.

W celu określenia sytuacji, w której układ bądź system znajduje się na krawędzi chaosu, wykorzystuje się wykładnik Lapunowa. Jest to matematyczne określenie odległości oraz szybkości separacji pomiędzy dwiema początkowymi trajektoriami układu dynamicznego [39]. Metoda

ta znajduje zastosowanie nie tylko w analizie stabilnych i niestabilnych układów, ale także w badaniu anomalii, gdzie wykładnik Lapunowa umożliwia identyfikację subtelnych przejść w dynamice systemu. Dodatni wykładnik Lapunowa oznacza, że układ jest wrażliwy na warunki początkowe, a zatem znajduje się w reżimie chaotycznym. Natomiast jeśli wartość wykładnika przyjmuje wartości mniejsze od zera, wskazuje to na fakt, iż system jest stabilny lub uporządkowany. Dodatkowo autorzy w [40] zaproponowali pojęcie krawędzi stabilności jako nowej odmiany krawędzi chaosu, gdzie wykładnik Lapunowa staje się dodatni.

Ciekawym zagadnieniem z punktu widzenia krawędzi chaosu jest metastabilność systemów. Pojęcie to jest szczególnie rozważane w kontekście fizyki, chemii, biologii, ale także neurologii [41]. Najprostsza definicja metastabilności mówi o przesunięciach i przejściach pomiędzy stanami stabilnymi. Z kolei, kiedy mamy do czynienia z krawędzią chaosu, możemy spodziewać się sytuacji, w której układ ze stabilnej fazy powolnych stopniowych zmian, przejdzie w fazę chaosu – gwałtownych i nieoczekiwanych zmian. W przypadku metastabilności dla układu, który w swojej naturze posiada przemiany fazowe, obserwuje się sytuację, podczas której układ zamiast przechodzić przemianę fazową, pozostaje dłuższy czas w sytuacji stabilnej, do czasu aż czynnik zewnętrzny nie zapoczątkuje nowej fazy, dążącej do prawdziwego stanu równowagi [42]. Układ stosunkowo szybko osiąga pozorną równowagę, zanim osiągnie stabilność – równowagę stochastyczną z pozoru w nieprzewidywalny sposób [43]. Obserwator systemu w fazie metastabilnej mierząc dane zmienne, zaobserwuje, iż system zaczyna przyjmować wartości bliskie oczekiwanym w pewnym rozkładzie prawdopodobieństwa na konfiguracjach systemu [44].

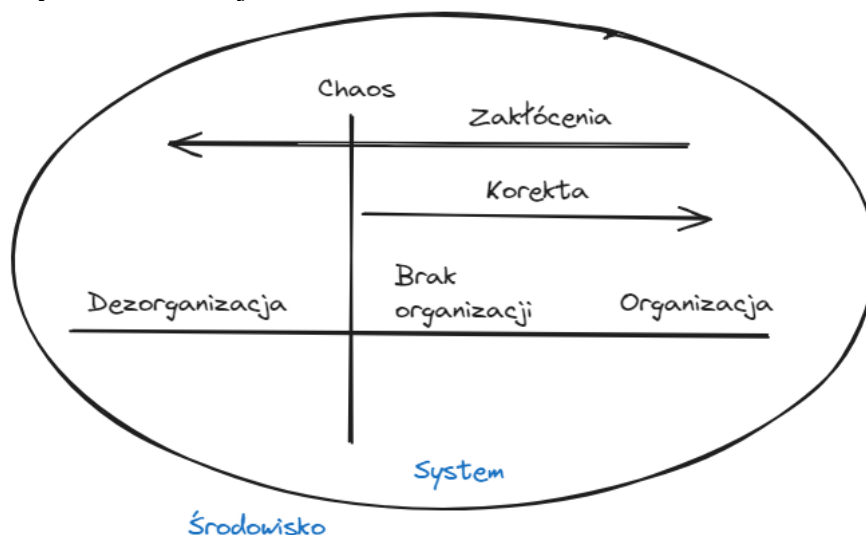
W kontekście dynamiki systemów należy również poruszyć zagadnienie systemów multistabilnych. Definiuje się je jako układy dynamiczne, które mogą przyjmować więcej niż jeden stabilny stan równowagi w zależności od warunków początkowych i parametrów systemu. Zjawisko multistabilności występuje w niemal wszystkich dziedzinach nauki i przyrody [45]. Liczne badania wykazały, że układy multistabilne są bardzo wrażliwe na warunki początkowe [46] oraz losowy szum czy inne zaburzenia [47]. Ponadto zachowanie systemów multistabilnych może gwałtownie zmienić się nawet przy niewielkich zmianach ich parametrów.

Powyższy przegląd literatury pozwala na sformułowanie definicji organizacji i dezorganizacji, którą można przyjąć za adekwatną również do zagadnień związanych z formacjami rojów, których dotyczy niniejsza

rozprawa. Nie ulega wątpliwości, że organizacja to występowanie ładu i uporządkowania, to także zachowanie pewnej stabilności i równowagi.

Układ bądź system wykazuje cechy organizacji, kiedy zgodnie z określonymi warunkami początkowymi oraz zdefiniowanym celem osiąga wyniki końcowe, adekwatne z pewnym wzorcem zachowań, a dokładniej – z zachowaniami normatywnymi w określonym czasie i przestrzeni. Dodatkowo istotne jest, aby obserwator układu posiadał wiedzę dotyczącą sposobu i standardów określania zachowań normatywnych. Ponadto, kiedy mowa o organizacji systemów cyberfizycznych, kluczowe jest, aby oprogramowanie umożliwiało detekcję i klasyfikację zachowań poprawnych oraz anomalii, a także posiadało metody reakcji na nieprawidłowości. System może z fazy organizacji przejść w fazę dezorganizacji. W tym kontekście istotne jest przyjęcie określonych miar, za pomocą których identyfikowane będą zachowania anomalne, o czym mowa w rozdziale 4.

Przyczynami dezorganizacji mogą być: zaburzony przepływ informacji i niepoprawna lub zaburzona komunikacja pomiędzy elementami systemu, czynniki zewnętrzne wpływające na system w sposób destrukcyjny, brak powrotu do układu do pierwotnego stabilnego stanu po wystąpieniu sytuacji zaburzających układ, następujące po sobie w sposób kaskadowy zaburzenia. W układzie mogą wystąpić anomalie punktowe, dotyczące pojedynczych elementów systemu, które mogą, ale nie muszą przekształcić się w anomalie zbiorowe, wpływające niekorzystnie na układ jako całość.



Rysunek 4. Schematyczne przedstawienie zachowania systemu [opracowanie własne]

Na podstawie przedstawionej analizy sformułowano poniższe wnioski, a uzyskane informacje podsumowujące zobrazowano na rysunku 4. Zgodnie z formalizacją problemu badawczego w rozdziale 3 system istnieje w określonym środowisku, a w odpowiedzi na pojawienie się zakłóceń mogą wystąpić zmiany w zakresie jego organizacji oraz stanów stabilności. Powstałe zakłócenia są przyczyną przejścia układu ze stanu organizacji do stanu dezorganizacji i są one odwracalne, poprzez pewną korektę stanu. Należy natomiast mieć na uwadze, że im większe zakłócenia nie są korygowane, tym bardziej powodują, że układ nie wraca do stanu organizacji. Przyczynia się to do wystąpienia dezorganizacji, a także chaosu, który jest nieodwracalną formą dezorganizacji.

2.2. ASPEKTY ZWIĄZANE Z ROJAMI DRONÓW

Na wstępie niniejszego rozdziału zdefiniowano niezbędne pojęcia w celu precyzyjnego sformułowania zakresu i kontekstu omawianych zagadnień związanych z dronami i rojami dronów. Następnie omówione zostaną technologie antykolizyjne oraz możliwości zastosowania stacjonowanych formacji roju dronów.

Dron to ogólna definicja odnosząca się zarówno do bezzałogowych statków powietrznych, bezzałogowych statków naziemnych, a także bezzałogowych statków pływających. Ponadto dron to taki obiekt, który może wykonywać misje bez obecności pilota na pokładzie [48]. Na potrzeby niniejszej rozprawy pojęcie dron i bezzałogowy statek powietrzny będą wykorzystywane zamiennie i stosowane w odniesieniu do popularnego wielowirnikowca, to znaczy obiektu pionowego startu i lądowania, który wyposażony jest w wiele silników zapewniających ciąg śmigieł [49].

Pojęcie roju zostało zaczerpnięte ze świata zwierząt. Obserwacje zachowania grupowych pszczół [50], szarańczy [51], ptaków czy ryb [52], [53], [54], [55] były inspiracją do powstania wielu algorytmów, w tym tych związanych z kooperacją, przydziałem, a także wykonywaniem zadań. Pozwoliły również na analizę inteligencji roju i wdrożenia tego pojęcia do świata techniki. Rój robotów według pracy [56] to „grupa co najmniej trzech robotów, które wykonują zadania wspólnie, otrzymując ograniczoną kontrolę od operatorów lub nie mając jej wcale”. Dodatkowo warto do tej definicji dodać, iż drony w roju poruszają się w określonej przestrzeni, wchodzą ze sobą w interakcje, dążą do ściśle określonego celu, a także unikają kolizji. Ostatecznie rój dronów można zaliczyć do systemów cyberfizycznych [57].

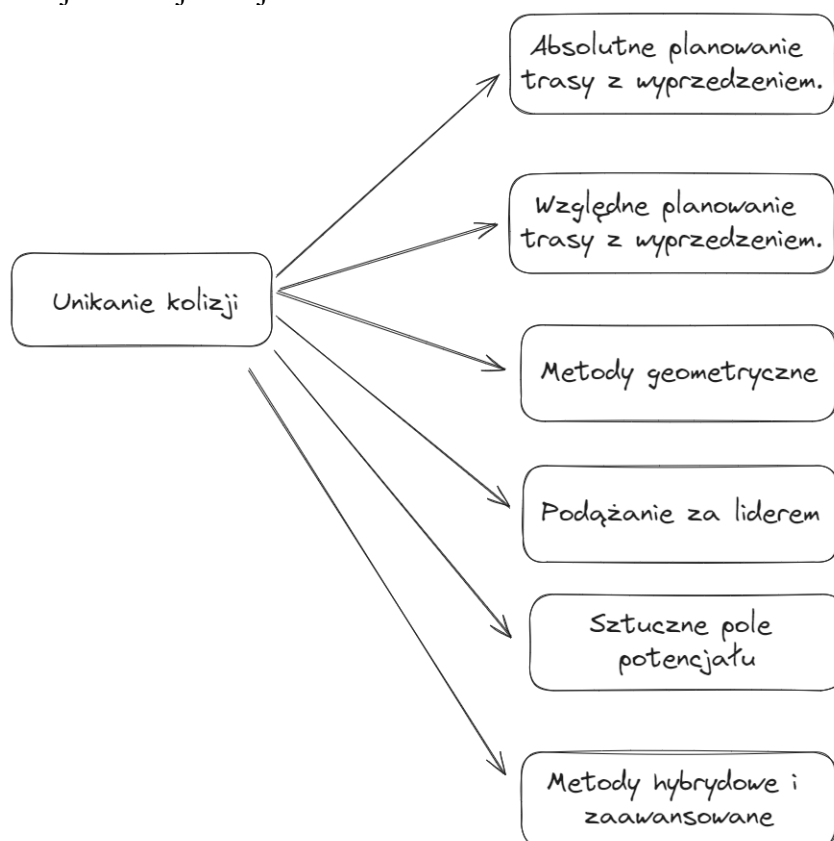
Zarówno drony, jak i roje mogą wykonywać misje. Misja przebiega w dowolnym czasie, w którym drony w roju poruszają się z pewną prędkością do określonego celu, wykonując pożądaną trajektorię w możliwie optymalny i bezpieczny sposób. Misja może być wykonywana automatycznie, półautomatycznie lub autonomicznie. O misji automatycznej mówi się wtedy, gdy trajektoria zostaje wykonana bez użycia algorytmów unikania kolizji oraz ignorowania przeszkód. Z kolei półautomatyczność i autonomiczność obejmują metody, które umożliwiają dronom podejmowanie decyzji na podstawie analizy otrzymanych danych oraz reakcje na sytuacje nieprzewidziane wraz z generowaniem nowych trajektorii lotu w przypadku wystąpienia sytuacji kryzysowych i awaryjnych [58]. W związku z tym, że loty półautomatyczne oraz autonomiczne odgrywają coraz większe znaczenie, istotne jest spełnienie wielu wymagań w celu zapewnienia rozwoju bezpiecznych technologii [59].

Istnieje szereg wymagań i zagrożeń związanych z niezawodnością takiego systemu [60]. Rój dronów powinien cechować się przede wszystkim: odpornością na zakłócenia i zmiany środowiskowe; elastycznością oraz skalowalnością [61]. W celu spełnienia powyższych wymagań należy wdrożyć technologie antykolizyjne. Z reguły można wyróżnić w tym zakresie trzy główne elementy: wykrywanie przeszkód, przewidywanie kolizji oraz ich unikanie [62].

W zakresie analizy technologii antykolizyjnych identyfikuje się dwie główne grupy systemów: współpracujące oraz niewspółpracujące [63]. W ramach systemów współpracujących, czyli kooperatywnych, składające się z wielu elementów systemy bezzałogowych statków powietrznych wzajemnie współdziałają i wymieniają informacje w czasie rzeczywistym. Szczególnie istotna w tym zakresie jest wymiana informacji zarówno pomiędzy dronami, jak i między dronami a infrastrukturą naziemną. W kontekście wykrywania przeszkód przez systemy współpracujące elementy tego systemu, jak np. drony, powinny informować otoczenie o m.in. swojej pozycji, prędkości, kierunku lotu, co ostatecznie będzie prowadziło do analizy i prognozowania ruchu powietrznego i do skoordynowanych działań w celu przewidywania i uniknięcia kolizji.

W przypadku systemów niewspółpracujących wykrywanie przeszkód opiera się na analizie otoczenia [64]. Wówczas na pokładzie bezzałogowego statku powietrznego muszą znajdować się sensory. Główny podział obejmuje czujniki pasywne i aktywne [65]. Czujniki pasywne wykorzystują naturalne źródła promieniowania, rejestrując

emitowane lub odbijane fale, co umożliwia identyfikację obiektów na podstawie ich charakterystyk termicznych lub wizualnych. Z kolei czujniki aktywne, takie jak LIDAR, RADAR, SONAR, emitują promieniowanie, a następnie odczytują promieniowanie odbite od otaczających obiektów w celu określenia ich lokalizacji. Unikanie kolizji w tym zakresie występuje zgodnie z zasadą „sense and avoid” [66], czyli rozpoznaj i uniknij kolizji.



Rysunek 5. Główne grupy metod unikania kolizji

Unikanie kolizji jest jednym z głównych komponentów przytoczonych technologii antykolizyjnych. Na rysunku 5 przedstawiono podział głównych grup metod unikania kolizji, opracowany na podstawie analizy literatury w tym zakresie. W zależności od zastosowanych algorytmów i metod wykorzystywanych w zakresie antykolizyjności można wyodrębnić następujące grupy: absolutne planowanie trasy z wyprzedzeniem, względne planowanie trasy z wyprzedzeniem, metody

geometryczne, podążanie za liderem, sztuczne pole potencjału oraz metody hybrydowe i zaawansowane.

Absolutne planowanie trasy z wyprzedzeniem to jedna z najbardziej podstawowych metod. Polega na odgórnym zaplanowaniu misji bezzałogowych statków powietrznych w taki sposób, aby drony podczas lotu omijały przeszkody statyczne, a także siebie nawzajem. W pracach [67] [68] skupiono się na opracowaniu metod koordynacji torów lotu w oparciu o scentralizowane zarządzanie przy użyciu określonych punktów orientacyjnych. Z kolei w artykule [69] autorzy predefiniują wzorce lotu, a nie konkretne ścieżki, w wyniku czego drony określają swoje położenie, bazując na punktach odniesienia.

Względne planowanie trasy z wyprzedzeniem stanowi ulepszenie opisywanej powyżej metody planowania bezwzględnego. Metoda ta wymaga współpracy pomiędzy dronami w roju w zakresie wymiany w zadanych okresach komunikatów o swojej pozycji, prędkości i numerze identyfikacyjnym, aby zachować określoną kolejność [70]. W pracy [71] lokalna współpraca pomiędzy dronami w roju była podstawową metodą unikania kolizji. Została ona zrealizowana na podstawie komunikacji typu peer-to-peer pomiędzy dronami w roju. Ponadto za pośrednictwem komunikacji klient-serwer drony miały możliwość otrzymania optymalnej konfiguracji lotu.

Wykorzystanie metod geometrycznych bazuje na wyznaczonych geometrycznych zależnościach pomiędzy dronami w roju lub pomiędzy przeszkodami statycznymi oraz dynamicznymi. W jednej z prac wykorzystano wektor odległości drona od danego punktu kolizyjnego, na podstawie którego dokonywano oceny kolizji [72]. W pracy [73] przedstawiono algorytm unikania kolizji, na który składały się strefy graniczne przeszkody, kąty błędu śledzenia, a kontrola prędkości została uzyskana metodą Lapunowa na podstawie wymienionych danych. Znane są też prace, gdzie bada się różne typy stref kolizyjnych, np. strefę prostopadłościenną, elipsoidalną czy cylindryczną [74].

Ciekawym rozwiązaniem w zakresie unikania kolizji jest strategia podążania za liderem, która stanowi alternatywę dla planowania ścieżki dla całego roju. Metoda ta opiera się na zaplanowaniu trajektorii wyłącznie dla lidera roju, natomiast celem pozostałych dronów jest podążanie za nim. W pracy [75] wykazano, że topologia takiej formacji może być utrzymana poprzez zachowanie stałej odległości i określonego kąta pomiędzy każdym dronem a liderem. Z kolei w pracy [76] każdy z elementów systemu mógł być jednocześnie liderem i naśladowcą, a kształt formacji odwzorowywał kształty formacji, jakie przybierają ptaki w locie.

Podejście to pozwalało na pewne formy unikania kolizji pod warunkiem, że przeszkody były statyczne i lider mógł je wykryć.

Im większa autonomia rojów dronów, tym bardziej znaczące jest zastosowanie algorytmów unikania kolizji. Istotna jest świadomość dronów na temat ich lokalizacji, kierunku i prędkości lotu, ocena możliwości wystąpienia przeszkód. Warto, aby drony odbierały i rozgłaszały wymienione powyżej parametry, tak aby możliwe było podejmowanie przez nie autonomicznych decyzji co do unikania przeszkód.

Kolejnym podejściem jest metoda sztucznego pola potencjału [77], która w podstawowej wersji polega na odzwierciedleniu zachowania pomiędzy cząstkami naładowanymi, generującymi pole elektryczne lub magnetyczne, indukujące siły odpychania i przyciągania. Występują również pewne modyfikacje tej metody. Jedną z nich jest opracowana w pracy [78] koncepcja sztucznego pola potencjału o dowolnym kształcie. W tym przypadku siła odpychająca pomiędzy agentami powoduje ich równomierne rozłożenie tak, aby nie kolidowały ze sobą. Z kolei siła przyciągania powoduje, że elementy roju nie opuszczają granic pola. Pewne konfiguracje mogą powodować znaczące wzrosty złożoności obliczeniowej, w związku z tym w pracy [79] opracowano podejście, w którym obliczane są jedynie lokalne aspekty pola potencjału po wcześniejszym podziale na partycje Woronoja.

Następną dużą gałąź unikania kolizji stanowią metody hybrydowe o wyższym stopniu zaawansowania, które łączą metody koordynacji wraz z mechanizmami unikania kolizji również pomiędzy dronami w roju. Odgrywa to coraz większe znaczenie w kontekście zwiększającej się autonomii roju. W pracy [80] zaprezentowano hybrydową metodę obejmującą podejście lider-podążający oraz sztuczne pole potencjału. W podejściu tym unikanie kolizji bazowało na wymianie komunikatów pomiędzy dronami, dotyczących ich lokalizacji, przez co możliwe było zapewnienie bezpieczniejszej odległości pomiędzy nimi. Ponadto sztuczne pole potencjału pozwalało na opracowanie siatki 3D wraz z punktami, które stanowiły miejsca kolizyjne. Dodatkowo połączenie map cyfrowych oraz lokalizacji dynamicznych przeszkód umożliwiło wzbogacenie siatki o wszelkie punkty kolizyjne, co ostatecznie doprowadziło do efektywnego wdrożenia unikania kolizji. Z kolei autorzy w [81] zaproponowali strategię koordynowania rojów dronów wraz z unikaniem kolizji i dążeniem do określonego celu w oparciu o 3 mechanizmy: stygmergię, kolektywne zachowania stadne oraz algorytmy ewolucyjne. W pracy [82] zaprezentowano zaawansowany algorytm flokowania do koordynacji

rojów dronów wraz z unikaniem kolizji, w którym parametry optymalizowano za pomocą algorytmu ewolucyjnego. Aby utrzymać bezpieczną odległość przy dużej prędkości i jednocześnie zminimalizować opóźnienia zastosowano sztuczne odpychanie.

Jakkolwiek drony kojarzą się głównie z przemieszczaniem się, jednym z ważnych obszarów ich zastosowań są sytuacje, gdy powinny one pozostawać w stałej formacji, np. na potrzeby monitorowania terenu, dokonywania pomiarów lub przechwytywania rakiet. W takiej sytuacji celem każdego drona w roju jest utrzymanie się w wyznaczonej lokalizacji. Podejście to jest niezbędne podczas realizacji przez roje specjalistycznych misji, które w pracy [83] obejmowały ustalanie pozycji intruza podczas patrolu granicznego. Z kolei autorzy w [84] opracowali system roju dronów, który gromadzi informacje o natężeniu ruchu w inteligentnym mieście, a każdy z dronów wymienia się określonymi informacjami i decyduje o kolejnych obszarach do patrolu. W pracy [85] opracowano metodę rozmieszczania roju dronów, które pełniły funkcję bezprzewodowych stacji bazowych. Kolejnym przykładem, gdzie utrzymywanie formacji jest kluczowe, jest FANET, gdzie bezzałogowe statki powietrzne stanowią węzły bezprzewodowej sieci ad-hoc [86]. W ostatnich latach obserwuje się znaczący rozwój koncepcji IoE (ang. Internet of Everything), w skład której wchodzi również IoD (ang. Internet of Drones). Koncepcja Internetu dronów wykazuje zastosowanie w specjalistycznych misjach takich jak nadzór miast, misje wojskowe czy bezprzewodowe sieci czujników [87]. W koncepcji IoD drony w roju powinny współpracować ze sobą w sposób skoordynowany, wymieniać informacje, a także utrzymywać bezpieczne trajektorie i wykonywać zadane misje [88]. Zdecydowana większość z tych misji wymaga utrzymania stacjonarnej formacji.

Podsumowując, technologie antykolizyjne są niezbędne do zapewnienia odporności rojom bezzałogowych statków powietrznych realizujących specjalistyczne misje. Zagadnienie to można rozważać na różnych poziomach złożoności oraz zarządzania i koordynacji. Warto jednak zauważyć, że badania w tej dziedzinie koncentrują się głównie na algorytmach antykolizyjnych oraz optymalizacji tras lotu, podczas gdy procesy dezorganizacji i reorganizacji rojów pozostają stosunkowo słabo zbadane. W tym zakresie zauważalna jest istotna luka badawcza, a przeprowadzone w niniejszej pracy badania wypełniają ją, oferując zrozumienie mechanizmów prowadzących do destabilizacji oraz ponownej organizacji struktur rojów, co jest kluczowe dla opracowania bardziej efektywnych systemów zarządzania i koordynacji. Z perspektywy

konceptji U-Space, która zakłada bezpieczną integrację ruchu załogowego i bezzałogowego w złożonym środowisku powietrznym, analiza tych procesów ma kluczowe znaczenie. Efektywne zarządzanie dynamicznymi zmianami w strukturze i zachowaniu rojów jest niezbędne do zapewnienia bezpiecznej i efektywnej współpracy między różnymi typami uczestników ruchu powietrznego. Ponadto, szczególną uwagę warto poświęcić badaniu stacjonarnych formacji rojów dronów, których celem jest realizacja zadań takich jak obserwacja, monitoring czy długoterminowe zbieranie danych w określonym obszarze. Te formacje mogą odgrywać istotną rolę w zastosowaniach cywilnych i wojskowych, jednocześnie wnosząc dodatkowe wyzwania w zakresie stabilności i koordynacji.

3. MODEL ROJU – FORMALIZACJA PROBLEMU BADAWCZEGO

Rozprawę rozpoczęto od opracowania modelu systemu z określonymi parametrami w kontekście roju bezzałogowych statków powietrznych w obliczu zakłóceń w postaci dronów określanych mianem intruzów. Opracowany model jest niezbędny do badania zależności pomiędzy zachowaniem zbliżonych systemów oraz do analizy wpływu zakłóceń na ich stabilność. Pozwoli on również na eksplorację, w jaki sposób można manipulować parametrami, aby kontrolować dynamikę systemu, co jest szczególnie istotne w kontekście systemów chaotycznych lub znajdujących się na skraju chaosu. W literaturze naukowej istnieją modele, które opisują zachowania zbiorowe organizmów, systemów wieloagentowych czy algorytmów optymalizacyjnych. Niemniej jednak, nie istnieje model, który w sposób kompleksowy badałby zarówno proces dezorganizacji, jak i organizacji roju dronów. Opracowane w ramach rozprawy rozwiązanie stanowi pierwszy tego typu model, który wprowadza znaczące udoskonalenia w stosunku do istniejących podejść oraz wyznacza nowy kierunek badań.

Modelem tym jest probabilistyczny graf przejść z wagami, który wymaga parametryzacji dla każdego analizowanego systemu. Graf ten opisuje możliwe przejścia między stanami systemu. Decyzja o zastosowaniu grafu probabilistycznego wynika z natury systemów multi-stabilnych, które często nie zachowują się deterministycznie, a ich przejścia między stanami mogą być wywołane losowymi zakłóceniami. Ponadto model algorytmiczny lepiej opisuje rzeczywiste procesy zachodzące w systemach złożonych.

Aby model rzetelnie odzwierciedlał zachodzące zmiany stanów, konieczne jest określenie metod parametryzacji dla różnej dokładności modelu przy tym samym zakresie parametrów. W tym celu wykorzystano symulacje, które umożliwiają wyznaczenie wartości parametrów grafu dla grupy systemów i zakłóceń. W odróżnieniu od podejść teoretycznych symulacja pozwala na elastyczne badanie szerokiego zakresu scenariuszy, co jest kluczowe dla systemów złożonych.

Mając zdefiniowane metody parametryzacji, możemy przejść do realizacji algorytmów, które pozwolą na wyznaczenie pozostałych parametrów modelu dla różnych poziomów dokładności. Algorytmiczne metody parametryzacji mają jednak swoje ograniczenia – oferują wyniki dla określonych punktów parametrycznych. Aby zrozumieć wpływ

zmiany parametrów na cały system, konieczne jest zastosowanie dodatkowych metod analitycznych, które pozwolą na eksplorację szerszego zakresu dynamiki systemu, szczególnie w kontekście systemów znajdujących się na skraju chaosu.

W analizowanym przypadku rozważamy rodzinę systemów $S = \{s_1, \dots, s_n\}$, która może być potencjalnie nieskończona. Istnieje funkcja $param(s \in S) \rightarrow \mathbb{R}^n$ zwracająca zestaw parametrów danego systemu. Każdy system w rodzinie systemów S ma tę samą liczbę n parametrów. Z kolei systemy te są rozróżnialne wyłącznie na podstawie ich parametrów. Oznacza to, że dwa systemy o identycznych wartościach parametrów są uznawane za jeden i ten sam system. W odniesieniu do niniejszej pracy każdy system reprezentuje rój z określonymi parametrami.

Ponadto istnieje potencjalnie nieskończona przestrzeń obserwowanych stanów systemu $X_i = \{x_1, \dots\}$, taka, iż system $s_i \in S$ jest zawsze w jednym ze stanów $x \in X_i$. W kontekście tej pracy stan systemu to pozycje oraz wektory: misji \vec{p}_m , ucieczki \vec{p}_u oraz wektor \vec{p}_z wszystkich dronów. Warto nadmienić, że przestrzeń jest inna dla każdego systemu.

Każdy z opisywanych wyżej systemów istnieje w identycznym środowisku E , które zakłóca pracę systemu poprzez wysyłanie zakłóceń ze zbioru $D = \{d_1, \dots, d_{|D|}\}$. W rozumieniu niniejszej dysertacji zakłócenia te są definiowane jako intruzi, którzy oddziałują na systemy, wpływając na ich stany, modyfikując je. Każdy system z rodziny S może reagować na zakłócenia w różny sposób w zależności od swoich parametrów, co czyni analizowany model bogatym w różnorodność dynamicznych interakcji pomiędzy systemami a środowiskiem zakłócającym. Omawiamy system $s_i \in S$ jest multistabilny. Dla każdego systemu możliwe jest określenie zbioru jego punktów stabilności $Y_i \subset X_i$.

W typowych warunkach system znajdujący się w punkcie stabilności w wyniku zakłócenia opuszcza ten punkt, a następnie porusza się określoną trajektorią, dążąc do ponownego osiągnięcia tego samego punktu stabilności. W pewnych przypadkach trajektoria ruchu może jednak doprowadzić system do innego stanu stabilności. W kontekście omawianego roju wyróżnia się cztery punkty stabilności: normalne przejście, wibracje, oscylacje oraz kolizje.

Trajektorie określa się wzorem (1):

$$T_{s_j, Y_j, d_k} = \{t_i = [x_1, x_2, \dots, x_{m-1}, x_m; x \in X, x_1 \in Y_j, x_m \in Y_j]; \quad (1) \\ i = 1..n\}$$

Dla każdego systemu $s_i \in S$ istnieje zbiór $Z_i \subseteq Y_i$ punktów stabilności w których system jest w stanie zorganizowania. Jeżeli system znajduje się w jakimkolwiek innym punkcie $x \in X$, jest on uznawany za dezorganizowany nawet jeżeli jest to punkt stabilności. Jeżeli system jest w stanie zorganizowania, to realizuje on pewne użyteczne cele.

Istnieje metryka $H(x_1, x_2 \in X) \rightarrow \mathbb{R}$ określona dla przestrzeni X , tak iż jest możliwe określenie odległości pomiędzy stanem systemu a dowolnym punktem w X . W szczególności możliwe jest określenie odległości od punktów w Z . Odległość ta jest miarą dezorganizacji systemu. W rozumieniu niniejszej pracy miarą dezorganizacji systemu jest entropia krzyżowa.

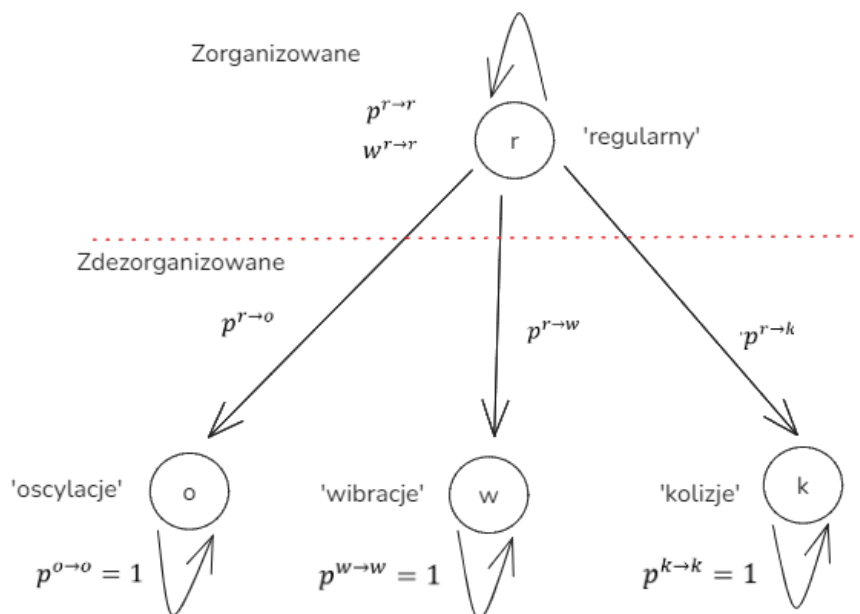
Wysilek W określony równaniem (2) związany z dezorganizacją przy przebyciu trajektorii t może być wyznaczony jako suma dezorganizacji wszystkich stanów należących do t zgodnie z metryką E .

$$W(t) = \sum_{i=1}^m \Delta(x_i), \quad (2)$$

gdzie $\Delta(x_i) = H(x_i, z_i)$

$\Delta(x_i)$ określa odległość pomiędzy stanem systemu a punktem stabilności.

Opracowany model M jest modelem algorytmicznym zrealizowanym jako probabilistyczny graf przejść (rysunek 6) wraz z określonymi parametrami.



Rysunek 6. Probabilistyczny graf przejść

W rozumieniu niniejszej pracy model M roju jest zatem określany jako system s_i z rodziny systemów S , posiadający następujące parametry. System s_i istnieje w środowisku E , które zakłóca pracę systemu poprzez wysyłanie zakłóceń ze zbioru D . Zakłócenia to intruzi, którzy powodują zmianę stanów stabilnych systemu. W systemie wyróżnia się cztery stany stabilne, w tym jeden stan organizacji określany jako regularny oraz trzy stany dezorganizacji – wibracje, kolizje i oscylacje. W systemie określa się prawdopodobieństwa przejść między stanami: $p^{r \rightarrow r}, p^{r \rightarrow w}, p^{r \rightarrow o}, p^{r \rightarrow k}$. Prawdopodobieństwa te określają szanse, że system przejdzie z jednego stanu do innego lub pozostanie w tym samym stanie. Waga przejścia $w^{r \rightarrow r}$ to oczekiwany wysiłek wymagany do przejścia ze stanu regularnego do tego samego stanu, czyli pozostania w stanie organizacji. Wagę przejścia można interpretować jako trudność w utrzymaniu systemu w stanie organizacji w obliczu zakłóceń. Oczekiwany wysiłek dla opisywanej sytuacji można przedstawić równaniem 3:

$$M = (s_i \in S' \subseteq S, D' \subseteq D, r \in Z, v, o, c \in Y; p^{r \rightarrow r}, p^{r \rightarrow w}, p^{r \rightarrow o}, p^{r \rightarrow k}, w^{r \rightarrow r}) \quad (3)$$

Ponadto istnieje funkcja określona wzorem 4, która określa prawdopodobieństwa przejść między stanami w systemie oraz oczekiwany

wysiłek wymagany do przejścia ze stanu regularnego do tego samego stanu.

$$f(S' \subseteq S, D' \subseteq D) \rightarrow (p^{r \rightarrow r}, p^{r \rightarrow w}, p^{r \rightarrow o}, p^{r \rightarrow k}, w^{r \rightarrow r}) \quad (4)$$

Funkcja przyjmuje dwa podzbiory, S' i D' , jako dane wejściowe, gdzie S' jest podzbiorem S (system), a D' jest podzbiorem D (zakłócenia).

Wynikiem powyższej funkcji jest pięć wartości:

$p^{r \rightarrow r}$ - prawdopodobieństwo, że system pozostanie w stanie regularnym,

$p^{r \rightarrow w}$ - prawdopodobieństwo, że system przejdzie ze stanu regularnego do wibracji,

$p^{r \rightarrow o}$ - prawdopodobieństwo, że system przejdzie ze stanu regularnego do stanu oscylacji,

$p^{r \rightarrow k}$ - prawdopodobieństwo, że system przejdzie ze stanu regularnego kolizji,

$w^{r \rightarrow r}$ - oczekiwany trudność w utrzymaniu systemu w stanie organizacji i pozostania w stanie regularnego.

Biorąc pod uwagę dynamikę systemu S , przestrzeń obserwowalnych stanów x i parametrów, a także obecność zakłóceń D możliwe do obserwacji są zjawiska takie jak występowanie systemu na krawędzi chaosu lub zachowania chaotyczne. Uwzględniając powyższe, model analityczny jest trudno osiągalny, z kolei model algorytmiczny pozwala na uzyskanie wyników punktowych. W związku z tym w pracy stosowana jest wyjaśnialność modeli.

Systemy, zakłócenia i trajektorie są zbliżone do siebie, jeżeli odległość ich parametrów nie przekracza ustalonej wartości zgodnie z naturalną metryką w \mathbb{R} . W przeciwnym wypadku są one istotnie różne od siebie.

W rozumieniu niniejszej pracy zachowania chaotyczne identyfikuje się w następujących sytuacjach:

Jeżeli system s_1 oraz zbliżony do niego system s_2 dla takiego samego zakłócenia d_1 realizują znacząco inne trajektorie t_1 oraz t_2 , a wysiłek $W(t_1)$ oraz $W(t_2)$ są znacząco różne.

Jeżeli system s_1 dla zakłócenia d_1 oraz zbliżonego do niego zakłócenia d_2 realizuje znacząco inne trajektorie t_1 oraz t_2 , a wysiłek $W(t_1)$ oraz $W(t_2)$ są znacząco różne.

W systemach będących przedmiotem rozprawy występują opisywane zachowania chaotyczne, stąd też opracowany model algorytmiczny, który pomimo że daje wyniki punktowe, jest lepszy niż zastosowanie modelu analitycznego. Ponadto w późniejszym etapie pracy wykorzystywana jest

wyjaśnialność, która pomaga w zrozumieniu decyzji podejmowanych przez modele uczenia maszynowego na podstawie opracowanego modelu.

4. MIARY

4.1. ENTROPIA I ENTROPIA KRZYŻOWA

W poprzednim rozdziale podkreślono, że istnieje potrzeba, aby wskazać miarę, za pośrednictwem której byłaby możliwa ocena stanu organizacji/ dezorganizacji układu bądź systemu. Niniejszy rozdział przybliży zagadnienia związane z entropią jako miarą niepewności i dezorganizowania oraz entropią krzyżową jako miarą dezorganizacji względem stanu idealnego (organizacji). Przede wszystkim należy mieć na uwadze, że na potrzeby pracy entropia będzie rozpatrywana jako referencyjna miara potencjalnie adekwatna do oceny stanu formacji roju dronów, a także poziomu dezorganizacji tego układu.

Pojęcie entropii ma swoje korzenie w dziedzinie fizyki i jest ściśle związane z termodynamiką [89]. Początkowo Rudolf Clausius dowiódł, że entropia to miara nieuporządkowania lub losowości w układach termodynamicznych. Zauważył również, że podczas przekształceń energetycznych w układach termodynamicznych energia ma tendencję do rozpraszania się i równomiernego dystrybuowania. Określił to jako wzrost entropii, który jest związany z nieodwracalnością procesów termodynamicznych [36]. Pojęcie entropii zostało wykorzystane również do zdefiniowania stanu energetycznego układu, w tym jako funkcja ilości mikrostanów w danym makroście systemu [90].

W kolejnych latach pojęcie entropii ewoluowało i znalazło zastosowanie w różnych dziedzinach nauki, takich jak: teoria informacji, teoria probabilistyczna i statystyka czy mechanika płynów. Wykazano również, że entropia jest zróżnicowanym parametrem reprezentowanym przez niejednorodne komponenty, w tym np. statyczne i dynamiczne, zewnętrzne i wewnętrzne, subiektywne i obiektywne [91].

Entropia Gibbsa [92] jest związana z fizyką statystyczną i termodynamiką. Wprowadzona przez J. Willarda Gibbsa opisuje stopień nieuporządkowania systemu fizycznego i jest funkcją mikroskopowych stanów systemu. W kontekście fizyki entropia Gibbsa opisuje ilość nieuporządkowania na poziomie molekularnym i atomowym w zamkniętym układzie.

Na szczególną uwagę zasługuje praca Claude'a Shannona „A Mathematical Theory of Communication” [93], w której wprowadzone zostało pojęcie entropii w kontekście teorii informacji, określane również jako entropia Shannona. Można ją interpretować jako minimalną średnią liczbę bitów potrzebną do zakodowania każdego

symbolu ze źródła danych. Wówczas entropia jest obliczana na podstawie prawdopodobieństwa wystąpienia różnych symboli w danym źródle informacji. Im większe prawdopodobieństwo wystąpienia danego symbolu, tym mniejsza entropia, a tym samym mniejsza informacyjna zawartość tego symbolu. Z drugiej strony im mniejsze prawdopodobieństwo wystąpienia symbolu, tym większa entropia i większa informacyjna zawartość tego symbolu. W literaturze [94] definiuje się entropię jako miarę określającą poziom informacji o systemie i jednocześnie miarę „wielkości chaosu”. Zgodnie z tym założeniem im większą posiada się informację o systemie, tym entropia jest mniejsza. Różnice między entropią Shannona, entropią Gibbsa wynikają głównie z kontekstu, w którym są używane. Shannon skupił się na informacyjnej zawartości, Gibbsa interesował poziom nieuporządkowania fizycznego.

Entropię Shannona można wykorzystać jako miarę informacji pozwalającą na ocenę niepewności lub złożoności na podstawie rozkładu prawdopodobieństwa, co w literaturze jest także nazywane miarą probabilistycznego nieporządku zbioru X [95]. Zakładając, że dany jest zbiór wartości $X = \{x_1, x_2 \dots x_n\}$, dla $n \in N$, równanie 5 przedstawia wzór na entropię dla dyskretnego rozkładu prawdopodobieństwa.

$$H(p) = - \sum_{x \in X} p(x) \times \log(p(x)) \quad (5)$$

W przypadku ciągłych rozkładów prawdopodobieństwa, ciągłe rozszerzenie entropii Shannona [96] można przedstawić poniższym równaniem 6.

$$H(P) = - \int_{x \in X} P(X) \times \log P(X) dx \quad (6)$$

gdzie $P(x)$ jest gęstością ciągłej zmiennej losowej X .

W pracy [97] autorzy, omawiając entropię w systemach, wskazali, że jest ona miarą stopnia organizacji i przypadkowości systemu. Zwrócili uwagę również na fakt, że we wszystkich systemach naturalnych występuje podatność do wzrostu entropii, natomiast kiedy systemowi narzucany jest sztuczny porządek, entropia maleje.

Warto odnieść się do pracy [98], w której przytacza się badania von Neumanna w zakresie definicji porządku w nawiązaniu do teorii informacji. Wskazuje ona, że im większa ilość informacji jest wymagana do opisanego danego systemu, tym mniejszy jest w nim porządek. Jeśli nieskończona liczba punktów na płaszczyźnie jest rozmieszczona losowo, to do opisanego ich położenia wymagana jest nieskończona ilość informacji.

Z kolei wybitny fizyk Richard Feynman w jednej ze swoich prac [99] wskazał, że porządek jest związany z posiadaniem szczegółowych informacji na temat mikrostanu systemu, a entropia w tym ujęciu jest tym większa, im mniej informacji posiadamy.

Entropia jako miara jest szeroko wykorzystywana w interdyscyplinarnych zagadnieniach. Przykładowo w medycynie może być używana do analizy EEG, gdzie służy jako miara przewidywalności przyszłych wartości amplitudy EEG na podstawie rozkładu prawdopodobieństwa wartości amplitud zaobserwowanych w sygnale [100]. Z kolei w systemach biologicznych uznawana jest jako wskaźnik i miara różnorodności oraz efektywnej liczby gatunków [101], a także określa trwałość i stan gleby, które wiążą się z zasadą minimalnej produkcji entropii [102].

W pracy [103] badano samoorganizację przemysłowych systemów gospodarczych na tle gwałtownych zmian w systemach gospodarczych. Autorzy wykorzystali tu entropię jako miarę uporządkowania systemu. Według przeprowadzonych przez nich obliczeń wzrost uporządkowania cechuje spadek entropii. Warto podkreślić, że jak wykazano w [104], przybliżona entropia (ang. *approximate entropy*) jest właściwą miarą do oceny złożonych systemów, charakteryzujących się co najmniej 1000 wartościami danych, dotyczących zarówno procesów stochastycznych, jak i deterministycznych chaotycznych.

W pracy [105] autorzy skoncentrowali swoje badania na zagadnieniu wykorzystania entropii jako miary zmian, zależności złożoności i dezorganizacji kodu źródłowego. Pod uwagę wzięto cztery główne czynniki wpływające na zmiany entropii w czasie powstawania kodu źródłowego. Wykazano między innymi, że pliki zmieniane przez większą liczbę programistów wykazują wyższą entropię zmian, a entropia maleje, gdy kod zostanie poddany procesowi refraktoryzacji.

Istnieją prace, w których badacze wykazali związek pomiędzy entropią w ujęciu termodynamicznym a entropią w teorii informacji [89]. Na podstawie analizy fizycznego ujęcia entropii Boltzmann'a oraz entropii związanej z teorią informacji również autorzy w pracy [106] wykazali, że koncepcja entropii wdrożona do zagadnień związanych z systemami rojów bezałogowych statków powietrznych może dostarczyć ilościowych i analitycznych danych oraz wskazówek do projektowania i doboru parametrów dla nich. Powyższe badania skupiały się również na zagadnieniach organizacji roju i związanych z nią zależności. W tym przypadku wykazano, że koordynacja związana jest ze spadkiem entropii na poziomie makro przy jednoczesnym zwiększaniu entropii na poziomie

mikro, gdzie za makro uważa się zachowanie dronów dążących do samoorganizacji, a mikro to łączenie się feromonów, czyli śladów obecności dronów na danej pozycji.

Jak wskazano we wstępie publikacji [107], pojęcie entropii pomimo różnic w definicji dla wielu dziedzin nauki może być względną miarą poziomu strukturalizacji układu. Daje to przesłanki również do tego, aby entropię wykorzystać jako miarę dezorganizacji i organizacji w systemach rojowych.

Istotnym rozszerzeniem entropii jest entropia krzyżowa, którą zdefiniowano jako miarę rozbieżności między dwoma rozkładami prawdopodobieństwa [108], w tym pomiędzy oczekiwanym rozkładem prawdopodobieństwa q , a rzeczywistym p . Warto nadmienić, że entropia krzyżowa może być interpretowana jako różnica pomiędzy stanem oczekiwanym a stanem zastanym, co idealnie wpisuje się również w przedstawioną w rozdziale definicję dezorganizacji systemu. Zakładając, że dany jest zbiór wartości $X = \{x_1, x_2 \dots x_n\}$, dla $n \in N$ równanie 7 przedstawia wzór na cross – entropię dla zmiennych x o dyskretnym rozkładzie prawdopodobieństwa.

$$H(p, q) = - \sum_{x \in X} p(x) \times \log(q(x)) \quad (7)$$

Równanie 8 przedstawia wzór na entropię krzyżową, gdzie oba rozkłady prawdopodobieństwa P i Q są funkcjami ciągłymi w domenie X .

$$H(p, q) = - \int_{x \in X} P(x) \log Q(x) dx(x) \quad (8)$$

Entropia krzyżowa oprócz teorii informacji znajduje szerokie zastosowanie w zagadnieniach optymalizacyjnych i statystyce, a także w uczeniu maszynowym. Entropia krzyżowa może być również wykorzystywana jako metryka stanowiąca uzupełnienie predyktywnego modelu oceny występowania defektów w kodach źródłowych oprogramowania [109] lub też jako miara ilościowego określenia naturalności kodu (przyjęto, że kod z błędami jest mniej naturalny niż kod wolny od błędów) [110].

W uczeniu maszynowym entropię krzyżową oraz jej zmodyfikowane warianty stosuje się również jako funkcję straty. Funkcja straty oblicza karę za jakiegokolwiek odchylenie między etykietą docelową a wynikami sieci neuronowej. Wykazano, że w przypadku zbioru uczącego danych niezbalansowanych entropia krzyżowa jako funkcja straty w sieciach

neuronowych MLP wykazuje dobre rezultaty [111]. Ponadto ulepszone w oparciu o entropię krzyżową funkcje straty zapobiegają nadmiernemu dopasowaniu do próbek w klasach większościowych [112], zwiększają dokładność rozpoznawania klas mniejszościowych [113] lub w przypadku danych charakteryzujących się występowaniem zakłóceń czy szumów [114] poprawiają dokładność klasyfikacji. W sytuacji uczenia przyrostowego metodę zmodyfikowanej entropii krzyżowej zastosowano w celu poprawy dokładności modelu przy jednoczesnym zmniejszeniu złożoności obliczeniowej podczas jego trenowania [115].

Entropia krzyżowa może być wykorzystywana do optymalizacji ruchu systemu wieloagentowego czy też w zagadnieniach inteligencji roju [116]. W pracy [117], wykorzystując minimalizację entropii krzyżowej, wyznacza się trasy w taki sposób, aby trasy wysokiej jakości były wybierane przez elementy systemu. Metodę tę można określić jako stochastyczną wersję podejścia do systemów dynamicznych.

Ponadto entropia krzyżowa jest wykorzystywana w optymalizacji roju cząstek [118], [119]. W pracy [118] wykorzystuje się ją w celu oceny sprawności i utrzymywania różnorodności roju, w tym jako miarę częstotliwości. Z kolei w [119] wykorzystuje się ją jako parametr mający wpływ na decyzję roju cząstek dotyczącą zastosowania komponentu wyszukiwania lokalnego, jak i schematu probabilistyczny losowego wyboru odpowiednich warunków początkowych dla wyszukiwania lokalnego.

W pracy [120] entropia krzyżowa służy do optymalizacji współczynników skalowania sterownika rozmytego PD dwukołowego robota samobalansującego. Dzięki zastosowaniu tej metody osiągnięto lepsze efekty w zakresie szybkości reakcji robota, a także balansu i stabilizacji. Z kolei w [121] podjęto się implementacji entropii krzyżowej jako metody optymalizacyjnej doboru parametrów kontrolera rozmytego do sterowania bezzałogowym systemem powietrznym w celu uniknięcia kolizji.

Podsumowując, entropia i entropia krzyżowa to pojęcia niezaprzeczalnie nierozzerwalne. Znajdują one swoje praktyczne i wszechstronne zastosowanie w różnych dziedzinach nauki. Na szczególną uwagę w kontekście niniejszej rozprawy zasługuje fakt, że można je wykorzystywać jako miary służące do oceny stanu systemu. Ponadto w rozumieniu niniejszej rozprawy wykorzystywana będzie entropia w ujęciu shannonowskim, a nie w układach termodynamicznych.

4.2. INNE MIARY WYKORZYSTANE W TEJ PRACY

Ocena jakości i efektywności modeli predykcyjnych wymaga zastosowania odpowiednich metryk, które umożliwiają dokładne określenie poziomu zgodności między przewidywaniami modelu a danymi referencyjnymi, pochodzącymi z symulacji. W literaturze naukowej wyróżnia się szereg wskaźników oceny modeli, z których najczęściej stosowane są [122]: średni błąd bezwzględny – MAE (ang. *Mean absolute Error*), błąd średniokwadratowy – MSE (ang. *Mean Squared Error*), pierwiastek z błędu średniokwadratowego – RMSE (ang. *Root Mean Square Error*) oraz współczynnik determinacji R^2 [123]. Każda z tych metryk dostarcza innych informacji o jakości modelu, pozwalając na bardziej kompleksową ocenę wyników modelowania. W tej pracy przyjęto te cztery wskaźniki do oceny wydajności modeli, z naciskiem na współczynnik determinacji R^2 jako główny wskaźnik jakości predykcji.

Średni błąd bezwzględny (MAE, ang. *Mean Absolute Error*) jest miarą dokładności prognoz, zgodnie z którą ocenia się średnią wielkość błędów absolutnych, tj. różnic między wartościami przewidywanymi a rzeczywistymi. Błąd średniokwadratowy (MSE, ang. *Mean Squared Error*) jest miarą, według której oblicza średnią wartość kwadratów różnic pomiędzy wartościami przewidywanymi a rzeczywistymi. W przeciwieństwie do MAE, MSE kładzie większy nacisk na większe odchylenia, ponieważ różnice są podnoszone do kwadratu. Dzięki temu jest bardziej wrażliwy na znaczne błędy, które mogą wskazywać na istotne rozbieżności w modelu. Pierwiastek z błędu średniokwadratowego (RMSE, ang. *Root Mean Square Error*) jest pierwiastkiem kwadratowym wartości MSE, co pozwala uzyskać miarę o jednostce zgodnej z jednostką danych wejściowych. RMSE jest szczególnie cenną metryką, gdy konieczne jest uwzględnienie wpływu dużych odchyłeń bez poświęcania interpretowalności wyników. Współczynnik determinacji (R^2) to miara statystyczna, która wskazuje, jak dobrze model wyjaśnia zmienność danych. Oblicza się go jako proporcję zmienności zmiennej zależnej wyjaśnioną przez zmienne niezależne w modelu. Wartość R^2 mieści się w przedziale od 0 do 1, gdzie 1 oznacza idealne dopasowanie modelu do danych rzeczywistych, a 0 wskazuje na całkowity brak zależności. Współczynnik R^2 jest jedną z najczęściej stosowanych miar dopasowania, ponieważ pozwala na szybkie określenie, w jakim stopniu wyniki modelu są zbieżne z rzeczywistymi wartościami. W przedstawionej analizie R^2 przyjęto jako główny wskaźnik jakości modelu, co umożliwia efektywne porównanie różnych modeli oraz ocenę ich wydajności.


5. ALGORYTM UNIKANIA KOLIZJI

Jak wykazano w przeglądzie literatury, algorytmy antykolizyjne są niezbędnym elementem systemu roju bezzałogowych statków powietrznych. Drony powinny mieć świadomość otoczenia, a także reagować na nienormatywne zachowania innych obiektów. Szczególnie istotna dla dronów w roju jest również reakcja na kolizje, które mogą wystąpić pomiędzy nimi. Należy mieć na uwadze, że ruch pojedynczego drona w celu uniknięcia kolizji może mieć wpływ na inne drony, jeśli znajdują się one wystarczająco blisko.

W kontekście roju dronów algorytmy antykolizyjne powinny również obejmować unikanie kolizji pomiędzy poszczególnymi jednostkami w roju. Unikanie kolizji między dronami w roju jest niezbędne, aby zapewnić płynną i bezpieczną interakcję pomiędzy nimi oraz minimalizować ryzyko zakłóceń w ruchu powietrznym. Unikanie kolizji w roju pozwala ponadto na efektywne wykorzystanie potencjału zbiorowego, umożliwiając dronom współpracę w celu realizacji zadań, w tym utrzymanie stacjonarnej formacji. Wdrażanie algorytmów antykolizyjnych dla roju dronów wymaga uwzględnienia dodatkowych aspektów, takich jak koordynacja i komunikacja pomiędzy jednostkami czy autonomiczne podejmowanie decyzji. Oczekuje się również, że algorytmy te będą skalowane – niezależnie od ilości dronów w roju zachowana zostanie efektywność i stabilność systemu, umożliwiając bezpieczne operacje.


W celu przeprowadzenia eksperymentów i badań nad rojami dronów opracowano innowacyjny i autorski algorytm unikania kolizji. Został on objęty zgłoszeniem patentowym [124], którego pewne aspekty w toku prac nad prezentowaną rozprawą zmodyfikowano. Uruchamia on szereg możliwości, które omówiono w kolejnych częściach pracy.

Po pierwsze opracowany algorytm antykolizyjny jest inspirowany oddziaływaniem sił odpychających, których występowanie odnotowano również w przypadku metody sztucznego pola potencjału, a także łączy to podejście z metodami geometrycznymi. Jak przedstawiono na rysunku 7, algorytm zakłada występowanie tzw. stref bezpieczeństwa.



Rysunek 7. Strefy bezpieczeństwa w algorytmie

Wyróżnia się dwie strefy bezpieczeństwa – wewnętrzną S_1 oraz zewnętrzną S_2 , które wyznaczone są na podstawie promieni stref – R_1 oraz R_2 . Promienie to jeden z parametrów, które dobiera się w celu minimalizacji ryzyka kolizji. W przedstawionym algorytmie można założyć, że wszystkie drony transmitują swoje pozycje lub że każdy dron bezpośrednio obserwuje swoje otoczenie. Algorytm jest uruchamiany przez każdy dron niezależnie, przynajmniej w ustalonych odstępach czasu i zawsze z uwzględnieniem nadchodzącego interwału. Na rysunku 8 schematycznie przedstawiono parametry, które ma każdy z dronów, któremu został zaimplementowany algorytm unikania kolizji w momencie zbliżania się intruza.



Rysunek 8. Składowe algorytmu

Po pierwsze występuje wektor misji \vec{p}_m , czyli prędkość i kierunek, w jakim musi podążać, aby osiągnąć cel. W formacji stacjonarnej wektor ten (jeśli jest niezerowy) jest zawsze skierowany w stronę wymaganej lokalizacji drona w formacji. Co więcej dron zna swoją pozycję (x_j) i obserwuje własne otoczenie. Kiedy w jego sąsiedztwie nie ma dronów, wektor misji jest wykonywany. Jest on wykonywany ponadto wtedy, gdy żaden inny dron nie znajduje się wewnątrz sfery S_2 .

Po drugie algorytm ma wektor ucieczki \vec{p}_u , który jest realizowany wtedy, gdy jakkolwiek dron przekracza granicę strefy S_1 . Oznacza to, że im bliżej określonego drona znajduje inny dron, tym wywiera on większy wpływ na wartość i kierunek wektora ucieczki. Za pomocą równania 9 przedstawiono wzór wektora ucieczki:

$$\vec{p}_u = \frac{\vec{p}_i}{|\vec{p}_i|} (R - |\vec{p}_i|)^q, \text{ gdzie } \vec{p}_i = \overrightarrow{(x_i, x_j)} \quad (9)$$

$$i \in N \leftrightarrow |\vec{p}_i| \leq R \text{ oraz } i \neq j$$

gdzie:

(x_j) – lokalizacja drona,

(x_i) – lokalizacja i-tego sąsiada,

N – zbiór sąsiadów w promieniu R ,

R – promień zainteresowania – dotyczący strefy zewnętrznej.

W tym momencie dron lekceważy wykonywanie misji i skupia się wyłącznie na realizacji ucieczki w celu uniknięcia kolizji. W stosunku do bazowej wersji algorytmu wprowadzono ponadto modyfikację, dzięki której w przypadku znalezienia jakiegokolwiek drona w wewnętrznej strefie bezpieczeństwa wektor ucieczki jest obrócony nieco w kierunku przeciwnym do ruchu wskazówek zegara. Daje to w efekcie większą skuteczność reakcji na uniknięcie kolizji, bez zmiany jej charakteru.

Z kolei ostatni z wektorów – wektor \vec{p}_z jest realizowany wtedy, gdy jakkolwiek dron znajduje się w strefie S_2 . Wówczas wykonywana jest zarówno misja, jak i ucieczka, co określa się wzorem (10).

$$\vec{p}_z = \vec{p}_m + \tau * \vec{p}_u \quad (10)$$

W algorytmie wprowadzono ponadto dwie stałe – q oraz τ , które są związane z intensywnością reakcji drona na otoczenie. Parametr τ jest elementem liniowym, natomiast parametr q jest elementem nieliniowym. Można przypuszczać, że określają one stopień „nerwowości” drona: jeśli obydwa parametry q i τ zostaną obniżone, dron staje się tolerancyjny i powoli reaguje na zachowania otoczenia; z drugiej strony, gdy te

parametry są podwyższone, dron staje się nadmiernie „nerwowy” i reaguje zbyt intensywnie.

Istotny jest fakt, iż powyższy algorytm jest uruchamiany przez każdy dron niezależnie, przynajmniej w ustalonych odstępach czasu i zawsze z uwzględnieniem nadchodzącego interwału. Uwzględnia lokalizację i ruch sąsiadujących dronów. Jego wynik determinuje zachowanie drona w kolejnym przedziale czasu. Jeśli w pobliżu znajdują się drony, algorytm zmienia ścieżki dronów, aby uniknąć bliskich spotkań; w przeciwnym razie próbują kontynuować swoją pierwotną misję.

6. SYMULACJA JAKO METODA UZYSKANIA DANYCH

6.1. SYMULATOR

W celu przeprowadzenia efektywnych i rzetelnych badań zachowań rojowych w oparciu o opracowany algorytm antykolizyjny stworzono symulator 2D. Oznacza to, że jest to symulator jednowarstwowy, gdzie każdy z dronów jest dronem wiodącym poruszającym się na tej samej wysokości i w dwóch wymiarach. Symulacja 2D jest również realistycznym odwzorowaniem zastosowania dronów np. w obserwacji terenu. W symulatorze zostały zaimplementowane funkcjonalności, które umożliwiają analizę zachowania formacji rojów dronów, a także identyfikację potencjalnych zaburzeń, takich jak kolizje czy oscylacje. Warto nadmienić, że symulator stanowi podstawę do badania dezorganizacji, dostarczając niezbędnych danych do analiz. W dalszej części rozdziału omówione zostaną jego kluczowe funkcjonalności.

Przed wszystkim podstawowym celem opisywanego oprogramowania jest symulowanie zachowania dronów podczas wykonywania zróżnicowanych scenariuszy testowych. W kontekście symulacji wyszczególnić można główne elementy, takie jak: drony znajdujące się w roju, które wykonują określoną misję, oraz drony będące intruzami. Dron intruz z założenia może być modelowany jako pojedynczy dron lub grupa dronów, które próbują wpłynąć na organizację formacji. Z założenia taki dron będzie próbował zdeorganizować formację, jednocześnie wykonując przy tym zadaną misję. Intruz może lecieć w kierunku formacji z dowolnego punktu planszy symulacyjnej oraz pod dowolnym kątem. Nawiązując do powyższych możliwości, warto nadmienić, iż symulator pozwala na wyszczególnienie różnych grup dronów w obrębie formacji. Każda grupa może być wyposażona w indywidualne cechy, takie jak prędkość, zasięg działania czy strategie zachowań, co pozwala na modelowanie bardziej złożonych interakcji wewnątrz formacji.

Kolejną istotną funkcjonalnością jest to, że omawiane oprogramowanie pozwala na wizualizację i zapis danych z lotu roju dronów, dzięki czemu możliwa jest implementacja różnych scenariuszy związanych z m.in. stacjonarną formacją roju dronów. W oprogramowaniu istnieje możliwość dostosowania wielkości oraz kształtu formacji dronów. Użytkownik może manipulować zarówno liczbą dronów w formacji, jak i ich rozmieszczeniem względem siebie, co pozwala na symulacje formacji, począwszy od prostych układów, na bardziej złożonych strukturach kończąc.

Szczególną uwagę należy zwrócić także na możliwość manipulowania zarówno parametrami roju, intruza, jak i parametrami algorytmu antykolizyjnego. W tabeli 1 zestawiono główne modyfikowalne parametry roju. Z kolei w tabeli 2 przedstawiono modyfikowalne parametry algorytmu antykolizyjnego.

Tabela 1. Parametry roju w symulatorze

Parametr	Opis
Formacja	
sizeX	liczba dronów w rzędzie
sizeY	liczba rzędów
spacing	odległość pomiędzy dronami w roju [m]
offset	przesunięcie względem punktu (0,0) układu współrzędnych
Metoda kartezjańska	
StartX, startY	współrzędne startu lotu intruza
target, targetY	współrzędne celu intruza
Metoda osiowa	
x, y	punkt na planszy symulacyjnej, przez który musi przelecieć dron intruz
Before, after	całkowita długość linii odzwierciedlającej trasę intruza
angle	kąt lotu wyrażony w stopniach
Metoda osiowa z zakresem kątów	
from	wartość początkowa kąta
to	wartość końcowa kąta
step	przyrost, o jaki będzie zwiększał się kąt w kolejnych iteracjach symulacji

Parametrami definiującymi formację są: „sizeX” oznaczający liczbę dronów w rzędzie, „sizeY” określający liczbę rzędów. Z kolei „spacing” definiuje odległość pomiędzy dronami w roju. Jedną z możliwych opcji jest także wyznaczenie przesunięcia całej formacji względem punktu początkowego układu współrzędnych, co określa parametr „offset”.

W symulatorze wyróżnia się dwie możliwości przelotu intruza i ruchu formacji. Pierwszą i podstawową jest metoda kartezjańska. Wówczas intruz porusza się na planszy symulacyjnej zgodnie z kartezjańskim układem współrzędnych. W celu określenia trajektorii lotu wykorzystywane są współrzędne początku i końca. Z kolei druga to metoda osiowa, gdzie trasa

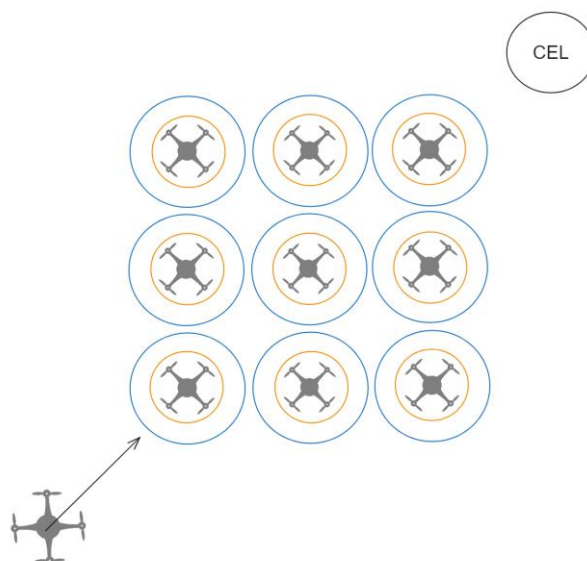
lotu intruza przebiega pod określonym kątem oraz na określonej długości. W przypadku metody osiowej ścieżka intruza jest linią prostą przechodzącą przez określony punkt (x, y) pod zadaniem kątem. Kąt jest liczony w stopniach, przeciwnie do ruchu wskazówek zegara, tak że zero oznacza „wzdłuż osi x w prawo”, a 90 oznacza „wzdłuż osi y w górę”. Całkowita długość linii to suma parametrów „before” i „after”.

Tabela 2. Parametry algorytmu antykolizyjnego w symulatorze

Parametr	Opis
R_1	Wewnętrzny promień bezpieczeństwa
R_2	Zewnętrzny promień bezpieczeństwa
τ	Stała odpowiedzialna za wzmocnienie reakcji drona podczas aktywacji wektora \vec{p}_z
q	Stała odpowiedzialna za wzmocnienie reakcji drona podczas aktywacji wektora \vec{p}_u

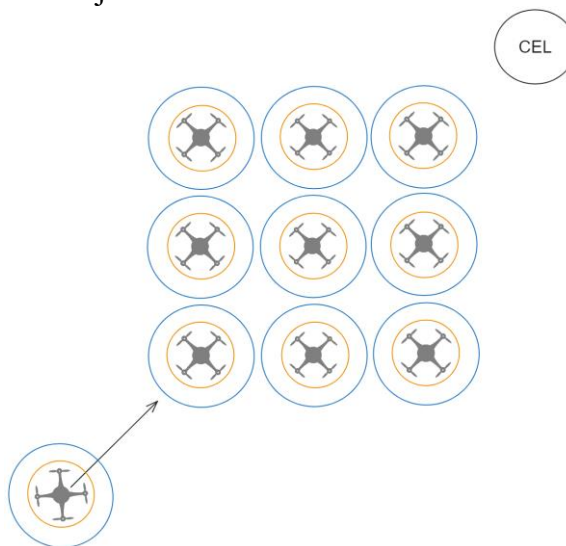
Istotną cechą symulatora, jak wspomniano powyżej, jest implementacja algorytmu unikania kolizji oraz modyfikowanie bezpośrednio jego głównych parametrów, tj.: R_1 , R_2 , τ , q . Dodatkowo w symulatorze można wyróżnić następujące scenariusze, które pozwalają na badanie zachowań kooperatywnych i niekooperatywnych.

Formacja roju dronów jest odpowiedzialna za unikanie kolizji, podczas gdy dron intruz lub grupa dronów o charakterze intruzów nie jest zaangażowana w ten proces i nie realizuje misji wraz z algorytmem unikania kolizji, co schematycznie przedstawiono na rysunku 9.



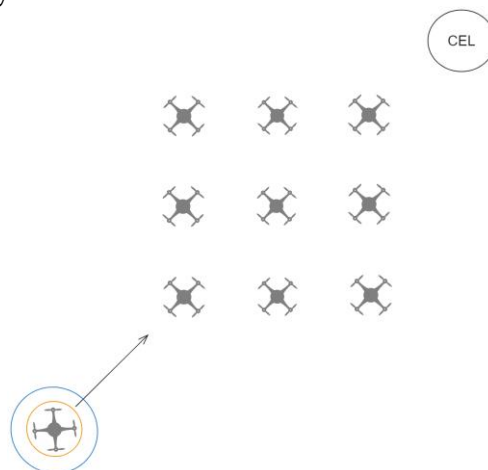
Rysunek 9. Schematyczny rysunek formacji realizującej algorytm unikania kolizji oraz intruza

Jak przedstawiono na rysunku 10, zarówno formacja roju dronów, jak i dron intruz są zaangażowane w proces unikania kolizji i mają wdrożony algorytm unikania kolizji.



Rysunek 10. Schematyczny rysunek formacji i intruza realizujących algorytm unikania kolizji

Formacja roju dronów nie ma zaimplementowanego algorytmu unikania kolizji, w przeciwieństwie do drona intruza, który ma mechanizm unikania kolizji – rysunek 11.



Rysunek 11. Schematyczny rysunek formacji oraz intruza realizującego algorytm unikania kolizji

6.2. MIARA W SYMULATORZE

Istotnym aspektem jest fakt, że symulator ma możliwość implementacji wybranych metryk, które umożliwiają ocenę dezorganizacji, efektywności formacji czy analizę skuteczności różnorodnych strategii. Przegląd literatury przedstawiony w Rozdziale 2. wykazał, że entropia jest powszechnie stosowana jako referencyjna miara strukturalizacji systemu w różnych obszarach nauki.

W związku z tym założenie, które poddano weryfikacji, jest następujące: entropia krzyżowa może być adekwatną miarą umożliwiającą monitorowanie stopnia nieuporządkowania czy nieprzewidywalności w badanych formacjach rojów dronów. Z tego względu zaimplementowano entropię krzyżową jako miarę do opracowanego symulatora. Zdecydowano się ją wykorzystać w celu monitorowania stopnia dezorganizacji w badanych formacjach oraz zrozumienia zależności w systemie roju dronów.

Wdrożona entropia krzyżowa reprezentuje różnicę między oczekiwanym a rzeczywistym rozkładem – w tym przypadku rozkładem dronów w przestrzeni. Entropia krzyżowa w oprogramowaniu liczona jest zgodnie z poniższym równaniem 11, gdzie $p(x)$ reprezentuje rozkład

oczekiwany, a $q(x)$ rozkład rzeczywisty. Odnosi się ona do odległości pomiędzy rzeczywistą a oczekiwaną pozycją dronów.

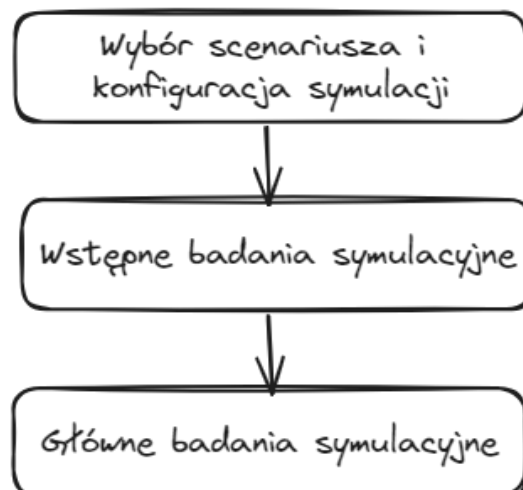
$$H(p, q) = - \sum_{x \in X} p(x) \times \log(q(x)) \quad (11)$$

W analizowanym oprogramowaniu entropia krzyżowa obliczana jest na każdym kroku symulacji dla wszystkich dronów w formacji. Idąc dalej, całkowita entropia krzyżowa jest sumą cząstkowych chwilowych entropii podczas każdego kroku symulacji. Istotne jest, że gdy nie ma intruza, oczekiwana entropia krzyżowa wynosi zero, ponieważ z perspektywy pracy drony nie zmieniają swoich pozycji w formacji. Warto podkreślić, że wartości entropii krzyżowej są referencyjne, co oznacza, że służą jako punkt odniesienia lub ogólniej porównania w procesie symulacji.

6.3. GENEROWANIE ZBIORU DANYCH – WSTĘPNE BADANIA SYMULACYJNE

W celu weryfikacji założeń i tezy badawczej zaprezentowanej w tej rozprawie prace rozpoczęto od wygenerowania i przygotowania odpowiednich zestawów danych na podstawie opracowanych scenariuszy testowych. Zbiór danych jest niezbędny w celu badania dezorganizacji roju dronów oraz oceny poziomu entropii krzyżowej. Etapy tego procesu zostały schematycznie zaprezentowane na rysunku 12.

Etapy generowania zbioru danych

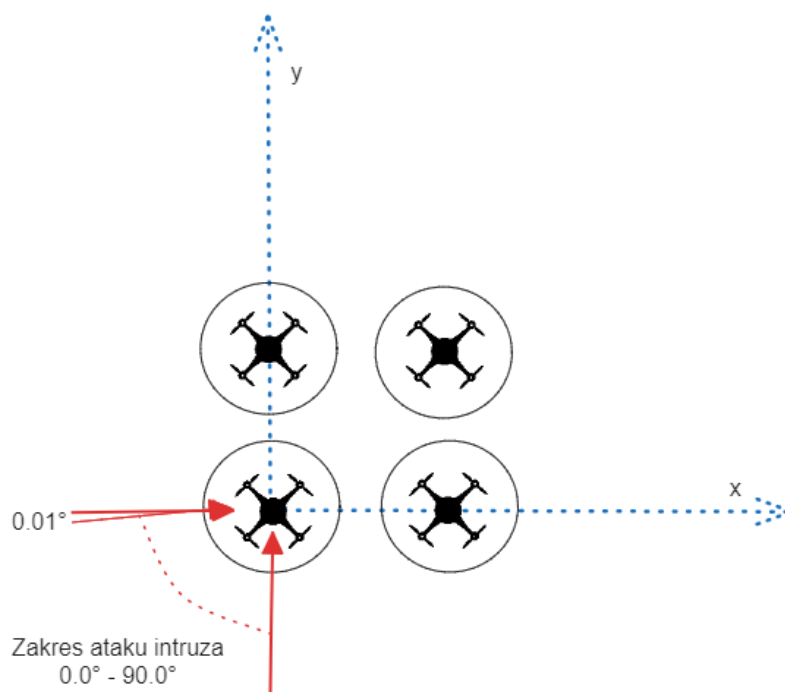


Rysunek 12. Etapy generowania zbioru danych

Poprzez skrupulatne przeprowadzenie powyższych faz możliwe jest uzyskanie kompleksowych i rzetelnych danych niezbędnych do wiarygodnej analizy formacji roju dronów, a także do opracowania modeli predykcyjnych. Pierwszy z etapów obejmuje zdefiniowanie celów symulacyjnych i wybór scenariusza symulacyjnego oraz zdefiniowanie zakresu dostępnych parametrów. Następnie przeprowadza się wstępne badania symulacyjne, których celem jest uzyskanie odpowiedniego interwału próbkowania. Podczas głównych badań symulacyjnych przeprowadzanych na podstawie wyników pochodzących z badań wstępnych uzyskuje się ostateczną liczbę próbek danych. Stanowią one zbiór danych, który następnie jest wykorzystywany do dalszych analiz.

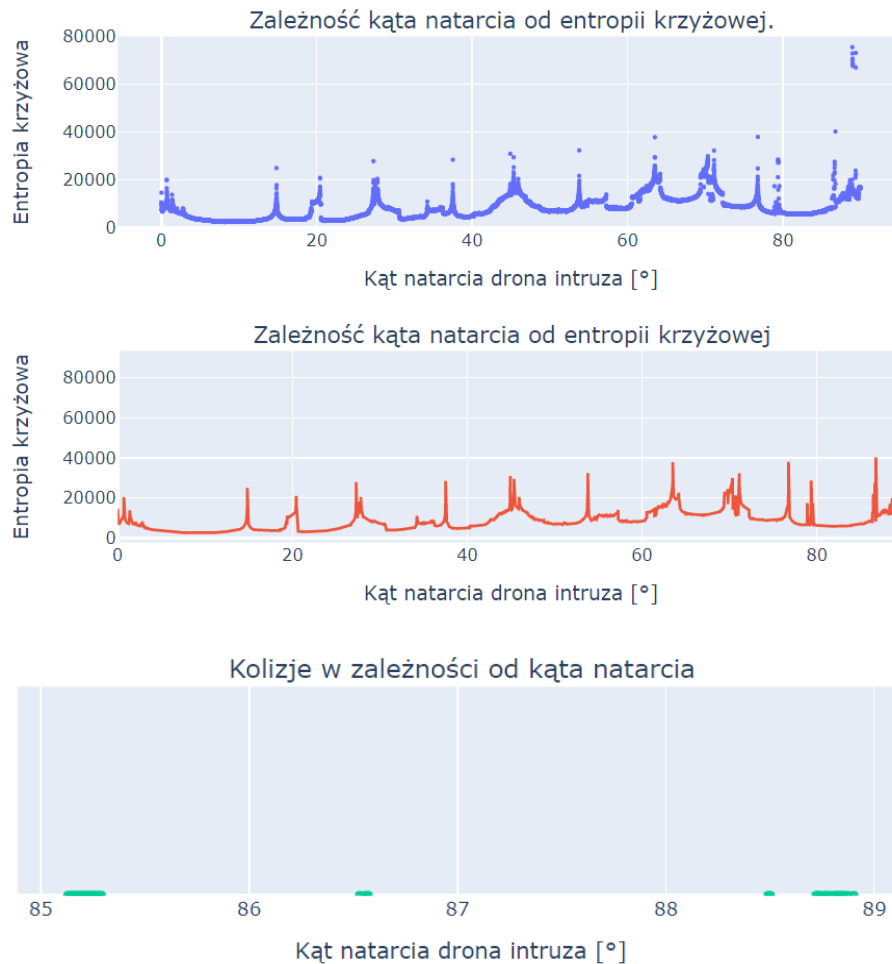
Początkowo do analiz wybrano dwuwymiarową kwadratową, stacjonarną formację roju dronów. Każdy z dronów w formacji miał zaimplementowany algorytm unikania kolizji, natomiast dron intruz w tym scenariuszu nie miał wdrożonej takiej funkcjonalności. Na podstawie wcześniejszych wstępnych analiz [125] określono, że intruz będzie zbliżał się do formacji od lewego dolnego rogu planszy symulacyjnej. Kąt natarcia wahać się będzie od 0 do 90 stopni, gdzie "zero" oznacza podejście wzdłuż osi x, a 90 stopni – wzdłuż osi y. Punkt podejścia intruza przesunięto w stosunku do pozycji lewego dolnego drona w formacji, o nie więcej niż połowę odległości między nimi zarówno w poziomie, jak i w pionie.

Powyższe założenia zostały schematycznie przedstawione na rysunku 13. Należy mieć na uwadze, że każdy przebieg symulacji wykorzystywał inny zestaw parametrów, jednak przedstawiony schemat wtargnięcia drona intruza został zachowany. Dron intruza wykonywał swoją misję, lecąc wprost na pierwszego drona w formacji pod różnymi kątami, a jego przesunięcie wynosiło 0,0. Co oznacza, że startował zawsze z tej samej pozycji.



Rysunek 13. Schemat ataku intruza pod różnymi kątami

W celu oceny zależności entropii krzyżowej od kąta natarcia drona intruza przeprowadzono symulacje, podczas których dron intruza nie miał zaimplementowanego algorytmu unikania kolizji, w przeciwieństwie do dronów wchodzących w skład 25-elementowej formacji. Drony były rozmieszczone w odstępach 30 m, zaczynając od pozycji (30, 30). Parametry algorytmu antykolizyjnego wynosiły kolejno: $R_1 = 15$ m, $R_2 = 20$ m, $\tau = 1$, $q = 1$. Rozważana jest sytuacja, w której drony w stacjonarnej formacji znajdują się na swoich początkowych, stałych pozycjach. Założono, że za każdym razem, gdy pozycja zostanie porzucona, spowoduje to pewien wzrost dezorganizacji, a tym samym wzrost wartości entropii krzyżowej. Na podstawie powyższych założeń uzyskano wyniki zależności zmian entropii krzyżowej związanych z zaburzeniami formacji, obliczonej dla każdego 0,01 stopnia, które przedstawiono na wykresach, na rysunku 14. Przebieg o kolorze niebieskim wskazuje punktowe wyniki, natomiast przebieg oznaczony kolorem czerwonym stanowi liniowe połączenie tych punktów, ilustrując zależność między kolejnymi wartościami. Linia ta nie wprowadza dodatkowej aproksymacji danych, a jedynie wizualizuje istniejące relacje w sposób ciągły, łącząc kolejne punkty pomiarowe.




Rysunek 14. Zależność entropii krzyżowej od kąta natarcia intruza

Po pierwsze analiza powyższych wyników wykazała, że sytuacje o względnie wysokiej entropii krzyżowej są bardzo zbliżone do sytuacji, gdy wartości te są niskie. Oznacza to, że nawet najmniejsza zmiana kąta może skutkować znaczącą zmianą entropii krzyżowej i wzrostem dezorganizacji całej formacji. Podczas zmiany kąta natarcia obserwuje się zarówno stany względnego spokoju, jak i szczyty wzrostów entropii. W zakresie kątów 85–89° obserwuje się ponadto kolizje. Podczas wystąpienia kolizji entropia krzyżowa nie jest obliczana, jednak można zauważyć, że wystąpienie kolizji wiąże się ze znacznym wzrostem

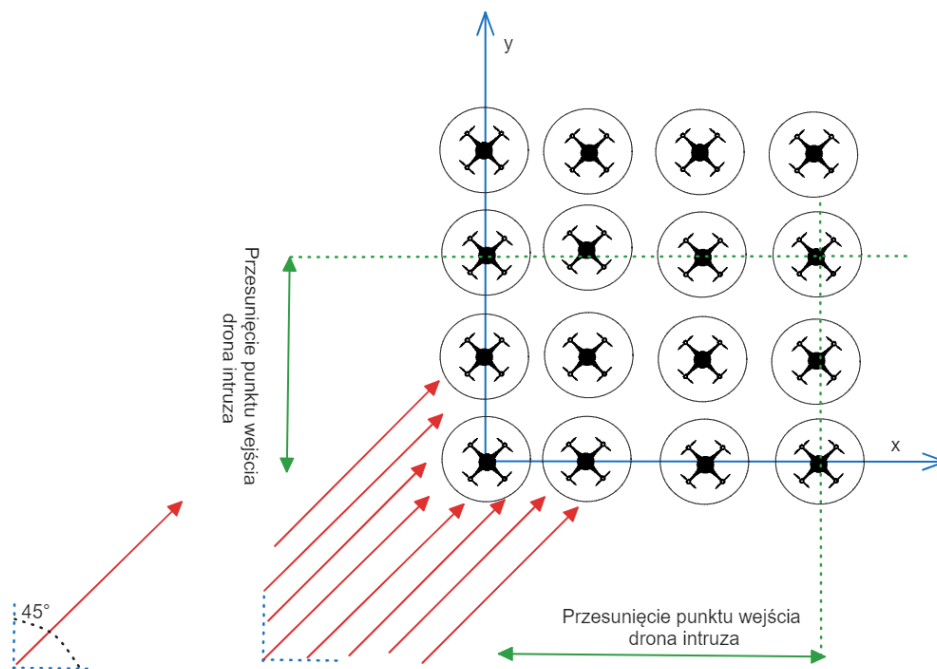
dezorganizacji formacji dla kątów sąsiednich do tych, przy których entropia krzyżowa osiąga największe wartości.

Chociaż zwiększone wartości entropii krzyżowej nie są skorelowane z konkretnymi wartościami kątów natarcia drona intruza, można zauważyć zależność, że im wyższe wartości kąta natarcia, tym wyższe wartości entropii krzyżowej. Dodatkowo, jeśli wyodrębni się następujące zakresy kątów: 0.00–20.00 stopni, 20.00–40.00 stopni, 40.00-60.00 stopni oraz 60.00-90.00 stopni, to w każdym z tych przedziałów można zauważyć pewne maksymalne wartości entropii krzyżowej dla określonych kątów, co zostało zobrazowane na rysunku 15.



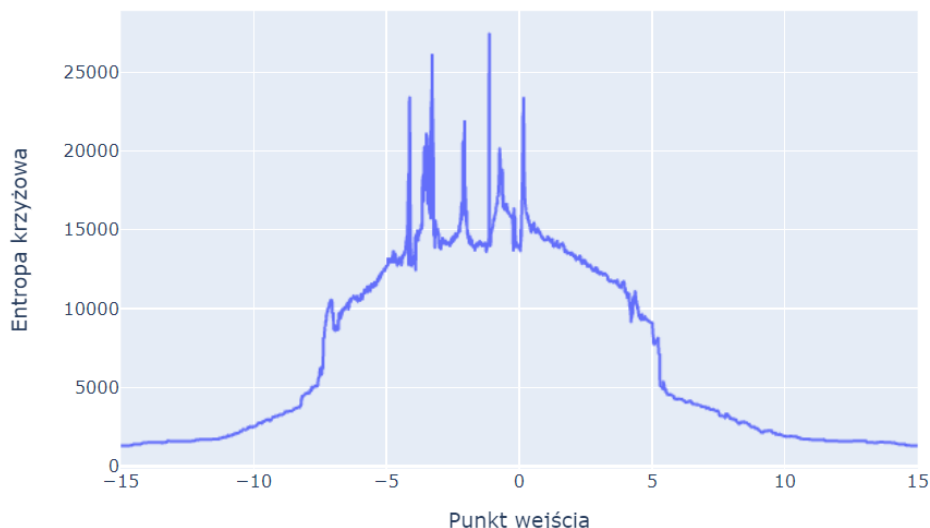
Rysunek 15. Najwyższe wartości entropii w danych zakresach kątów

W następnym kroku przeprowadzono kolejną serię wstępnych symulacji, które miały na celu zobrazowanie zmian wartości entropii krzyżowej w zależności od przesunięcia punktu wejścia drona intruza, przy zachowaniu stałego kąta wynoszącego 45°. Jak schematycznie przedstawiono na rysunku 16, zakres punktów wejścia drona intruza na planszy symulacyjnej mieści w zakresie od -15 do +15 z rozdzielczością 0,01 m. Pozostałe parametry zostały ustawione tak jak poprzednio.



Rysunek 16. Schemat przedstawiający punkt wejścia intruza

Jak przedstawiono na rysunku 17, ponownie zaobserwowano, że przypadki, w których entropia krzyżowa osiąga wysokie wartości, są bliskie przypadkom o niskich wartościach, co wskazuje, że nawet niewielka zmiana przesunięcia punktu wejścia może skutkować znaczącą zmianą entropii krzyżowej. Powyższe analizy wskazują, że jest to niemal chaotyczna sytuacja. Jak opisano w [34], jest to stan, w którym system znajduje się pomiędzy skrajnymi stanami porządku i chaosu, gdzie dopasowanie jest maksymalizowane. Dodatkowo jak wskazuje literatura, system znajduje się na skraju chaosu, gdy niewielka zmiana warunków początkowych powoduje duże, ale ograniczone różnice w wyniku [26].



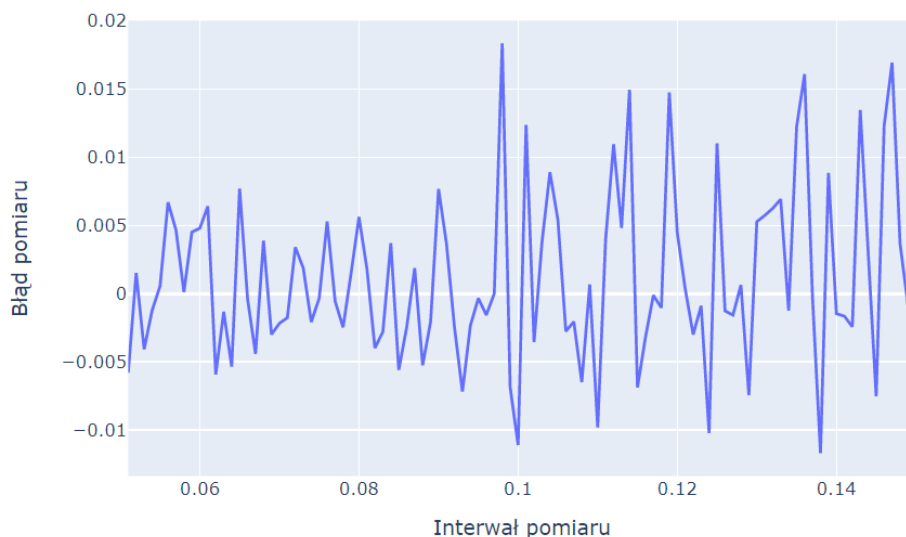
Rysunek 17. Zależność między punktem wejścia a entropią krzyżową.

Biorąc pod uwagę niemal chaotyczną zależność między parametrami intruza, ważne było określenie prawidłowego interwału próbkowania. Należy mieć na uwadze, że każdy pojedynczy punkt danych reprezentuje wynik dużej liczby symulacji. Dla danego zestawu parametrów należy uwzględnić różne kąty natarcia i punkty wejścia, a liczba ich kombinacji jest nieograniczona. Jednak na potrzeby dalszych analiz w celu uzyskania porównywalnych wyników dla wszystkich danych konieczne było podjęcie decyzji o ograniczonej liczbie tych kombinacji, aby obliczyć średnią entropię. W związku z tym konieczne było wprowadzenie interwału próbkowania i kwantyzacji danych oraz zaakceptowanie błędu, jaki taki proces wprowadza. Dołożono wszelkich starań opisanych szczegółowo w niniejszym podrozdziale, aby ustalić zakres takiego błędu i wybrać częstotliwość próbkowania, która minimalizuje błąd. Przeprowadzono kolejne z badań wstępnych mające na celu określenie przedziału mającego zastosowanie dla kąta i punktu wejścia.


Początkowo w celu wyznaczenia interwału próbkowania wybrano typowe kombinacje parametrów i obliczono uśrednioną entropię krzyżową dla odstępów $0,001^\circ$ i $0,001$ m odpowiednio dla kąta i punktu wejścia w kolejnych symulacjach. Z jednej strony powyższy interwał jest nadmierny i ze względów praktycznych był zbyt mały. Zdecydowanie jest on poniżej precyzji przyrządów służących do wyznaczania kąta czy położenia. Z drugiej strony jednak może służyć jako dobry punkt odniesienia do dalszych analiz oraz w przypadku potencjalnego

osiągnięcia takich precyzji. Następnie przeprowadzono ponownie szereg symulacji dla tych samych parametrów w coraz większych interwałach, a wyniki porównano. Jako referencyjny punkt odniesienia przyjęto średnią entropię krzyżową. Z kolei metryką był średni błąd bezwzględny pomiaru, obliczony jako różnica pomiędzy entropią krzyżową odniesienia a entropią krzyżową obliczoną na podstawie omawianego przyrostu. Ze względów praktycznych pożądanym był interwał próbkowania wynoszący 0,05 lub więcej, ponieważ im większy interwał, tym szybsze jest generowanie punktu danych.

Wyniki eksperymentu zostały przedstawione na wykresach 18 i 19 odpowiednio dla zmienności kąta natarcia oraz punktu wejścia. Analiza nie wykazała jednoznacznej zależności między interwałem próbkowania a poziomem błędu. Niemniej jednak obserwowane były wyraźne granice maksymalnych wartości błędu. Warto zauważyć, że błąd związany ze wzrostem interwału próbkowania oscylował w przedziale od +2,5% do 1% dla punktu wejścia oraz kąta, przy uwzględnieniu różnorodnych przedziałów. W kontekście ostatecznej decyzji dotyczącej interwałów próbkowania przyjęto strategię pobierania próbek w odstępach co 0,1 jednostki dla zarówno kąta, jak i punktu wejścia. Taka decyzja opierała się na założeniu, że wprowadzony błąd będzie utrzymany na poziomie niższym niż 5%. Ta strategia próbkowania została wybrana ze względu na minimalizację błędu przy jednoczesnym zachowaniu akceptowalnej wydajności procesu pomiarowego.



Rysunek 18. Zależność pomiędzy interwałem próbkowania a błędem pomiaru dla kąta natarcia



Rysunek 19. Zależność pomiędzy interwałem próbkowania a błędem pomiaru dla punktu wejścia

Należy ponadto nadmienić, że w celu wyznaczenia średniej wartości entropii w jednym punkcie danych z użyciem tego przedziału potrzeba było ponad 250 000 symulacji.

Podsumowując, dzięki wstępnym badaniom symulacyjnym możliwe było ustalenie niezbędnych informacji w celu uzyskania rzetelnych danych do opracowania modeli predykcyjnych, a także do analizy zachowania stacjonarnej formacji roju dronów. Zaobserwowano, że roje pod wpływem działania intruza mogą zachowywać się niemal chaotycznie. Dodatkowo – co istotne – wstępne symulacje potwierdzają, że entropia krzyżowa stanowi adekwatną i referencyjną miarę zmian zachodzących w formacji.

6.4. GŁÓWNE BADANIA SYMULACYJNE – GENEROWANIE ORAZ ANALIZA ZBIORÓW DANYCH

Eksperymenty zreferowane w podrozdziale 6.3 pozwoliły na wygenerowanie docelowego zbioru punktów danych, zgodnie ze scenariuszem, w którym dron intruz nie miał zaimplementowanego

algorytmu unikania kolizji – zachowanie niekooperatywne. Każdy pojedynczy punkt danych był wynikiem 270 000–450 000, dla których wartości entropii krzyżowej zostały uśrednione. Symulacja postępuje zgodnie z iteracyjnym procesem, w którym entropia chwilowa jest obliczana w każdym kroku symulacji, a wystąpienie ewentualnych kolizji jest wykrywane natychmiast. Oprócz parametrów bezpośrednio dotyczących formacji i algorytmu antykolizyjnego oraz entropii krzyżowej w wygenerowanym zbiorze danych znajdują się również informacje, takie jak: typ formacji, numer formacji oraz informacje dotyczące prawdopodobieństw wystąpienia: oscylacji, kolizji, wibracji i przejścia. Suma prawdopodobieństw wszystkich możliwych zdarzeń w przestrzeni zgodnie ze wzorem 12 wynosi 1.0:

$$P(K) + P(O) + P(W) + P(L) = 1.0 \quad (12)$$

gdzie:

$P(K)$ – prawdopodobieństwo wystąpienia kolizji,

$P(O)$ – prawdopodobieństwo wystąpienia oscylacji,

$P(W)$ – prawdopodobieństwo wystąpienia wibracji,

$P(L)$ – prawdopodobieństwo przejścia drona intruza.

Należy również zdefiniować, czym w rozumieniu symulacji są poszczególne zjawiska. Kolizja to sytuacja, w której przy zadanym układzie parametrów którykolwiek z dronów przekroczy zarówno strefę bezpieczeństwa R_1 , jak i R_2 drona, z którym znajdzie się na torze kolizyjnym, a realizacja wektora ucieczki nie będzie skutkowałą wycofaniem. Ostatecznie powoduje to brak możliwości kontynuacji misji. Należy podkreślić, że chociaż dołożono wszelkich starań, aby wybrać wartości parametrów, które nie ułatwiają kolizji, nadal takie zjawisko może wystąpić.

Z kolei oscylacje w rozumieniu autorki tej pracy można porównać z zachowaniem awaryjnym, w którym dron znacznie oddala się od swojej pozycji wyjściowej z powodu wybicia z formacji np. przez drona intruza. Aczkolwiek w tej sytuacji istotny jest fakt, że jego powrót do pozycji wyjściowej jest znacznie utrudniony, a nawet niemożliwy. Wynika to z wystąpienia sytuacji blokowania go przez inne drony w roju. Wibracje występują w obrębie formacji wówczas, gdy dany dron lub drony znajdują

się blisko swoich prawidłowych pozycji, jednak w wyniku różnych czynników nie są w stanie dokładnie do nich wrócić.

Z kolei przejście to sytuacja, podczas której dron intruz realizuje swoją misję, wykonując trajektorię poprzez formację, nie doprowadzając do zjawisk niepożądanych, takich jak omówione wcześniej kolizje.

Oczywiście zarówno oscylacje, jak i wibracje mogą trwać w nieskończoność, jeśli warunki pozostaną takie same. Poza tym zarówno oscylacje, wibracje, jak i kolizje są zjawiskami niepożądanymi z punktu widzenia utrzymywania stacjonarnej formacji roju dronów, ale badawczo są ciekawe. Niemniej jednak świadomość występowania szczególnie oscylacji i wibracji w obrębie roju daje nowe i niewątpliwie ważne spojrzenie na bezpieczeństwo lotu i odpowiedni dobór parametrów.

Tak jak opisano powyżej, na jeden punkt danych składają się tysiące symulacji, a obliczona entropia krzyżowa stanowi wartość średnią ze wszystkich symulacji. Powyżej opisane zjawiska, takie jak kolizje, oscylacje i wibracje, odnoszą się do pojedynczych symulacji i nie negują wartości ogólnego punktu danych. Z perspektywy symulacji negowana jest więc jedynie ważność zestawu parametrów pojedynczego punktu, dla którego końcowa entropia przelotu nie jest obliczana i jest wyłączana ze średniej. Tymczasem w analizowanym zbiorze danych wskazano na prawdopodobieństwo wystąpienia tych niepożądanych efektów dla każdego ogólnego punktu danych.

6.4.1. Analiza pierwszego wygenerowanego zbioru danych – zachowania niekooperatywne

Początkowo wygenerowany zbiór danych składał się łącznie z 3891 próbek. Pierwszym krokiem podczas jego analizy były identyfikacja i usuwanie wartości odstających. Jest to istotny proces pod kątem opracowania późniejszych modeli oraz analiz [126]. Zaobserwowano, że zdarzały się sytuacje, w których odsetek pomyślnych przejść był tak niski, że uzyskana średnia wartość entropii krzyżowej mogła być wysoce niepewna. Postanowiono usunąć punkty danych, w których odsetek pomyślnych przejść był mniejszy niż 0.01 całkowitej liczby prób przejść, co dość często skutkowało usunięciem punktów danych o bardzo wysokiej entropii krzyżowej. Usunięcie tych punktów danych miało na celu eliminację wartości odstających, które mogłyby negatywnie wpływać na jakość i wiarygodność analiz oraz późniejszych modeli, a także zniekształcić ogólne wnioski, a ich obecność w analizie mogłaby

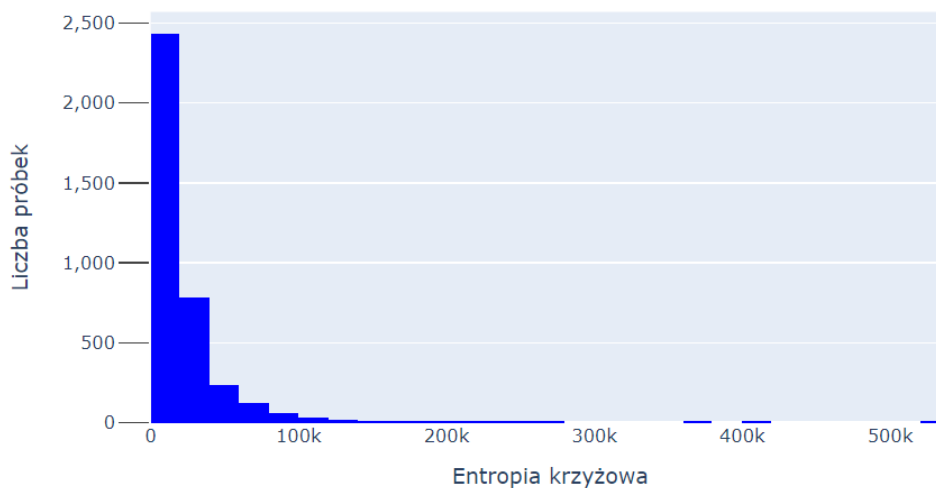
prowadzić do błędnych interpretacji. Po usunięciu próbek o prawdopodobieństwie przejścia mniejszym niż 0.01 zbiór danych składał się z 3720 próbek. Usunięte wartości stanowiły mniej niż 4%. W tabeli 3 przedstawiono podsumowanie statystyczne wygenerowanego zbioru danych po usunięciu wartości odstających.

Tabela 3. Statystyczny opis parametrów w zbiorze danych dotyczący zachowania niekooperatywnego

Parametr	Średnia	Odchylenie standardowe	min.	25%	50%	75%	max.
Rozmiar	5.397	2.282	2.000	3.000	5.000	7.000	9.000
Odstęp	37.714	7.177	25.006	31.626	37.790	43.967	49.997
R ₁	20.636	5.806	13.001	16.163	19.433	23.633	46.624
R ₂	28.867	6.589	20.015	23.435	27.346	33.068	48.393
τ	0.904	0.289	0.400	0.6525	0.9147	1.154	1.399
q	0.907	0.289	0.401	0.6569	0.9122	1.156	1.399
P(K)	0.016	0.037	0.000	0.000	0.0002	0.011	0.346
P(O)	0.250	0.311	0.000	0.000	0.083	0.434	0.988
P(W)	0.004	0.022	0.000	0.000	0.000	0.0007	0.360
P(L)	0.728	0.326	0.010	0.530	0.891	0.999	1.000
Entropia krzyżowa	22191.1	28530.7	1321.85	7015.48	13226.02	26825.3	527232.2


Początkowo podczas wstępnych analiz zbioru danych skupiono się na parametrze entropii krzyżowej. Wynika to z faktu, iż jest to przyjęta w pracy miara badania dezorganizacji roju dronów. Jak przedstawiono w tabeli 3, średnia entropia wynosi 22191.1, z odchyleniem standardowym 28530.7. Minimalna zaobserwowana entropia wynosi 1321.85, podczas gdy maksymalna entropia osiąga 527232.2. Analiza kwartylowa wskazuje, że 25% danych leży poniżej 7015.48, 50% – poniżej 13226.02 i 75% – poniżej 26825.3. Z kolei w celu zobrazowania histogramu wartości entropii krzyżowej opracowany został wykres przedstawiony na rysunku

20. Rozkład jest wyraźnie przesunięty w kierunku względnie niższych wartości i charakteryzuje się długim ogonem.



Rysunek 20. Histogram wartości entropii krzyżowej w zbiorze danych

Następnie dalsza analiza danych miała na celu znalezienie zależności, które mogłyby pomóc w określeniu najlepszego modelu predykcyjnego. Przeprowadzono korelację między entropią krzyżową a pozostałymi parametrami, a wyniki przedstawiono na rysunku 21. Należy zauważyć, że do analizy wykorzystano zmienne zależne, niezależne oraz prawdopodobieństwa.



Rysunek 21. Analiza korelacji parametrów z entropią krzyżową

Dodatni współczynnik korelacji wskazuje, że istnieje bezpośredni i dodatni związek pomiędzy dwiema zmiennymi. Zmienne, które dodatnio korelują z wartościami entropii krzyżowej, to R_1 i prawdopodobieństwo oscylacji. Parametr R_1 bezpośrednio wpływa na zachowanie roju, im jego wartości są większe, tym drony szybciej reagują na każde naruszenie przestrzeni wokół drona. Z kolei oscylacje prowadzą do bardzo wysokiej entropii krzyżowej, ponieważ są to sytuacje, w których rój nie jest w stanie się ustabilizować. Z drugiej strony normalne przejście oznacza, że rój był w stanie powstrzymać zakłócenia. Istotną ujemną korelację można więc zaobserwować w przypadku prawdopodobieństwa normalnego przejścia. Obserwacja ta jest zgodna z wiedzą dziedzinową.

6.4.2. Analiza drugiego wygenerowanego zbioru danych – zachowania kooperatywne

Drugi z wygenerowanych zbiorów danych zgodnie z omówioną w początkowych rozdziałach metodologią i parametryzacją składa się z 4616 próbek, z których w wyniku usunięcia próbek, gdzie prawdopodobieństwo przelotu wynosiło mniej niż 0.01, zbiór danych zawiera 4564 próbek.

W tabeli 4 przedstawiono analizę statystyczną drugiego zbioru danych. W porównaniu z pierwszym zbiorem danych, gdzie przedmiotem badań były zachowania niekooperatywne, w tym przypadku można zaobserwować statystycznie niższe wartości entropii krzyżowej. Średnia wartość entropii krzyżowej to 6798,23, odchylenie standardowe wynosi 13984,39. Percentyl 25% wynosi 2622,14, co oznacza, że jedna czwarta wszystkich wartości entropii jest mniejsza od tej liczby. Percentyl 50% wynosi 4249,90, co wskazuje, że połowa wartości entropii znajduje się poniżej tego poziomu. Z kolei percentyl 75% wynosi 6564,79, co sugeruje, że trzy czwarte wartości entropii jest mniejsze niż ta wartość, a tylko 25% wyników przekracza tę granicę. Porównanie percentyli ukazuje dużą koncentrację wartości entropii w dolnym zakresie rozkładu, jednak wartość maksymalna (291493,3) wskazuje na obecność ekstremalnych wyników, które znacznie odbiegają od reszty danych.


Poza tym w wygenerowanym zbiorze danych tak naprawdę nie występują kolizje, w związku z czym maksymalne prawdopodobieństwo wystąpienia kolizji wynosi 0,000354. Dane te mogą wskazywać, że zachowania kooperatywne w mniejszym stopniu wpływają na dezorganizację systemu.

Tabela 4. Analiza statystyczna zbioru danych związana z zachowaniem kooperatywnym drona intruza

Parametr	Średnia	Odchylenie standardowe	min.	25%	50%	75%	max.
Rozmiar	5.533	2.281	2.000	4.000	6.000	7.000	9.000
Odstęp	37.342	7.159	25.001	31.224	37.234	43.452	49.994
R1	20.689	5.722	13.007	16.240	19.588	23.742	45.456
R2	28.485	6.310	20.002	23.325	27.094	32.562	48.965
τ	0.905	0.288	0.400	0.656	0.904	1.154	1.399
q	0.894	0.287	0.400	0.650	0.889	1.146	1.399
P(K)	7.77E-08	5.25E-06	0	0	0	0	0.00035
P(O)	0,064	0.178	0	0	0	0.0145	0.988

P(W)	0.105	0.166	0	0	0.0075	0.167	0.916
P(L)	0.829	0.233	0.010	0.717	0.960	1	1
Entropia krzyżowa	6798.227	13984.39	427.580	2622.141	4249.902	6564.788	291493.3

W celu zobrazowania histogramu wartości entropii krzyżowej opracowano ponadto wykres przedstawiony na rysunku 22. Jak wskazuje analiza, większość próbek znajduje się w bardzo niskim zakresie entropii krzyżowej. Oprócz tego występuje tzw. „długi ogon rozkładu”, gdzie entropia krzyżowa osiąga nawet bardzo wysokie wartości (rzędu setek tysięcy), choć liczba takich przypadków jest bardzo mała. Histogram ma niesymetryczny rozkład z wysokim skupiskiem wartości blisko zera oraz małą liczbą obserwacji z bardzo dużymi wartościami entropii krzyżowej.

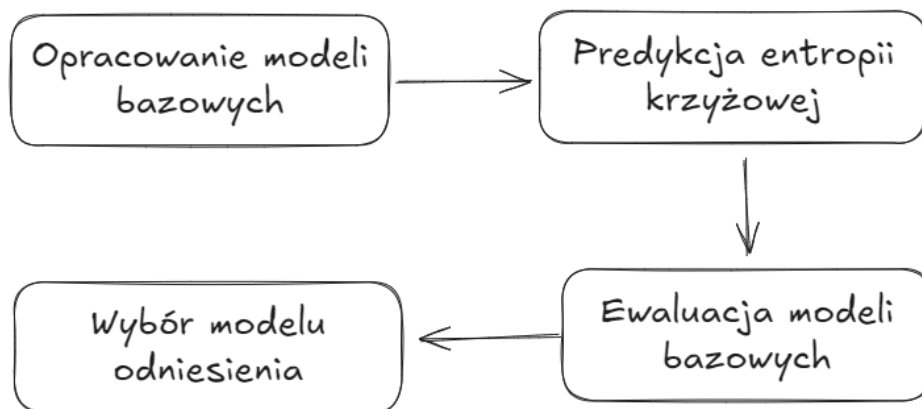


Rysunek 22. Histogram wartości entropii krzyżowej w drugim zbiorze danych

7. MODELE BAZOWE

W rozdziale tym omówiono badania mające na celu potwierdzenie postawionych tez badawczych. Po pierwsze jak pokazano schematycznie na rysunku 23, prace rozpoczęto od opracowania modelu bazowego. Model bazowy (model odniesienia) został opracowany w celu ustanowienia punktu odniesienia dla oceny modeli predykcyjnych. W kontekście prezentowanej pracy jest on niezbędny w celu ustalenia minimalnego poziomu skuteczności, który musi być przekroczony, aby kolejne modele w oparciu o inne algorytmy zostały uznane za ulepszone. Rozdział ten stanowi rozszerzenie koncepcji zaprezentowanej w pracy [127]. Opracowane modele bazowe będą dokonywały predykcji entropii krzyżowej, która jest przyjętą miarą dezorganizacji. Następnie skuteczność tej predykcji będzie mierzona metrykami R^2 , MAE, MSE, RMSE szczegółowo opisanymi w podrozdziale 4.2. Finalnie wybrany zostanie jeden, najlepszy model odniesienia, do którego w dalszych częściach pracy będzie następować odwołanie.

Modele bazowe będą dotyczyły predykcji entropii krzyżowej na podstawie określonych parametrów związanych z rojem i algorytmem antykolizyjnym.



Rysunek 23. Schemat badań nad modelami bazowymi

Jako modele bazowe zdecydowano się zastosować regresję liniową. Nie oczekiwano, że przyniesie ona optymalne rezultaty, lecz że posłuży jako punkt wyjścia do oceny i porównania z bardziej zaawansowanymi modelami. W kontekście bardziej złożonych technik, takich jak algorytmy uczenia maszynowego, regresja liniowa miała pełnić funkcję benchmarku, umożliwiając ocenę wartości dodanej wprowadzanych udoskonaleń.

Zastosowano kilka wariantów regresji liniowej, w tym regresję Hubera, regresję grzbietową (ang. ridge regression) oraz Elastic Net, Theil-Shein, aby lepiej radzić sobie z różnymi problemami związanymi z danymi.

Regresja Hubera to technika regresji odporna na wartości odstające. W przeciwieństwie do klasycznej regresji liniowej, w regresji Hubera łączy się metodę najmniejszych kwadratów z metodą najmniejszych bezwzględnych odchyleń. Wybrano ją dlatego, że charakteryzuje się ona większą stabilnością w obecności wartości odstających i jest mniej wrażliwa na anomalie w danych [128].

Z kolei regresja grzbietowa (ang. ridge regression) dodatkowo wprowadza funkcję celu kary proporcjonalnej do kwadratu wielkości współczynników regresji [129]. Stosowana ponadto jest w celu estymacji regresji w przypadku, gdy zmienne są skorelowane [130]. Nie wszystkie zmienne w zbiorze danych cechują się silną korelacją, jednak oczekiwano, że zastosowana regularyzacja zminimalizuje wpływ tych zmiennych, które wnoszą mniejszą wartość predykcijną.

Wymieniona powyżej regresja Theil-Sen, nazywana również estymacją medianową [131], polega na obliczaniu nachylenia linii regresji za pomocą mediany nachyleń wyznaczonych dla wszystkich par punktów danych. Przede wszystkim istotną zaletą jest to, że algorytm ten jest mniej wrażliwy na wartości odstające, a także może być zastosowany do danych niecharakteryzujących się rozkładem normalnym.

Elastic Net to wariant regresji liniowej łączący w sobie właściwości regresji grzbietowej z regresją Lasso [132]. Dzięki tej kombinacji możliwe jest poprawienie dokładności modelu, szczególnie w zbiorach danych, które mają skorelowane zmienne.

Niezależnie od wariantu regresji liniowej w procesie opracowywania modeli niezbędna jest identyfikacja zależności pomiędzy zmiennymi. Konieczne jest określenie, czy zależności między zmiennymi niezależnymi a zmienną zależną są liniowe, ponieważ modele regresji liniowej zakładają występowanie zależności liniowych. Niektóre formy nieliniowości można skorygować poprzez linearyzację, co zaprezentowano w kolejnych rozdziałach.

7.1. MODELE BAZOWE DLA PIERWSZEGO ZBIORU DANYCH

Do opracowania modelu bazowego początkowo wzięto pod uwagę następujące parametry: rozmiar, odstęp, τ , q , R_1 , R_2 . Jak wskazała analiza danych omówiona w rozdziale 6.4. oprócz liniowości obserwuje się także nieliniowość w zależnościach entropii krzyżowej od parametrów. Co

należy podkreślić, w eksperymentach można było zaobserwować, że różni prawdopodobnie znajdował się na krawędzi chaosu, ponieważ bardzo mała zmiana w ustawieniach początkowych (tj. parametrach) może prowadzić do znaczących zmian w zachowaniu, wyjaśniając w ten sposób zmienność entropii krzyżowej. Obserwowalne zachowanie takich układów można zwykle opisać za pomocą zestawu równań nieliniowych, jednak możliwe jest ich aproksymowanie za pomocą zestawu równań liniowych, jeśli zastosuje się linearyzację i/lub jeśli model ograniczy się do określonego podzbioru stanów początkowych.

Początkowo zidentyfikowano zależności występujące pomiędzy zmiennymi. W tym celu opracowano wykresy rozrzutu, których analiza nie pozwoliła na jednoznaczny identyfikację zależności do linearyzacji, aczkolwiek istniały silne kandydatury, dla których porównano uśrednioną entropię krzyżową z wartościami parametrów. Ostatecznie zastosowano przekształcenia przedstawione w tabeli 5.

Tabela 5. Linearyzacja podstawowych parametrów

Parametr	Linearyzacja
Rozmiar	$y = 122.75x^3 - 2601.3x^2 + 19506x - 22590$
Odstęp	brak
R ₁	brak
R ₂	$y = -18.791x^2 + 2403.7x - 2922$
τ	brak
q	brak

Po niezbędnych przekształceniach opracowano następujące modele regresji liniowej: regresję Hubera, regresję grzbietową, regresję Theil-Shein, regresję Lasso oraz Elastic Net. Jako metryki oceny zastosowano opisane w rozdziale 4.2 R^2 , MSE, RMSE, MAE.

W tabeli 6 przedstawiono wyniki uzyskane przez modele regresji liniowej. Z analizy danych przedstawionych w tabeli wynika, że regresja grzbietowa oraz regresja Lasso osiągnęły najlepsze wyniki pod względem R^2 , co sugeruje, że najlepiej wyjaśniają zmienność danych. Oba modele mają również najniższe RMSE, co oznacza, że ich przewidywania są najbliższe rzeczywistym wartościom. Drugi najlepszy wynik osiągnęła regresja Elastic Net. Z kolei regresja Theil-Shein ma najniższe MAE, co oznacza, że średnio jej przewidywania są najmniej obciążone błędem bezwzględnym. Regresja Hubera ma najwyższe wartości MSE i RMSE

oraz najniższe R^2 , co wskazuje na najslabsze dopasowanie do danych spośród porównywanych modeli.

Tabela 6. Wyniki modeli regresji liniowej w oparciu o podstawowe parametry

	MAE	MSE	RMSE	R^2
Regresja Hubera	8821.001	681444590.614	26104.493	0.39211
Regresja grzbietowa	10036.884	589465088.010	24278.902	0.47416
Theil-Shein	8841.290	669229456.306	25869.469	0.40301
Lasso	10037.091	589466134.392	24278.923	0.47416
Elastic Net	9949.9123	593684117.91	24365.6339	0.47040

Jak zakładano, żaden z modeli nie wyjaśnia w pełni zmienności danych, na co wskazuje wartość współczynnika determinacji (R^2) mniejsza niż 0.5.

W toku prowadzonych analiz i eksperymentów, przyczyniających się do zrozumienia sposobu działania roju, dostrzeżono możliwość wzbogacenia modelu poprzez wprowadzenie dodatkowych zmiennych, które potencjalnie mogłyby lepiej uchwycić występujące w systemie zależności, ale także wpłynąć na poprawę precyzji modelu. Szczególnie ważne jest to w przypadku systemów charakteryzujących się zależnościami, które trudno uchwycić za pomocą wyłącznie prostych, liniowych modeli. Do modelu postanowiono wprowadzić następujące parametry:

$$D_1 = \text{odstęp} - R_2$$

$$D_2 = R_2 - R_1$$

$$D_3 = \tau^q$$

Zmienna D_1 reprezentuje obszar, w którym drony nie znajdują się w zasięgu wykrywania swoich sąsiadów. W związku z tym każdy ruch drona w tej przestrzeni nie ma wpływu na inne. Parametr ten został wprowadzony ze względu na wcześniejsze obserwacje efektu kaskadowego, w którym ruch jednego drona szybko rozprzestrzenia się w roju i może prowadzić do znacznego wzrostu entropii krzyżowej.

Z kolei parametr D_2 ma na celu reprezentację tolerancji drona pod względem przejścia od strategii unikania kolizji z realizacją misją do wyłącznie ucieczki przed innymi dronami. Drony o wysokiej tolerancji

zwykle reagują wolniej i z większą precyzją na nadlatujące drony, natomiast niska tolerancja oznacza, że ich reakcje są nadmierne.


Zmienną D_3 wprowadzono w celu odzwierciedlenia pozornej nieliniowości modelu.

Przeprowadzono analizę statystyczną dla wprowadzonych dodatkowo parametrów, a jej wyniki zostały przedstawione w tabeli 7. Zmienne D_1 i D_2 charakteryzują się szerokim zakresem wartości, co jest szczególnie widoczne dla wartości minimalnych i maksymalnych. Z kolei wartości zmiennej D_3 są bardziej skoncentrowane, z mniejszą zmiennością tych danych.

Tabela 7. Analiza statystyczna dodatkowo wprowadzonych zmiennych

Parametr	Minimum	25%	50%	75%	Maximum
D_1	0.008391	3.460397	7.458046	12.963891	29.044929
D_2	0.002874	3.801763	7.051316	11.197266	35.032219
D_3	0.283523	0.700088	0.929429	1.117552	1.581113

Po wprowadzeniu dodatkowych parametrów dokonano analizy korelacji oraz zależności pomiędzy wprowadzonymi parametrami. Na mapie cieplnej korelacji zaprezentowanej na rysunku 24 przedstawiono oczekiwane zależności, tj. wprowadzone parametry są skorelowane z podstawowymi, które składają się na dodane do zbioru danych zmienne.



Rysunek 24. Mapa cieplna korelacji

Jak wskazuje powyższa mapa korelacji, dla wymienionych uprzednio parametrów można zaobserwować, że istnieje silna, pozytywna korelacja pomiędzy D_3 a τ . Istnieje ponadto umiarkowana pozytywna korelacja pomiędzy odstępem, a zmienną D_1 , a także pomiędzy D_2 a R_2 . Dodatkowo można zauważyć, że słaba pozytywna korelacja występuje pomiędzy D_2 a odstępem. Jak w przypadku podstawowych parametrów przeprowadzono analizę liniowości zależności oraz ocenę konieczności linearyzacji, co przedstawiono w tabeli 8.

Tabela 8. Linearyzacja dodatkowych parametrów

Parametr	Linearyzacja
D_1	brak
D_2	$y = 99.413x^2 - 3764.2x + 43333$
D_3	brak

Po wprowadzeniu dodatkowych zmiennych opracowano kolejne modele regresji liniowej, a uzyskane wyniki zaprezentowano w tabeli 9.

Tabela 9 Wyniki modeli regresji liniowej w oparciu o podstawowe i dodatkowe parametry

	MAE	MSE	RMSE	R2 Square
Regresja Hubera	8828.285	680933415.195	26094.700	0.39257
Regresja grzbietowa	10077.5365	589209727.685	24273.6426	0.47439
Theil-Shein	8910.8743	651124549.593	25517.1422	0.41916
Regresja Lasso	10080.9795	589223030.837	24273.9166	0.47438
Elastic Net	9978.86188	592971987.0727	24351.0161	0.47103

Modele regresji liniowej opracowane na podstawie następujących parametrów: rozmiar, odstęp, τ , q , R_1 , R_2 , D_1 , D_2 , D_3 uzyskały nieznacznie lepsze rezultaty niż w przypadku modeli opracowanych na podstawie podstawowych parametrów.

Po analizie otrzymanych wyników za punkt odniesienia można przyjąć wartość współczynnika determinacji R^2 uzyskanego dla regresji grzbietowej zarówno dla modelu opracowanego na podstawie podstawowych parametrów, jak i modelu z dodatkowo wprowadzonymi zmiennymi. Jest to R^2 0.47439 dla modelu o rozszerzonych parametrach

i 0.47416 dla modelu na podstawie podstawowych parametrów. Jak zakładano, wyniki te nie są imponujące, jednakże mają istotne znaczenie jako punkt odniesienia. Stanowią one podstawę do oceny i porównywania kolejnych modeli.

7.2. MODELE BAZOWE DLA DRUGIEGO ZBIORU DANYCH

Po niezbędnych przekształceniach opracowano modele bazowe, stanowiące punkt odniesienia do dalszych analiz. W tym celu wykorzystano regresje Hubera, Ridge, Theil-Shein, Lasso oraz Elastic Net. W tabeli 10 przedstawiono wyniki dla modeli opracowanych na podstawie pierwszej grupy parametrów, tj.: rozmiar, odstęp, τ , q , R_1 , R_2 .

Tabela 10. Modele regresji liniowej opracowane na podstawie drugiego zbioru danych i pierwszej grupy parametrów

	MAE	MSE	RMSE	R^2
Regresja Hubera	2560.584	77341318.290	8794.391	0.1229
Regresja Ridge	4282.158	69377672.779	8329.326	0.2132
Theil-Shein	2602.162	75321346.9224	8678.787	0.1458
Regresja Lasso	4282.052	69376262.373	8329.241	0.2132
Elastic Net	4323.417	69543974.750	8339.303	0.2113

Z analizy danych przedstawionych w tabeli 10 wynika, że regresja Ridge oraz regresja Lasso osiągnęły najlepsze wyniki pod względem R^2 . Oba modele mają również najniższe RMSE. Regresja Hubera ma najwyższe wartości MSE i RMSE oraz najniższe R^2 , co wskazuje na najslabsze dopasowanie do danych spośród porównywanych modeli. Tymczasem warto zaznaczyć fakt, że modele te nie osiągają wartości R^2 powyżej 22%, co po pierwsze nie jest satysfakcjonującym wynikiem, a po drugie przewidywania te są znacznie gorsze niż w przypadku zbioru danych, gdzie występowały zachowania niekooperatywne.

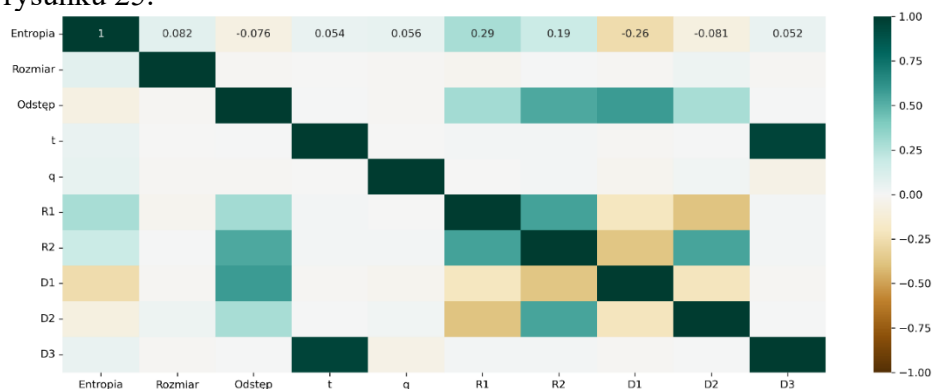
Poza tym do drugiego zbioru danych, wzorem pierwszego, zostały wprowadzone dodatkowe parametry D_1 , D_2 , D_3 , które mają pomóc w lepszym uchwyceniu zależności w zachowaniu roju bezzałogowych

statków powietrznych. Analiza statystyczna dla tych parametrów w drugim zbiorze danych została przedstawiona w tabeli 11.

Tabela 11. Analiza statystyczna dodatkowo wprowadzonych parametrów w zbiorze danych dot. zachowań kooperatywnych

Parametr	Średnia	Odczylenie standardowe	min.	25%	50%	75%	max.
D ₁	8.856	6.560	0.0022	3.656	7.254	12.930	29.466
D ₂	7.796	5.694	0.0009	3.497	6.701	10.774	32.768
D ₃	0.914	0.271	0.294	0.710	0.924	1.121	1.582

Opracowano również mapę korelacji, która została przedstawiona na rysunku 25.



Rysunek 25. Mapa korelacji zmiennych w drugim zbiorze danych

Na podstawie przedstawionej mapy korelacji można wyciągnąć następujące wnioski dotyczące sposobu korelacji zmiennych w zbiorze danych. R₁ to zmienna o najwyższej dodatniej korelacji z entropią. Im wyższa wartość tego parametru, tym wyższa wartość entropii krzyżowej. Słabą dodatnią korelację z entropią krzyżową wykazuje parametr R₂. Z kolei parametr D₁ to zmienna o najwyższej ujemnej korelacji z entropią krzyżową.

Z kolei jak przedstawiono w tabeli 12, modele regresji liniowej opracowane na podstawie następujących parametrów: rozmiar, odstęp, τ ,

q, R1, R2, D1, D2, D3 uzyskały niezauważalnie nieznacznie lepsze rezultaty niż w przypadku modeli opracowanych na podstawie podstawowych parametrów. Ponownie modele te nie osiągają wartości R^2 powyżej 22%.

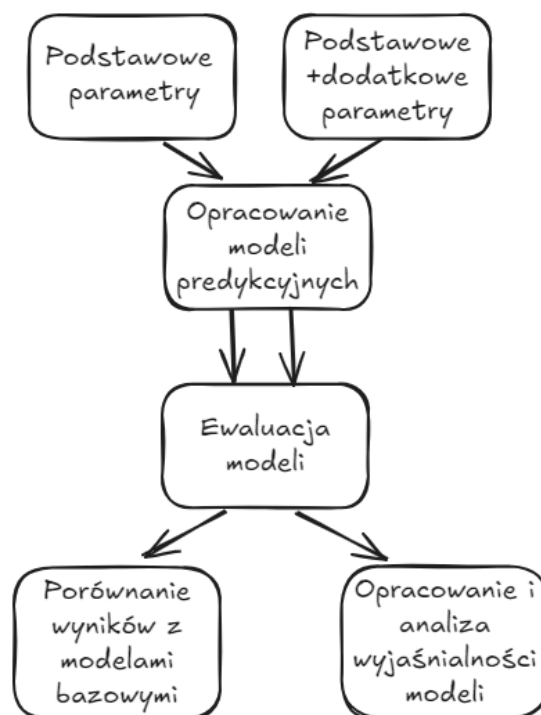
Tabela 12. Modele regresji liniowej opracowane na podstawie drugiego zbioru danych i drugiej grupy parametrów

	MAE	MSE	RMSE	R^2
Regresja Hubera	2551.6128	77254964.177	8789.480	0.1238
Regresja Ridge	4272.675	69353838.027	8327.895	0.21350
Theil-Shein	2586.353	74642534.938	8639.591	0.1535
Regresja Lasso	4272.429	69352260.700	8327.800	0.2135
Elastic Net	4336.124	69563842.896	8340.4941	0.2111

8. MODELE PREDYKCYJNE I ICH WYJAŚNIALNOŚĆ

Po ustaleniu modelu odniesienia przystąpiono do kolejnych etapów prac badawczych.

Jak wskazano na rysunku 26, pierwszym krokiem było opracowanie predykcyjnych modeli uczenia maszynowego z uwzględnieniem zarówno podstawowych, jak i rozszerzonych parametrów danych. Przyjęto, że podstawowe parametry nazywane będą pierwszą grupą parametrów, z kolei pojęcie druga grupa parametrów będzie dotyczyło podstawowych i połączonych parametrów. Następnie zgodnie z przyjętymi metrykami dokonano ewaluacji i oceny jakości modeli. W tym kontekście również porównano uzyskane wyniki z bazowym modelem odniesienia. Ostatecznym krokiem była analiza wyjaśnialności modeli za pomocą techniki SHAP (ang. Shapley Additive Explanations), co umożliwiło zrozumienie wpływu poszczególnych zmiennych wejściowych na wyniki predykcyjne modeli.



Rysunek 26. Schemat dalszych prac badawczych po ustaleniu modelu bazowego

Zgodnie z przyjętą metodologią badawczą w pierwszym etapie prac wybrano i opracowano modele uczenia maszynowego. Wśród modeli można wyróżnić następujące grupy: modele oparte na drzewach decyzyjnych Decision Tree [133], Random Forest [133] oraz te wykorzystujące dodatkowo metody gradientowe: CatBoost [134] oraz XGboost [135]. Dodatkowo wykorzystano SVR [136] oraz K-Neighbors Regressor [137]. Wszystkie wymienione modele są algorytmami uczenia nadzorowanego [138].

CatBoost jest to metoda uczenia maszynowego polegająca na wykorzystaniu zmodyfikowanego algorytmu wzmocnienia gradientu w drzewach decyzyjnych, który jest bardziej odporny na wartości odstające i zaszumione dane, w celu połączenia wielu słabych modeli w silny model predykcyjny. XGboost to również model uczenia maszynowego, wykorzystujący tradycyjny algorytm zwiększania gradientu. Drzewo decyzyjne (ang. Decision Tree) to model predykcyjny używany zarówno w klasyfikacji, jak i regresji, który operuje na zasadzie hierarchicznego podziału danych na mniejsze podzbiory, podejmując decyzje na podstawie wartości atrybutów wejściowych. Z kolei podstawową ideą lasu losowego (ang. Random Forest) jest utworzenie wielu drzew decyzyjnych, z których każde jest trenowane na losowym podzbiore danych i funkcji szkoleniowych. Celem SVR (ang. Support Vector Regression) (regresja wektorów nośnych) jest znalezienie funkcji, która może przewidzieć wartości w oparciu o zestaw cech wejściowych. Algorytm działa poprzez znalezienie hiperpłaszczyzny, która maksymalnie oddziela punkty danych w przestrzeni cech. K-Neighbors Regressor – Regresja K-najbliższych sąsiadów to algorytm, który dokonuje predykcji, znajdując K punktów danych najbliższych danym wejściowym i uśredniając ich wartości docelowe.

W kontekście tej pracy SHAP (SHapley Additive exPlanations) wykorzystuje się w odniesieniu do wyjaśnialności opracowanych modeli uczenia maszynowego w celu predykcji dezorganizacji roju dronów na podstawie parametrów roju i algorytmu antykolizyjnego, aby zrozumieć wpływ poszczególnych cech na zachowanie systemu. Wykorzystanie SHAP w tym zagadnieniu pozwala na precyzyjne określenie, jakie parametry roju oraz jakie elementy algorytmu antykolizyjnego mają największy wpływ na wartości entropii krzyżowej, co przekłada się na stabilność i organizację roju. Pozwala to również na identyfikację kluczowych czynników prowadzących do dezorganizacji.

Korzystanie z SHAP w analizie wyników modeli predykcyjnych w tym obszarze przynosi kilka korzyści. Po pierwsze, zwiększa

zrozumienie mechanizmów decyzyjnych modelu, co jest niezbędne dla optymalizacji algorytmów antykolizyjnych w zależności od konkretnych sytuacji. Po drugie, pozwala na identyfikację i redukcję ryzyka wystąpienia dezorganizacji poprzez modyfikację kluczowych parametrów roju lub ich dostosowanie. Podstawowe badania z uwzględnieniem wyjaśnialności modeli zostały zaprezentowane w pracy [139]. W prezentowanej rozprawie rozszerzono zakres badań o zarówno wyjaśnialność modeli opracowanych na podstawie drugiego zbioru danych, jak i wyjaśnialność modeli predykcyjnych stanów dezorganizacji.

Warto podkreślić, że w badaniach coraz częściej wykorzystuje się możliwość wyjaśnienia modeli sztucznej inteligencji. Jest to związane ze stopniem, w jakim człowiek może zrozumieć i wyjaśnić wewnętrzną mechanikę systemu sztucznej inteligencji/uczenia maszynowego [140]. Jak słusznie zauważono w [141], wyłącznie algorytmiczna interpretacja modelu dla poszczególnych danych nie zapewni wyjaśnienia dla zrozumienia decyzji modelu. Konieczne jest łączenie i reprezentowanie wiedzy dziedzinowej oraz jej integracja z modelem sztucznej inteligencji [142]. Popularną biblioteką [143] do osiągnięcia wyjaśnialności jest SHAP (SHapley Additive exPlanations) [144]. Jak wykazano w [145], wartości uzyskane w wyniku użycia SHAP są lepsze niż inne miary w obecności wartości odstających lub zależności cech.

8.1. MODELE PREDYKCYJNE ENTROPII KRZYŻOWEJ NA PODSTAWIE PIERWSZEGO ZBIORU DANYCH

W tabeli 13 przedstawiono zastosowane hiperparametry dla opracowanych modeli sztucznej inteligencji. Jeśli nie wskazano inaczej, przyjęto domyślne wartości hiperparametrów modeli. Warto nadmienić, że uwzględnienie poniższych parametrów podczas procesu szkolenia modeli przyniosło najlepsze rezultaty.

Tabela 13. Hiperparametry modeli

CatBoost		
Parametry	Podstawowe	Podstawowe + dodatkowe
learning rate	0.1	0.1
tree depth	10	6
L2 regularization	1	5
XGBoost		
learning rate	0.015	0.015
max depth	4	4
n_estimators	700	700
SVR		
C	10000000	
epsilon	0.001	
kernel	rbf	
Decision Tree		
max_depth	6	
Random Forest – wartości domyślne		
k-Neighbors Regressor		
n_neighbors	8	6

Do oceny opracowanych modeli uczenia maszynowego wykorzystano tak jak w modelach regresji metryki: R^2 , MAE, MSE, RMSE. Uzyskane wyniki dla omówionych grup parametrów przedstawiono w tabeli 14. Metryką oceny, którą w największym stopniu brano pod uwagę przy ocenie modeli, było R^2 . Powszechnie uznaje się, że im wyższa wartość R^2 , tym opracowany model jest lepszy.

Tabela 14. Ocena opracowanych modeli uczenia maszynowego

Model	Parametry	R ²	MAE	MSE	RSME
XGBoost	Podstawowe	0.739	5389.857	217212721.06	14738.138
	Podstawowe + dodatkowe	0.793	4738.638	172004558.38 7	13115.050
Random Forest	Podstawowe	0.682	5341.032	264883919.61 6	16275.254
	Podstawowe + dodatkowe	0.672	5065.185	273504461.56 4	16537.970
Decision Tree	Podstawowe	0.086	8798.797	762852963.98 6	27619.792
	Podstawowe + dodatkowe	-0.012	8815.587	844892473.38 6	29067.034
CatBoost	Podstawowe	0.710	5084.195	241343123.23 8	15535.222
	Podstawowe + dodatkowe	0.833	3879.535	138960432.22 1	11788.147
SVR	Podstawowe	0.634	4472.176	304696917.86 3	17455.569
	Podstawowe + dodatkowe	0.649	4370.404	292561422.11 9	17104.426
K Neighbors Regressor	Podstawowe	0.717	5921.064	235467321.07 9	15344.944
	Podstawowe + dodatkowe	0.724	6207.841	230383727.65 1	15178.396
Model odniesienia	Podstawowe	0.474	10036.884	589465088.01 0	24278.902
	Podstawowe + dodatkowe	0.4743	10077.536	589209727.68 5	24273.642


Opierając się na powyższych wynikach, można stwierdzić, że możliwe jest opracowanie predykcyjnych modeli osiągających wyższą przewidywalność niż opracowany model bazowy.

Z kolei dane zawarte w tabeli 14 wskazują, że wszystkie modele, z wyjątkiem drzewa decyzyjnego, uzyskały progres w przewidywaniach entropii krzyżowej w porównaniu z modelem bazowym. Dodatkowo jak wynika z przeprowadzonych badań, wprowadzenie dodatkowych parametrów w przypadku czterech z sześciu modeli zwiększyło skuteczność predykcji entropii krzyżowej. Najwyższy procent poprawy w stosunku do modelu bazowego osiągnięto dla modelu CatBoost oraz XGBoost opracowanych z wykorzystaniem parametrów podstawowych i dodatkowych. Warto zauważyć, że model CatBoost osiągnął również

najwyższy procent poprawy predykcji spośród modeli opracowanych na podstawie pierwszej i drugiej grupy parametrów. Dokładność predykcji modeli SVR, K Neighbors Regressor i Random Forest jest podobna niezależnie od grupy parametrów. Modele te wskazują na około 2-procentową poprawę między podstawową pierwszą grupą parametrów a drugą grupą parametrów. Mimo to osiągają wyższą dokładność predykcji – wyższe wartości R^2 niż model bazowy. Random Forest jest jedynym opracowanym modelem, w którym uzyskano lepszy wynik dla pierwszej grupy parametrów, czyli tylko parametrów roju i algorytmu antykolizyjnego bez zmiennych pochodnych.


Zgodnie z przyjętą metodologią badawczą ostatnim krokiem było opracowanie wyjaśnialności sztucznej inteligencji. Do analizy wybrano CatBoost oraz SVR (ang. Support Vector Regression). Ma to swoje uzasadnienie, gdy uwzględni się analizę uzyskanych wyników. CatBoost osiągnął najwyższy procent poprawy w porównaniu z modelem bazowym, z kolei model SVR osiągnął najniższy procent poprawy (poza Drzewem decyzyjnym). Zastosowana metoda SHAP łączy lokalne interpretacje z wartościami Shapleya [146], wynikającymi z matematycznej koncepcji teorii gier koalicyjnych. Wartość Shapleya j-tej cechy to jej udział w predykcji w porównaniu ze średnią predykcją, ważoną i sumowaną dla wszystkich możliwych kombinacji cech [147]. Celem jest określenie wkładu każdej zmiennej lub cechy w przewidywaniach modelu.

Na rysunkach 27, 28, 35, 36 przedstawiono wykresy rozkładu wartości SHAP parametrów cech dla opracowanych modeli. Na wstępie analizy wyjaśnialności modeli należy przedstawić interpretację analiz SHAP. Na osi X znajdują się wartości SHAP, które mają wpływ na wynik modelu. Na osi Y znajdują się poszczególne parametry modelu. W tym przypadku kolor niebieski oznacza niskie wartości parametru, z kolei kolorem czerwonym oznaczone są wysokie wartości cechy. Na wykresie oś Y przebiega przez punkt 0, oś tę można zatem potraktować jako punkt odniesienia. Wszystkie ujemne wartości znajdujące się na osi X będą wpływać na zmniejszenie wartości entropii krzyżowej, z kolei wszystkie dodatnie będą wpływać na jej zwiększenie.



Rysunek 27. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i pierwszej grupy parametrów.

Na rysunku 27 przedstawiono wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i z pierwszą grupą parametrów. Na podstawie powyższych danych można wskazać cechy, które mają największy wpływ na ten model, i są to kolejno: R_1 , rozmiar, odstęp. Z kolei R_2 , q oraz τ można zakwalifikować do parametrów, które w mniejszym stopniu wpływają na podjęte przez model decyzje. Można sformułować ponadto następujące ogólne zależności mające wpływ na predykcję wartości entropii krzyżowej: wysokie wartości R_1 zwiększają entropię krzyżową, natomiast niskie ją zmniejszają. Niewielki rozmiar formacji wpływa na obniżenie entropii krzyżowej. Tymczasem im większa formacja, tym wyższe wartości entropii krzyżowej. Im większy odstęp pomiędzy dronami, tym entropia krzyżowa jest mniejsza, natomiast mniejszy odstęp powoduje wyższe wartości entropii krzyżowej. Generalizując, można również stwierdzić, że wysokie wartości parametru R_2 obniżają entropię krzyżową. Z kolei dla parametrów q oraz τ nie można sformułować w tym przypadku ogólnej zależności.




Rysunek 28. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i drugiej grupy parametrów


Z kolei na rysunku 28 przedstawiono wyniki SHAP dla modelu CatBoost opracowanego na podstawie drugiej grupy parametrów. W tym przypadku ponownie parametry R_1 oraz rozmiar mają największy wpływ na decyzję modelu, z kolei kolejnymi są D_2 oraz D_1 . Jak wykazała analiza, ponownie wysokie wartości R_1 powodują wysokie wartości entropii krzyżowej, z kolei niskie – jej zmniejszenie. Oprócz tego im mniejsza różnica pomiędzy parametrami R_2 a R_1 (niskie wartości parametru D_2), tym entropia krzyżowa jest wyższa. Podobnie jak w przypadku parametru D_1 , gdy jego niskie wartości również wpływają na większe wartości entropii krzyżowej. Parametr ten odnosi się do różnicy pomiędzy odstępem a R_2 . W związku z tym im ta różnica jest mniejsza, tym entropia krzyżowa jest wyższa. W przypadku omawianego modelu parametry q oraz τ to kolejne elementy mające wpływ na wyjaśnialność modelu. Im wyższe wartości q i τ , tym niższa entropia krzyżowa.

Model Catboost opracowany na podstawie drugiej grupy parametrów uzyskał najwyższą wartość R^2 – 83,3%. W związku z tym, aby lepiej zobrazować zależności dla cech, które w największym stopniu oddziałują na model, wykonano wykresy, których rezultaty przedstawiono na rysunkach od 29 do 34. W tych przypadkach kolorem niebieskim

oznaczone są niskie wartości cechy, natomiast czerwonym – wysokie wartości. Oś Y to wartości SHAP dla danej cechy, z kolei na osi X umieszczone zostały wartości danego parametru. Analiza danych zaprezentowana na wymienionych wykresach daje możliwość opracowania ogólnych wytycznych dla zarządzających rojami.




Rysunek 29. Wykres zależności pomiędzy parametrem R_1 a wartościami SHAP



Rysunek 30. Wykres zależności pomiędzy rozmiarem formacji a wartościami SHAP


Po pierwsze jak wskazano na rysunku 29, wartości parametru R_1 w zakresie 0–20 wpływają korzystnie na zmniejszenie wartości entropii krzyżowej, a w konsekwencji – minimalizują dezorganizację roju. Z kolei entropia krzyżowa będzie się znacząco zwiększać dla wartości cechy R_1 powyżej 30. W odniesieniu do parametru, jakim jest rozmiar formacji, warto nadmienić, że oznacza on liczbę rzędów i wierszy w formacji. W związku z tym, jeśli mowa o rozmiarze 4, to formacja składa się łącznie z 16 dronów. Jak przedstawiono na rysunku 27, formacja składająca się z więcej niż 6 dronów w rzędzie ma wpływ na zwiększenie wartości entropii krzyżowej, przy czym mała liczba dronów w roju wpływa korzystnie na jej niskie wartości.

Kolejnymi parametrami o istotnym wpływie na decyzyjność modelu były D_1 oraz D_2 zmienne pochodne, dodatkowo wprowadzone do modelu na podstawie wiedzy dziedzinowej. Parametr D_2 określa różnicę pomiędzy wewnętrzną strefą bezpieczeństwa R_2 a zewnętrzną strefą bezpieczeństwa R_1 . Z kolei parametr D_1 to różnica pomiędzy odstępem a parametrem D_2 .




Rysunek 31. Wykres zależności między parametrem D_2 , a wartościami SHAP

Jak wykazała analiza wykresu przedstawionego na rysunku 31, niskie wartości parametru D_2 w przedziale 0–5 znacząco wpływają na wzrost wartości entropii. Z kolei dla wartości parametru D_2 powyżej 5 można stwierdzić, że sytuacja ta wpływa korzystnie na jej zmniejszenie. Widoczny jest wtedy zdecydowany punkt przegięcia.




Rysunek 32. Wykres zależności między parametrem D_1 , a wartościami SHAP

Parametr D_1 był kolejnym parametrem mającym znaczący wpływ na predykcję modelu. Na rysunku 32 przedstawiono wykres zależności pomiędzy tym parametrem a uzyskanymi wartościami SHAP. Wartość parametru D_1 w przedziale 0–10 zwiększa wartości entropii krzyżowej, z kolei wszystkie wartości powyżej wpływają na niskie wartości entropii krzyżowej i jednocześnie zmniejszenie dezorganizacji roju.




Rysunek 33. Wykres zależności między parametrem q a wartościami SHAP



Rysunek 34. Wykres zależności między parametrem τ a wartościami SHAP


Na rysunkach 33 i 34 przedstawiono wykresy zależności pomiędzy parametrem q oraz τ a wartościami SHAP. Ogólnie parametry te wpływają na intensywność reakcji drona. Na podstawie przedstawionych danych dla obu tych parametrów wartości poniżej 1.0 zdecydowanie wpływają na zwiększenie wartości entropii krzyżowej, z kolei powyżej przyczyniają się do uzyskania niższych wartości. Na podstawie powyższej analizy oraz wiedzy dziedzinowej można stwierdzić, że zbyt wolna reakcja dronów na występujące w obrębie formacji zakłócenia może przyczynić się do zwiększenia dezorganizacji.

Opracowano również wyjaśnialność dla modeli SVR, których rezultaty dla każdej grupy parametrów przedstawiono na rysunkach 35 oraz 36. Na model SVR opracowany na podstawie pierwszej grupy parametrów największy wpływ miały kolejno parametry: R_1 , rozmiar, odstęp, R_2 , q , τ . Z kolei dla modelu opracowanego na podstawie drugiej grupy parametrów były to: R_1 , rozmiar, D_2 , D_1 , q , odstęp, R_2 , τ , D_3 .



Rysunek 35. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu SVR opracowanym na podstawie pierwszej grupy parametrów

Dla modelu SVR opracowanego w oparciu o pierwszą grupę parametrów, podobnie jak w przypadku tożsamego modelu CatBoost, mniejsze wartości R_1 i rozmiaru formacji zmniejszają entropię krzyżową. Z kolei niskie odstęp i wartości R_2 zwiększają entropię. W przypadku tego modelu zmiany wartości parametrów q i t nie mają istotnego wpływu na model.



Rysunek 36. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu SVR opracowanym na podstawie drugiej grupy parametrów

Model SVR opracowany w oparciu o drugą grupę parametrów wskazuje, że najważniejszymi parametrami dla predykcji modelu są również: R₁ i rozmiar, D₂ i D₁. Co więcej wpływ wartości tych parametrów na wartości SHAP jest analogiczny jak w modelu CatBoost dla drugiej grupy parametrów. Analizując powyżej opisane wykresy oraz informacje uzyskane w wyniku opracowania wyjaśnialności modeli sztucznej inteligencji, można stwierdzić, że niezależnie od wartości poprawności przewidywań modelu, parametry, które najbardziej wpływają na model, są praktycznie takie same. Co więcej wprowadzenie dodatkowych zmiennych – zmiennych pochodnych – nie zawsze skutkuje zwiększoną predykcją, ale pozwala na lepsze uchwycenie zależności w roju.

W celu podsumowania wyników wytłumaczalności w przypadku zachowań niekooperatywnych opracowane zostały tabele 15 i 16, w których przedstawiono najważniejsze zależności wpływające na entropię krzyżową. Tabela 15 zawiera podsumowanie wartości SHAP i ich wpływu na model CatBoost i SVR w oparciu o pierwszą grupę

parametrów. Z kolei Tabela 16 to podsumowanie wartości SHAP i ich wpływu na model CatBoost i SVR w oparciu o drugą grupę parametrów.

Tabela 15. Podsumowanie wartości SHAP i wpływu na model CatBoost i SVR w oparciu o pierwszą grupę parametrów

Parametr	CatBoost	SVR
R_1	Niskie wartości → zmniejszenie wartości entropii krzyżowej Wysoki wpływ parametru na decyzyjność modelu	
R_2	Wysokie wartości → zmniejszenie wartości entropii krzyżowej	
	Najmniejszy wpływ parametru na decyzyjność modelu	Niski wpływ parametru na decyzyjność modelu
τ	Brak jednoznacznych relacji Niski wpływ parametru na decyzyjność modelu	Brak jednoznacznych relacji Najmniejszy wpływ parametru na decyzyjność modelu
q	Brak jednoznacznych relacji Niski wpływ parametru na decyzyjność modelu	Brak jednoznacznych relacji Najmniejszy/niski wpływ parametru na decyzyjność modelu
rozmiar	Niskie wartości → zmniejszenie wartości entropii krzyżowej Wysoki wpływ parametru na decyzyjność modelu	
odstęp	Wysokie wartości → zmniejszenie wartości entropii krzyżowej Wysoki wpływ parametru na decyzyjność modelu	

Tabela 16. Podsumowanie wartości SHAP i wpływu na model CatBoost i VR w oparciu o drugą grupę parametrów

Parametr	CatBoost	SVR
R ₁	Niskie wartości → zmniejszenie wartości entropii krzyżowej Wysoki wpływ parametru na decyzyjność modelu	
R ₂	Wysokie wartości → zwiększenie wartości entropii krzyżowej Niski wpływ parametru na decyzyjność modelu	Wysokie wartości → zwiększenie wartości entropii krzyżowej Średni wpływ parametru na decyzyjność modelu
t	Niskie wartości → zwiększenie wartości entropii krzyżowej Średni wpływ parametru	Brak znaczącego wpływu
q	Niskie wartości → zwiększenie wartości entropii krzyżowej Średni wpływ parametru	
rozmiar	Niskie wartości → zwiększenie wartości entropii krzyżowej Wysoki wpływ parametru na decyzyjność modelu	
odstęp	Wysokie wartości → zmniejszenie wartości entropii krzyżowej Średni wpływ parametru na decyzyjność modelu	
D ₁	Niskie wartości → zwiększenie wartości entropii krzyżowej Wysoki wpływ parametru na decyzyjność modelu	
D ₂	Niskie wartości → zwiększenie wartości entropii krzyżowej Wysoki wpływ parametru na decyzyjność modelu	
D ₃	Wysokie wartości → zmniejszenie wartości entropii krzyżowej Niski wpływ parametru na decyzyjność modelu	Brak znaczącego wpływu

8.2. MODELE PREDYKCYJNE STANÓW DEZORGANIZACJI NA PODSTAWIE PIERWSZEGO ZBIORU DANYCH

Chociaż głównym celem prezentowanych badań było opracowanie modeli, które dokonują predykcji dezorganizacji na podstawie entropii krzyżowej, warto również dokonać predykcji wystąpienia innych punktów stabilności, wpływających na szeroko pojęte zmiany i potencjalne zaburzenia w systemie. W kontekście tej pracy zjawiska, o których mowa, to kolizje, oscylacje oraz wibracje. Są one nieodłącznymi elementami występującymi podczas przejścia z fazy organizacji do fazy dezorganizacji. W przygotowanym zbiorze danych uwzględniono prawdopodobieństwo wystąpienia powyższych zjawisk.

W związku z tym, że badania omówione w podrozdziale 8.1, wykazały, że możliwe jest opracowanie modeli uczenia maszynowego dokonujących predykcji entropii krzyżowej, postanowiono opracować predykcyjne modele prawdopodobieństwa wystąpienia stanów stabilności: oscylacji, wibracji, kolizji oraz normalnego przelotu.

W celu opracowania modeli umożliwiających predykcję prawdopodobieństwa wystąpienia zjawisk, takich jak kolizje, oscylacje, wibracje oraz przelot normalny, ponownie jak uprzednio rozważano modele opracowane na podstawie podstawowej, jak i rozszerzonej grupy parametrów. Opracowano modele: CatBoost, XGboost, Decision Tree, Random Forest, SVR, K-Neighbors Regressor, które zostały szerzej omówione w podrozdziale 4.2 i oceniono je poprzez metryki R^2 , MAE, MSE, RSME.

W tabeli 17 zbiorczo zaprezentowano wyniki uzyskane przez modele uczenia maszynowego na podstawie pierwszej, podstawowej grupy parametrów.

Tabela 17. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia kolizji, oscylacji, wibracji i normalnego przelotu na podstawie pierwszej grupy parametrów

Model	Zmienne wyjściowe	R ²	MAE	MSE	RSME
XGBoost	P(K)	0.9019	0.0059	0.00013796	0.01174596
	P(W)	-0.0669	0.0078	0.00072099	0.02685137
	P(O)	0.9019	0.0059	0.00013796	0.01174596
	P(L)	0.9210	0.0617	0.00860970	0.09278852
Random Forest	P(K)	0.9016	0.0056	0.00013848	0.01176800
	P(W)	0.0320	0.0070	0.00065410	0.02557551
	P(O)	0.9299	0.0550	0.00689854	0.08305749
	P(L)	0.9249	0.0604	0.00818012	0.09044402
Decision Tree	P(K)	0.5759	0.0100	0.00059683	0.02443023
	P(W)	-1.0017	0.0092	0.00135264	0.03677828
	P(O)	0.7407	0.0874	0.02551554	0.15973584
	P(L)	0.7488	0.0924	0.02738171	0.1654742
CatBoost	P(K)	0.9473	0.0045	0.00007408	0.00860722
	P(W)	0.1700	0.0068	0.00056080	0.02368124
	P(O)	0.9588	0.0451	0.00405483	0.06367755
	P(L)	0.9607	0.0068	0.00056080	0.02368124
SVR	P(K)	-3.2526	0.0743	0.00598573	0.07736755
	P(W)	-12.323	0.0938	0.0090032	0.09488550
	P(O)	0.8452	0.0969	0.01523042	0.12341160
	P(L)	0.8426	0.1029	0.01715928	0.13099344
K Neighbors Regressor	P(K)	0.2262	0.0190	0,00108911	0,03300171
	P(W)	0.1265	0.0072	0.00059022	0.02429458
	P(O)	0.7906	0.1032	0.02060773	0.14355393
	P(L)	0.7649	0.1170	0.02562904	0.16009075

Jak wynika z danych zaprezentowanych w tabeli 17, modele CatBoost oraz XGBoost osiągają bardzo wysokie wyniki, co oznacza, że są w stanie dobrze przewidywać prawdopodobieństwa wystąpienia poszczególnych

zdarzeń. Ich wysokie wartości R^2 oraz niskie MAE i RMSE sugerują, że są one skuteczne w modelowaniu rzeczywistych zależności. Najgorzej w tym przypadku wypadają modele K-Neighbors Regressor oraz SVR. Należy jednak podkreślić, że wszystkie modele mają trudności z dokładnym przewidywaniem prawdopodobieństwa wibracji. Wartości R^2 są niskie, a czasem nawet ujemne, co oznacza, że modele te nie są wystarczająco precyzyjne w prognozowaniu tego zdarzenia. Wynik ten odzwierciedla wiedzę dziedzinową. Wibracje występują w obrębie formacji wówczas, gdy dany dron lub drony znajdują się blisko swoich prawidłowych pozycji, jednak w wyniku różnych czynników nie są w stanie dokładnie do nich wrócić. Taki stan może utrzymywać się stosunkowo długo, nawet przez wszystkie kroki symulacji. Prawdopodobieństwo wystąpienia wibracji jest trudniejsze do przewidzenia niż inne zjawiska, takie jak kolizje czy oscylacje. Mogą one być zależne od bardziej subtelnych i złożonych czynników, co sprawia, że modele oparte na standardowych cechach nie są w stanie dobrze ich uchwycić.

W związku z tym, że we wcześniejszych badaniach opracowywano modele na podstawie drugiej grupy parametrów, która zawiera dodatkowo wprowadzone zmienne, w tym przypadku również postanowiono opracować modele w oparciu o tę grupę, a wyniki zaprezentowano w tabeli 18.


Tabela 18. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia kolizji, oscylacji, wibracji i normalnego przelotu na podstawie drugiej grupy parametrów

Model	Zmienne wyjściowe	R ²	MAE	MSE	RSME
XGBoost	P(K)	0.9137	0.00564	0.000121	0.0110205
	P(W)	0.0702	0.00676	0.0006282	0.0250651
	P(O)	0.9437	0.04777	0.0055415	0.0744415
	P(L)	0.9564	0.0460295	0.0047439	0.0688766
Random Forest	P(K)	0.9029	0.0055769	0.0001366	0.0116889
	P(W)	0.2264	0.0063351	0.0005227	0.0228630
	P(O)	0.9384	0.046687	0.006063	0.0778685
	P(L)	0.9386	0.050697	0.006691	0.0817985
Decision Tree	P(K)	0.7351	0.008060	0.000372	0.0193062
	P(W)	-0.1363	0.006890	0.000767	0.0277106
	P(O)	0.8324	0.070353	0.016488	0.1284092
	P(L)	0.8396	0.073531	0.017481	0.1322190
CatBoost	P(K)	0.9542	0.004259	0.000064	0.0080205
	P(W)	0.3368	0.005958	0.000448	0.0211684
	P(O)	0.9720	0.035133	0.002752	0.0524662
	P(L)	0.9751	0.035877	0.002705	0.0520127
K Neighbors Regressor	P(K)	0.2049	0.019699	0.001119	0.0334522
	P(W)	0.7889	0.103515	0.020778	0.1441472
	P(O)	0.7889	0.103515	0.020778	0.1441472
	P(L)	0.7625	0.117767	0.025883	0.1608833

Ponownie można mówić o sytuacji, gdy wszystkie z opracowanych modeli mają trudności z dokładnym przewidywaniem prawdopodobieństwa wibracji, jednak większość modeli odnotowała wzrost wartości R^2 w porównaniu z tymi osiągniętymi w przypadku modeli opracowanych wyłącznie z wykorzystaniem podstawowych parametrów. CatBoost i XGBoost to modele, które konsekwentnie osiągają najlepsze wyniki zarówno przed, jak i po dodaniu dodatkowych parametrów. Modele te są bardziej zaawansowane pod względem algorytmicznym, co pozwala im lepiej radzić sobie z większą liczbą zmiennych i bardziej złożonymi wzorcami w danych. Potwierdza się również w tym przypadku, że wprowadzenie dodatkowych zmiennych pomaga lepiej uchwycić zależności, które występują w roju, powodując poprawienie modeli predykcyjnych.

W celu identyfikacji cech, które w największym stopniu wpływają na przewidywane prawdopodobieństwa, tak jak w poprzednich przypadkach opracowano wyjaśnialność SHAP, aczkolwiek skupiono się na najlepszym modelu, jakim został Catboost. Wyniki dla obu grup parametrów przedstawiono na rysunkach 37–42, gdzie na osi X znajdują się wartości SHAP, które mają wpływ na wynik modelu. Na osi Y znajdują się poszczególne parametry modelu. W tym przypadku kolor niebieski oznacza niskie wartości parametru, z kolei kolorem czerwonym oznaczone są wysokie wartości cechy. Na wykresie oś Y przebiega przez punkt 0, oś tę można zatem potraktować jako punkt odniesienia. Wszystkie ujemne wartości znajdujące się na osi X będą wpływać na zmniejszenie określonego prawdopodobieństwa, z kolei wszystkie dodatnie będą wpływać na jego zwiększenie.


Na rysunkach 37 oraz 38 zaprezentowano wykresy dystrybucji wartości SHAP dla przewidywania prawdopodobieństwa kolizji dla modelu Catboost opracowanego kolejno na podstawie pierwszej oraz drugiej grupy parametrów. Zarówno w pierwszym, jak i drugim przypadku największy wpływ na decyzje modelu ma parametr q . Jak omówiono w poprzednich rozdziałach, parametr ten dotyczy intensywności reakcji drona. Na podstawie analizy wykresów dystrybucji wartości SHAP można przyjąć, że wysokie wartości q wpływają na obniżenie prawdopodobieństwa wystąpienia kolizji, z kolei niskie je zwiększają. Uwzględniając wiedzę dziedzinową, można wysunąć wniosek, że w kontekście roju dronów i aspektu unikania kolizji, kluczowa staje się intensywność reakcji. Jeśli będzie ona zbyt wolna lub nieadekwatna do zagrożenia, potencjalne ryzyko związane z kolizją będzie wzrastało.



Rysunek 37. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa kolizji $P(K)$ w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów


Analizując ponadto wykres przedstawiony na rysunku 34, można wyciągnąć następujące wnioski: im mniejsza formacja oraz im mniejszy rozmiar promienia bezpieczeństwa R_1 , tym mniejsze prawdopodobieństwo wystąpienia kolizji. Z kolei im większy rozmiar promienia bezpieczeństwa R_2 oraz im większe odstęp między dronami w roju, tym mniejsze prawdopodobieństwo wystąpienia kolizji. Poza tym im wyższe wartości parametrów τ również dotyczącego intensywności reakcji drona, tym mniejsze prawdopodobieństwo wystąpienia kolizji.

Analizując wykres przedstawiony na rysunku 35 – dla drugiej grupy parametrów, stwierdzono, że na decyzyjność modelu mają największy wpływ kolejno parametry: q , rozmiar, R_2 , odstęp, τ , D_2, D_3 , R_1 , D_1 . Dokładność modelu po wprowadzeniu dodatkowych zmiennych była nieznacznie wyższa niż modelu opracowanego na podstawie pierwszej grupy parametrów. Widoczne jest to również w analizie wyjaśnialności. Dodatkowo wprowadzone parametry, takie jak: D_2 , D_3 , D_1 , nie mają znaczącego wpływu na decyzyjność modelu. Nie występują ponadto jednoznaczne relacje dla parametrów R_1 oraz D_1 . Z kolei podobnie jak w przypadku modelu opracowanego na podstawie pierwszej grupy parametrów można wysunąć wnioski, że im mniejsza formacja, tym mniejsze prawdopodobieństwo kolizji. Oprócz tego im większe wartości parametrów R_2 , τ , D_2 , D_3 oraz im większy odstęp między dronami, tym mniejsze prawdopodobieństwo wystąpienia kolizji.




Rysunek 38. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa kolizji $P(K)$ w modelu Catboost opracowanym na podstawie drugiej grupy parametrów.

Na rysunkach 39 oraz 40 przedstawiono analizę wartości SHAP w kontekście prawdopodobieństwa wystąpienia oscylacji kolejno dla modelu opracowanego na podstawie pierwszej i drugiej grupy parametrów. W tym przypadku wpływ parametrów na decyzyjność modelu znacząco różni się w zależności od modelu. Wyniki badań przedstawionych na rysunku 36 jasno wskazują, że dla modelu opracowanego na podstawie pierwszej grupy parametrów największy wpływ na decyzyjność ma rozmiar wewnętrznego promienia R_1 . W dalszej kolejności występują: odstęp, R_2 , q , τ oraz rozmiar. W dalszej analizie wyniki można zinterpretować następująco: im mniejsza wartość parametru R_1 oraz im mniejszy rozmiar formacji, tym prawdopodobieństwo wystąpienia oscylacji jest mniejsze. Z kolei im większy odstęp oraz wartości parametrów R_2 , q , τ , tym mniejsze prawdopodobieństwo wystąpienia oscylacji.




Rysunek 39. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów

Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów przedstawiony na rysunku 37 wskazuje, że największy wpływ na decyzyjność modelu ma dodatkowo wprowadzony parametr D_2 , który wskazuje na różnicę pomiędzy promieniem R_2 a R_1 . Wysokie wartości D_2 wpływają na zmniejszenie prawdopodobieństwa wystąpienia oscylacji. W praktyce oznacza to, że im większa różnica pomiędzy promieniem strefy zewnętrznej R_2 a promieniem strefy wewnętrznej R_1 , tym mniejsze prawdopodobieństwo wystąpienia oscylacji. Idąc dalej, stwierdzono, że im niższe wartości promienia R_1 , tym mniejsze prawdopodobieństwo wystąpienia oscylacji, co oznacza, że promień R_2 powinien być odpowiednio większy. Poza tym im mniejsza formacja, tym mniejsze prawdopodobieństwo oscylacji. Opierając się na omawianych wynikach, można stwierdzić, że wysokie wartości parametrów D_2 , q , D_1 , odstęp, τ , D_3 wpływają na zmniejszenie prawdopodobieństwa oscylacji.




Rysunek 40. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów

Kolejnym analizowanym zjawiskiem jest prawdopodobieństwo wystąpienia wibracji. Jest to zagadnienie złożone, a wyniki predykcji wystąpienia tego stanu stabilności są niezadowalające. Jednak w celu zrozumienia dynamiki tego zjawiska postanowiono dokonać analizy wartości SHAP dla modeli opracowanych na podstawie obu grup parametrów, co przedstawiono na rysunkach 41 oraz 42. Analiza wykresu dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji P(W) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów wskazuje, że najważniejszym parametrem wpływającym na decyzjność modelu w tym przypadku jest odstęp pomiędzy dronami w roju. Z kolei kolejnymi są parametry: R_1 , q , τ , R_2 oraz rozmiar. Uzyskane dane pozwalają ponadto wywnioskować, że im większy odstęp pomiędzy dronami w roju, tym mniejsze prawdopodobieństwo wystąpienia wibracji. Im niższa wartość parametru R_1 oraz im mniejszy rozmiar formacji, tym mniejsze prawdopodobieństwo wystąpienia wibracji. Złożoność zagadnienia wibracji znajduje potwierdzenie braku występowania jednoznacznych relacji pomiędzy pozostałymi parametrami. Aczkolwiek opracowanie wyjaśnialności dostarczyło cennych informacji.



Rysunek 41. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji $P(W)$ w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów


W świetle uzyskanych wyników przedstawionych na rysunku 41 można stwierdzić, że odległość pomiędzy dronami w roju jest najbardziej istotna dla decyzyjności modelu opartego na drugiej grupie parametrów. Im większe odległości pomiędzy dronami w roju, tym mniejsze prawdopodobieństwo wibracji. Następnie parametrami, mającymi wpływ na decyzyjność modelu, są kolejno: D_2 , R_1 , q , D_1 , R_2 , D_3 , rozmiar formacji oraz τ . Kolejnymi zależnościami, które można zidentyfikować, są: im mniejsza wartość parametrów D_2 oraz D_1 , tym wyższe prawdopodobieństwo wystąpienia wibracji. Im większa formacja, tym większe prawdopodobieństwo oscylacji. Dla pozostałych parametrów nie można określić jednoznacznych relacji.




Rysunek 42. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji P(W) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów.

Ostatnim analizowanym stanem jest prawdopodobieństwo przejścia drona intruza, oznaczone jako P(L). Jak wskazują dane przedstawione na rysunku 43, im mniejszy promień R_1 oraz im mniejsza liczba dronów w formacji, tym wyższe prawdopodobieństwo przelotu drona intruza, który nie wywołuje zaburzeń w obrębie formacji. Idąc dalej, zauważyć można, że im większy odstęp pomiędzy dronami w roju oraz im wyższe wartości parametrów q , R_2 , τ , tym większe prawdopodobieństwo przelotu drona intruza.

Analizując dane wartości SHAP na rysunku 44 dla modelu opracowanego w oparciu o drugą grupę parametrów, można stwierdzić, że parametrami mającymi wpływ na decyzyjność modelu są kolejno: D_2 , R_1 , q , D_1 , τ , rozmiar, odstęp, D_3 oraz R_2 . Zwiększenie prawdopodobieństwa przelotu można uzyskać poprzez zastosowanie wyższych wartości q , τ czy odstępu pomiędzy dronami w roju oraz zmniejszenie rozmiaru formacji oraz promienia R_1 . Istotnym faktem są ponadto wartości dodatkowo wprowadzonych zmiennych, gdzie obserwuje się, że im większe wartości parametrów D_2 , D_1 oraz D_3 , tym większe prawdopodobieństwo przelotu.



Rysunek 43. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa przejścia drona intruza P(L) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów



Rysunek 44. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa przejścia drona intruza P(L) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów

Dodatkowo dokonano porównania wyników wyjaśnialności dla entropii krzyżowej oraz prawdopodobieństwa wystąpienia wprowadzonych w formalizacji stanów dezorganizacji, jakimi są: wibracje, kolizje oraz oscylacje. Rezultaty analizy przedstawiono w tabeli 19. W tym przypadku pod uwagę wzięto wyłącznie podstawowe parametry.

Tabela 19. Porównanie wyników wyjaśnialności modeli Catboost w oparciu o pierwszą grupę parametrów

Parametr	P(K)	P(O)	P(W)	Entropia krzyżowa
R_1	Im niższe wartości R_1 , tym mniejsze prawdopodobieństwo wystąpienia kolizji	Im niższe wartości R_1 , tym mniejsze prawdopodobieństwo wystąpienia oscylacji	Brak możliwości określenia jednoznacznych zależności	Im niższe wartości R_1 , tym mniejsze wartości entropii krzyżowej i poziom dezorganizacji
Rozmiar	Im mniejszy rozmiar formacji, tym mniejsze prawdopodobieństwo kolizji	Im mniejszy rozmiar formacji, tym mniejsze prawdopodobieństwo oscylacji	Im mniejszy rozmiar formacji, tym mniejsze prawdopodobieństwo wibracji	Im mniejszy rozmiar formacji, tym mniejsze wartości entropii krzyżowej i poziom dezorganizacji
Odstęp	Im większy odstęp pomiędzy	Im większy odstęp pomiędzy	Im większy odstęp pomiędzy	Im większy odstęp pomiędzy

	dronami w roju tym mniejsze prawdopodo- bieństwo kolizji	dronami w roju tym mniejsze prawdopodo- bieństwo wystąpienia oscylacji	dronami w roju tym mniejsze prawdopodo- bieństwo wibracji	dronami w roju tym mniejsze wartości entropii krzyżowej i poziom dezorganizacji
R_2	Im większy rozmiar promienia bezpieczeń- stwa R_2 , tym mniejsze prawdopodo- bieństwo wystąpienia kolizji	Im większy rozmiar promienia bezpieczeń- stwa R_2 , tym mniejsze prawdopodo- bieństwo wystąpienia oscylacji	Brak możliwości określenia jednoznacz- nych zależności	Im większy rozmiar promienia bezpieczeń- stwa R_2 , tym mniejsze wartości entropii krzyżowej i poziom dezorganizacji
q	Im wyższe wartości q , tym mniejsze prawdopodo- bieństwo wystąpienia kolizji	Im wyższe wartości q , tym mniejsze prawdopodo- bieństwo wystąpienia oscylacji	Brak możliwości określenia jednoznacz- nych zależności	Brak możliwości określenia jednoznacz- nych zależności, aczkolwiek rozszerzona analiza wskazuje, że

				im wyższe wartości q , tym mniejsze wartości entropii krzyżowej
τ	Im większe wartości τ , tym mniejsze prawdopodobieństwo wystąpienia kolizji	Im większe wartości τ , tym mniejsze prawdopodobieństwo wystąpienia oscylacji	Brak możliwości określenia jednoznacznych zależności	Brak możliwości określenia jednoznacznych zależności, aczkolwiek rozszerzona analiza wskazuje, że im wyższe wartości τ , tym mniejsze wartości entropii krzyżowej

W związku z tym, że system istnieje w środowisku, które zaburza jego działanie poprzez wysyłanie zakłóceń w postaci intruzów, reaguje on na zakłócenia w różny sposób, w zależności od swoich parametrów. Wiadomo jest również, że w wyniku tych zdarzeń system może osiągać różne punkty stabilności. Powyższa analiza danych zawartych w tabeli 19 dostarcza cennych wskazówek dotyczących wpływu parametrów na dezorganizację roju dronów w odpowiedzi na przelot drona intruza. Niższe wartości promienia R_1 , wyznaczającego wewnętrzną strefę bezpieczeństwa, skutkują zmniejszonym prawdopodobieństwem

wystąpienia kolizji ($P(K)$) oraz oscylacji ($P(O)$). Jednocześnie zmniejszenie tego parametru powoduje niższe ryzyko wystąpienia dezorganizacji w systemie. W związku z tym można wysnuć wniosek, że rój dronów działa w sposób zorganizowany, podczas gdy wewnętrzna strefa bezpieczeństwa jest mniejsza. Analiza potwierdza również fakt, że wystąpienie kolizji czy oscylacji powoduje dezorganizację w systemie.

Warto przeanalizować parametr R_2 , czyli promień zewnętrznej strefy bezpieczeństwa. Im większy promień R_2 , tym mniejsze prawdopodobieństwo wystąpienia kolizji oraz oscylacji. Większy promień bezpieczeństwa R_2 wpływa również na zmniejszenie entropii krzyżowej, co sugeruje, że rój z większą strefą zewnętrzną jest bardziej uporządkowany i ryzyko wystąpienia dezorganizacji jest mniejsze. Poza tym biorąc pod uwagę oba parametry w kontekście zarządzania rojem, należy pójść na kompromis w zakresie ustalenia wielkości promieni bezpieczeństwa. Jeśli celem jest utrzymanie zorganizowanego systemu, należy zmniejszyć strefę R_1 kosztem zwiększenia strefy R_2 .

Zmniejszenie rozmiaru formacji dronów wpływa na obniżenie prawdopodobieństw kolizji, oscylacji oraz wibracji. W mniejszych grupach dronów łatwiej jest uniknąć niepożądanych interakcji, co wynika z ograniczonej liczby elementów w systemie. Podobnie mniejszy rozmiar formacji prowadzi do zmniejszenia wartości entropii krzyżowej, co wskazuje na bardziej zorganizowany stan systemu.

Zwiększenie odstępów pomiędzy dronami w roju skutkuje redukcją prawdopodobieństwa wystąpienia kolizji, oscylacji oraz wibracji. Większe odstępów pozwalają na bezpieczniejsze manewry, ograniczając zakłócenia wzajemne pomiędzy dronami. Jednocześnie wzrost odstępów skutkuje spadkiem entropii krzyżowej, co odzwierciedla lepszą organizację systemu, gdzie zakłócenia wewnętrzne są mniej prawdopodobne.

Analizując parametry q oraz τ związane z intensywnością reakcji drona na zmiany w otoczeniu, można wnioskować, że wyższe wartości q oraz τ prowadzą do zmniejszenia prawdopodobieństwa kolizji ($P(K)$) oraz oscylacji ($P(O)$), co wynika z bardziej intensywnych reakcji drona, który jest w stanie w lepszy sposób dostosować swoją trajektorię lotu w obliczu zakłócenia. Nie można jednak jednoznacznie określić wpływu q oraz τ na prawdopodobieństwo wibracji ($P(W)$), co wskazuje na złożoność tego zagadnienia. Choć zależność pomiędzy q i τ a entropią krzyżową nie jest jednoznaczna, rozszerzone analizy sugerują, że wyższe wartości tych parametrów mogą prowadzić do zmniejszenia entropii krzyżowej – drony reagują szybciej, co poprawia organizację systemu.

8.3. MODELE PREDYKCYJNE NA PODSTAWIE DRUGIEGO ZBIORU DANYCH (KOOPERACJA)

Po ustaleniu modeli odniesienia przystąpiono do kolejnych etapów prac badawczych, gdzie pierwszym krokiem było opracowanie predykcyjnych modeli uczenia maszynowego z uwzględnieniem zarówno podstawowych, jak i rozszerzonych parametrów danych. Wyniki dla poszczególnych modeli przedstawiono w tabeli 20. Warto nadmienić, że najlepsze rezultaty uzyskano z zastosowaniem domyślnych hiperparametrów modeli.

Tabela 20. Wyniki modeli uczenia maszynowego opracowane na podstawie drugiego zbioru danych

Model	Parametry	R ²	MAE	MSE	RSME
XGBoost	Podstawowe	0.4423	2987.924	202606458.5	14233,989
	Podstawowe + dodatkowe	0.8265	1967.422	63020548.03	7938,548
Random Forest	Podstawowe	0.3968	3017.610	219166317.7	14804.266
	Podstawowe + dodatkowe	0.7857	2049.695	77851392.55	8823.343
Decision Tree	Podstawowe	0.1841	3978.806	296419451.1	17216.836
	Podstawowe + dodatkowe	0.7699	2582.310	83589490.49	9142.728
CatBoost	Podstawowe	0.5073	2739.874	179009336.4	13379.437
	Podstawowe + dodatkowe	0.8370	1748.951	59221742	7695.566
SVR	Podstawowe	0.0597	3649.308	341623032.3	18483.047
	Podstawowe + dodatkowe	0.0748	3586.672	336161461.1	18334.706
K Neighbors Regressor	Podstawowe	0.4898	3101.957	185367187	13614.961
	Podstawowe + dodatkowe	0.5660	2963.473	157667592	12556.575

Analiza wyników wskazuje, że wszystkie modele, z wyjątkiem drzewa decyzyjnego oraz SVR, uzyskały progres w przewidywaniach entropii krzyżowej w porównaniu z modelem bazowym. Dodatkowo jak wynika z przeprowadzonych badań, wprowadzenie dodatkowych parametrów D₁, D₂ oraz D₃ przyczyniło się do znaczącej poprawy

predykcji modeli w przypadku wszystkich pięciu z sześciu modeli. Aczkolwiek poprawę odnotowano także dla najgorszego modelu SVR. Ciekawą obserwacją jest również to, że najwyższy procent poprawy predykcji pomiędzy modelami opracowanymi na podstawie pierwszej i drugiej grupy parametrów osiągnęły kolejno modele Decision Tree, Random Forest oraz XGBoost. Z kolei najwyższy procent poprawy w stosunku do modelu bazowego osiągnięto dla modelu CatBoost oraz XGBoost opracowanych w oparciu o drugą grupę parametrów.

Warto również porównać wyniki dla dwóch najlepszych modeli predykcyjnych entropii krzyżowej. Jak przedstawiono w tabeli 21 modele opracowane na podstawie pierwszej grupy parametrów dla zachowań kooperatywnych, cechują się zdecydowanie niższą jakością predykcji w porównaniu z tożsamymi modelami dla zachowań niekooperatywnych. Wskazuje to na istotną różnicę pomiędzy tymi systemami, a także różnicę w strukturze danych między zachowaniami kooperatywnymi a niekooperatywnymi, co może sugerować odmienność mechanizmów decyzyjnych. Modele opracowane dla zachowań niekooperatywnych zdają się lepiej wychwytywać wzorce, co może wynikać z większej jednoznaczności lub przewidywalności tych zachowań. Z kolei niższa jakość predykcji w przypadku zachowań kooperatywnych może sugerować większą zmienność w sposobie podejmowania decyzji, które trudniej uchwycić za pomocą standardowych parametrów użytych w modelach. Wskazuje to na słuszność wprowadzenia dodatkowych zmiennych modelu, które lepiej odwzorowały system, gdzie występowały zachowania kooperatywne. Potwierdzają to poniższe dane, które wskazują, że po wprowadzeniu dodatkowych zmiennych modele osiągają predykcję porównywalną, a nawet lepszą w przypadku zachowań kooperatywnych.


Tabela 21. Porównanie predykcji entropii krzyżowej najlepszych modeli dla obu zbioru danych

	Zachowania niekooperatywne		Zachowania kooperatywne	
	Pierwsza grupa parametrów – R^2	Druga grupa parametrów – R^2	Pierwsza grupa parametrów – R^2	Druga grupa parametrów – R^2
Catboost	0,7108	0,8335	0,5073	0,8370
XGboost	0,7397	0,7939	0,4423	0,8265

Zgodnie z przyjętą na początku metodologią badawczą również dla zbioru danych dotyczących zachowań kooperatywnych dla modelu Catboost opracowano analizę wyjaśnialności z wykorzystaniem metody SHAP (SHapley Additive exPlanations), aby lepiej zrozumieć wkład poszczególnych zmiennych w podejmowanie decyzji modelu predykcyjnego. Wyniki przedstawiono na wykresach znajdujących się na rysunkach 45 dla modelu opartego na pierwszej grupie parametrów oraz 46 dla drugiej grupy parametrów.


Analiza SHAP jest istotna również w kontekście zachowań kooperatywnych, gdzie zrozumienie działania systemu pod wpływem innego typu zakłócenia jest istotne w kontekście analizy dezorganizacji.

Na osi X znajdują się wartości SHAP, które mają wpływ na wynik modelu. Na osi Y znajdują się poszczególne parametry modelu. W tym przypadku kolor niebieski oznacza niskie wartości parametru, z kolei kolorem czerwonym oznaczone są wysokie wartości cechy. Na wykresie oś Y przebiega przez punkt 0, oś tę można zatem potraktować jako punkt odniesienia. Wszystkie ujemne wartości znajdujące się na osi X będą wpływać na zmniejszenie wartości entropii krzyżowej, z kolei wszystkie dodatnie będą wpływać na jej zwiększenie.



Rysunek 45. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i pierwszej grupy parametrów dla zachowań kooperatywnych


Jak przedstawiono na wykresie znajdującym się na rysunku 45, kolejność wpływu parametrów na decyzyjność tego modelu to: R_1 , odstęp, R_2 , rozmiar, q oraz τ . Parametr R_1 można uznać za ten, który ma największy wpływ na decyzyjność modelu, analogicznie do modelu opracowanego na podstawie zachowań niekooperatywnych. Wysokie wartości R_1 zwiększają entropię krzyżową, natomiast niskie wartości tego parametru wpływają na jej zmniejszenie. Kolejną cechą mającą znaczący wpływ na decyzyjność modelu jest odstęp pomiędzy dronami w roju. Im mniejszy, tym większa entropia krzyżowa. Dodatkowo jednoznaczny wniosek, który można wysnuć, dotyczy wartości promienia R_2 , im większy, tym większe wartości entropii krzyżowej i dezorganizacji. Niewielki rozmiar formacji wpływa ponadto na obniżenie entropii krzyżowej. Tymczasem im większa formacja, tym wyższe wartości entropii krzyżowej. Z kolei dla parametrów q oraz τ nie można sformułować w tym przypadku ogólnych zależności. Warto zaznaczyć, że pomimo zmiany typu zakłócenia oraz zauważalnie niższej jakości predykcji na decyzyjność modelu największy wpływ ma parametr R_1 , tak jak w przypadku zakłóceń w postaci drona intruza, charakteryzującego się brakiem zachowań kooperatywnych.



Rysunek 46. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i drugiej grupy parametrów dla zachowań kooperatywnych


Na rysunku 46 przedstawiono wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i drugiej grupy parametrów dla zachowań kooperatywnych. Omawiana analiza wskazuje, że na decyzyjność powyższego modelu w największym stopniu wpływają parametry D_1 oraz D_2 . Następnie kolejne parametry to rozmiar, R_1 , R_2 , q , odstęp, D_3 oraz τ . Jest to sytuacja odmienna w porównaniu z modelem w oparciu o zachowania niekooperatywne, gdzie największy wpływ na decyzyjność modelu miał R_1 , rozmiar, a dopiero w dalszej kolejności D_2 i D_1 . Ma to również swoje uzasadnienie w poprawie jakości predykcji po dodaniu dodatkowo wprowadzonych parametrów. Im mniejsza wartość parametru D_1 oraz D_2 , tym wyższa wartość entropii krzyżowej i dezorganizacji w formacji roju dronów. Z kolei im większa formacja, a także wielkość promienia R_1 oraz R_2 oraz im mniejszy odstęp, tym wyższa wartość entropii krzyżowej i dezorganizacji. Z kolei dla parametrów q , D_3 oraz τ nie można sformułować w tym przypadku ogólnych zależności. Powyższa analiza wyjaśnialności potwierdza, że wprowadzenie dodatkowych parametrów wpływa nie tylko na decyzyjność modelu, ale także na zwiększenie jakości predykcji.

W celu pogłębienia analizy dotyczącej wpływu wartości parametrów modelu na wartości SHAP opracowano wykresy, które zostały przedstawione na rysunkach od 47 do 52. W przypadku wspomnianych wykresów kolorem niebieskim oznaczone są niskie wartości cechy, natomiast czerwonym wysokie wartości, na osi X umieszczono odpowiednie wartości. Z kolei oś Y to wartości SHAP dla danej cechy. Analiza danych zaprezentowana na wymienionych wykresach daje możliwość opracowania ogólnych wytycznych dla zarządzających rojami w zakresie zachowań kooperatywnych, ale także dostarcza cennych informacji w kontekście porównania dwóch systemów o odmiennych zakłóceniach.




Rysunek 47. Wykres zależności między rozmiarem, a wartościami SHAP

Jak przedstawiono na rysunku 47, w przypadku zachowań kooperatywnych liczba dronów większa niż 4 drony w rzędzie ma wpływ na zwiększenie entropii krzyżowej, a w konsekwencji – na zwiększenie dezorganizacji w roju. Z kolei im mniejsza liczba dronów w roju, tym mniejsza dezorganizacja.




Rysunek 48. Wykres zależności między parametrem R_1 a wartościami SHAP

Z kolei w odniesieniu do parametru, jakim jest rozmiar promienia R_1 wewnętrznej strefy bezpieczeństwa, na podstawie analizy wykresu zależności pomiędzy tym parametrem a wartościami SHAP, jak przedstawiono na rysunku 48, stwierdzono, że entropia krzyżowa stopniowo będzie się zwiększać powyżej wartości 24. Wartości tego parametru poniżej 20 będą natomiast skutkowały obniżaniem wartości entropii krzyżowej oraz niższym ryzykiem dezorganizacji systemu.



Rysunek 49. Wykres zależności między parametrem D_1 a wartościami SHAP


Analizując dodatkowo wprowadzony parametr D_1 (rysunek 49), który w największym stopniu wpływa na decyzyjność modelu, obserwuje się wyraźny punkt przegięcia na poziomie wartości 4. Każda wartość poniżej 4 będzie wpływała na znaczące zwiększenie entropii krzyżowej, a tym samym na wzrost dezorganizacji systemu. Z kolei wszystkie wartości powyżej będą pozytywnie wpływały na zmniejszenie entropii krzyżowej. Warto przypomnieć, że parametr D_1 stanowi różnicę pomiędzy odstępem a wielkością promienia R_2 . Im mniejsza różnica pomiędzy nimi, tym większa dezorganizacja systemu.




Rysunek 50. Wykres zależności między parametrem D_2 a wartościami SHAP

Kolejnym parametrem mającym wysoki wpływ na decyzyjność modelu jest dodatkowo wprowadzony parametr D_2 . Określony jest jako różnica pomiędzy dwoma promieniami bezpieczeństwa: R_2 określającym zewnętrzną strefę bezpieczeństwa i R_1 wyznaczającym wewnętrzną strefę bezpieczeństwa. Jak przedstawiono na rysunku 50, wartości od 0 do 3/3.5 wpływają na zwiększenie wartości entropii krzyżowej. Z kolei im większa różnica pomiędzy tymi parametrami, tym mniejsza dezorganizacja systemu. Podobnie jak w przypadku parametru D_1 zauważalne jest charakterystyczne przegięcie, gdzie widoczny jest wzrost dezorganizacji.

Chociaż parametry q i τ nie mają istotnego wpływu na decyzyjność modelu, postanowiono zbadać zależność pomiędzy nimi a wartościami SHAP w celu zidentyfikowania różnic lub podobieństw w omawianych systemach. Cechy te ponadto są związane z intensywnością reakcji drona na pojawiające się zakłócenia.



Rysunek 51. Wykres zależności między parametrem τ a wartościami SHAP



Rysunek 52. Wykres zależności między parametrem q a wartościami SHAP

Jak wskazują wykresy przedstawione na rysunkach 51 oraz 52, dla parametrów τ i q nie obserwuje się istotnych punktów przegięcia, które wskazywałyby na znaczący wzrost lub spadek wartości entropii krzyżowej oraz krytycznych zmian w organizacji systemu. Warto natomiast podkreślić, że najlepszy pod względem minimalizacji dezorganizacji i utrzymania stanu organizacji jest zakres tych parametrów pomiędzy 0.8 a 1.0. Wówczas obserwuje się największe skupienie wartości SHAP blisko zera, co sugeruje, że zakres ten jest najbardziej optymalny ze względu na utrzymanie organizacji.

W celu porównania wpływu zależności pomiędzy wybranymi parametrami modelu a wartościami SHAP dla dwóch systemów charakteryzujących się różnymi zakłóceniami opracowano zestawienie porównawcze zawarte w tabeli 22.

Tabela 22. Porównanie zależności pomiędzy parametrami modelu, a wartościami SHAP dla zachowań kooperatywnych i niekooperatywnych

Parametr	Zachowania niekooperatywne	Zachowania kooperatywne
R_1	Wartości parametru w przedziale 0–20 wpływają korzystnie na zmniejszenie wartości entropii krzyżowej i zmniejszenie dezorganizacji roju. Obserwuje się znaczący wzrost entropii krzyżowej dla wartości tego parametru powyżej 30	Wartości parametru w przedziale 0–20 wpływa korzystnie na zmniejszenie wartości entropii krzyżowej i zmniejszenie dezorganizacji roju Obserwuje się wzrost entropii krzyżowej dla wartości powyżej 25. Nie jest to natomiast znaczący i gwałtowny wzrost
Rozmiar	Formacja składająca się z więcej niż 36 dronów ma wpływ na zwiększenie wartości entropii krzyżowej, przy czym mniejsza liczba dronów w roju wpływa korzystnie na jej niskie wartości	Formacja składająca się z więcej niż 16 dronów ma wpływ na zwiększenie entropii krzyżowej, przy czym mniejsza liczba dronów w roju wpływa korzystnie na jej niskie wartości
D_2	Wartości parametru D_2 w przedziale 0–5 znacząco	Wartości parametru D_2 w przedziale 0–3/3.5 znacząco

	wpływają na wzrost wartości entropii. Z kolei dla wartości powyżej 5 wpływają korzystnie na jej zmniejszenie. Dla tej wartości widoczny jest charakterystyczny punkt przegięcia	wpływają na wzrost wartości entropii. Z kolei dla wartości powyżej wymienionych wpływają korzystnie na jej zmniejszenie. Dla tej wartości widoczny jest charakterystyczny punkt przegięcia
D_1	Wartość parametru D_1 w przedziale 0–6 zwiększa wartości entropii krzyżowej, z kolei wszystkie wartości powyżej wpływają na niskie wartości entropii krzyżowej i jednocześnie zmniejszenie dezorganizacji roju	Wartość parametru D_1 w przedziale 0–4 zwiększa wartości entropii krzyżowej, z kolei wszystkie wartości powyżej wpływają na niskie wartości entropii krzyżowej i jednocześnie zmniejszenie dezorganizacji roju. Występuje charakterystyczny punkt przegięcia
q i τ	Dla obu parametrów q i τ wartości poniżej 1.0 zdecydowanie wpływają na zwiększenie wartości entropii krzyżowej, z kolei powyżej przyczyniają się do uzyskania niższych wartości	Najlepszy pod kątem minimalizacji dezorganizacji i utrzymania stanu organizacji jest zakres tych parametrów pomiędzy 0.8 a 1.0

Podsumowując uzyskane wyniki oraz analizy wyjaśnialności modeli uczenia maszynowego, można stwierdzić, że podczas zachowań kooperatywnych, gdy dron intruz oraz drony w roju mają zaimplementowane algorytmy unikania kolizji, entropia krzyżowa jest niższa niż podczas zachowań niekooperatywnych. Zmiany entropii krzyżowej są raczej ograniczone i niegwałtowne.

W kontekście analizy zachowań rojowych obserwuje się, że pomimo niższej entropii krzyżowej, a zatem mniejszego poziomu dezorganizacji system wykazuje większą wrażliwość na zmiany wartości parametrów w porównaniu z systemem z zachowaniami niekooperatywnymi. Przykładowo w przypadku zachowań kooperatywnych formacje składające się z więcej niż 16 dronów powodują wzrost entropii krzyżowej, podczas gdy dla formacji niekooperatywnych podobny wzrost

obserwuje się dopiero przy liczebności przekraczającej 36 jednostek. Oznacza to, że w przypadku struktur kooperatywnych dynamika układu zmienia się szybciej w odpowiedzi na wzrost liczby elementów, co implikuje większą złożoność i zmienność interakcji między dronami. Analogiczne zależności można zaobserwować także dla pozostałych parametrów.


8.4. MODELE PREDYKCYJNE STANÓW DEZORGANIZACJI NA PODSTAWIE DRUGIEGO ZBIORU DANYCH

W oparciu o przyjętą metodologię badawczą również w tym przypadku dokonano predykcji prawdopodobieństwa wystąpienia określonych przez model stanów stabilności systemu w środowisku, gdzie występują zakłócenia zewnętrzne w postaci drona intruza mającego zaimplementowany algorytm unikania kolizji. W tym przypadku można więc mówić o zachowaniach kooperatywnych. W tabeli 23 przedstawiono wyniki badań dla pierwszej, podstawowej grupy parametrów. Jak wynika z analizy, ponownie model Catboost charakteryzuje się najwyższą jakością predykcji dla prawdopodobieństwa wystąpienia wibracji, oscylacji, a także normalnego przelotu. Wcześniejsza statystyczna analiza zbioru danych wykazała, że w przypadku tego systemu nie są obecne kolizje. W związku z tym prawdopodobieństwo wystąpienia tego stanu nie jest poddane modelowaniu. W kontekście predykcji prawdopodobieństwa wibracji warto podkreślić, że wyniki uzyskane przez wszystkie modele z wyjątkiem modelu Decision Tree mają współczynnik determinacji wyższy niż 75%. W porównaniu z wcześniejszym systemem, gdzie mowa o zachowaniach niekooperatywnych, współczynnik determinacji dla tego stanu wynosił maksymalnie 20% dla każdego z modeli. Lepsza jakość predykcji może wynikać z charakterystyki systemu. Zachowania kooperatywne bowiem cechują się mniejszym ryzykiem wystąpienia niekorzystnych zjawisk i są bardziej przewidywalne.

Tabela 23. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia oscylacji, wibracji i normalnego przelotu na podstawie pierwszej grupy parametrów


Model	Parametr wyjściowy	R ²	MAE	MSE	RSME
XGBoost	P(W)	0.795	0.0417798	0.005245	0.0724275
	P(O)	0.874	0.0258161	0.004526	0.0672785
	P(L)	0.900	0.0449733	0.005511	0.0742382
Random Forest	P(W)	0.792	0.0405110	0.005341	0.073083
	P(O)	0.858	0.0254943	0.005092	0.071363
	P(L)	0.907	0.0410616	0.005155	0.071803
Decision Tree	P(W)	0.569	0.0526225	0.011058	0.105157
	P(O)	0.740	0.0331022	0.009336	0.096623
	P(L)	0.820	0.0534730	0.009994	0.099972
CatBoost	P(W)	0.858	0.036744	0.003631	0.060259
	P(O)	0.927	0.022152	0.002621	0.051205
	P(L)	0.932	0.037756	0.003740	0.061155
SVR	P(W)	0.828	0.039827	0.004400	0.066339
	P(O)	0.928	0.023446	0.002583	0.050824
	P(L)	0.924	0.039306	0.004213	0.064908
K Neighbors Regressor	P(W)	0.752	0.045574	0.006370	0.079814
	P(O)	0.873	0.025475	0.004548	0.067445
	P(L)	0.887	0.047014	0.006252	0.079072

Dla omawianego zbioru danych oraz dla modeli CatBoost dokonujących predykcji stanów dezorganizacji wykonano analizę wyjaśnialności za pomocą metody SHAP (SHapley Additive exPlanations), aby lepiej zrozumieć wpływ poszczególnych zmiennych na decyzje podejmowane przez model predykcyjny. Uzyskane wyniki dla zachowań kooperatywnych i pierwszej grupy parametrów zaprezentowano na wykresach zamieszczonych na rysunkach 53–58, gdzie na osi X przedstawiono wartości SHAP, które wskazują, jak poszczególne cechy wpływają na wyniki modelu. Na osi Y umieszczono konkretne parametry modelu. Kolor niebieski oznacza niskie wartości danej cechy, a czerwony odpowiada wysokim wartościom. Punkt 0 na osi Y służy jako punkt odniesienia.




Rysunek 53. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów

Jak wynika z analizy SHAP, w przypadku predykcyjnego modelu prawdopodobieństwa wystąpienia oscylacji, której rezultaty przedstawiono na rysunku 53, wpływ na decyzyjność mają kolejno parametry: R_1 , odstęp, R_2 , rozmiar, q oraz τ . Im mniejszy promień R_1 strefy bezpieczeństwa S_1 oraz im mniejszy rozmiar formacji, tym mniejsze prawdopodobieństwo wystąpienia oscylacji. Z kolei im mniejszy odstęp pomiędzy dronami, a także im mniejszy promień R_2 oraz im niższe wartości parametrów q oraz τ , tym większe prawdopodobieństwo wystąpienia oscylacji.



Rysunek 54. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji P(W) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów

Jak wynika z przeprowadzonych badań, wyjaśnialność dla modelu dokonującego predykcji prawdopodobieństwa wibracji kształtuje się w odmienny sposób. Przede wszystkim jak przedstawiono na rysunku 54 największy wpływ na predykcję ma rozmiar formacji, a następnie parametry R_1 oraz R_2 . W dalszej kolejności mniej istotnymi parametrami są odstęp, q oraz τ . Opierając się ponadto na powyższych wynikach, można stwierdzić, że niskie wartości wszystkich wymienionych parametrów wpływają na zmniejszenie prawdopodobieństwa wystąpienia wibracji. Jest to interesujący rezultat, szczególnie biorąc pod uwagę parametr, jakim jest odstęp pomiędzy dronami w roju. Z reguły im mniejszy, tym większe ryzyko wystąpienia stanów dezorganizacji, w tym wibracji. Jednak jak wynika z przedstawionych analiz, w przypadku zachowań kooperatywnych to właśnie większy odstęp może powodować wystąpienie wibracji. Zgodnie z wiedzą dziedzinową można uzasadnić ten fakt tym, że celem zakłócenia w postaci drona intruza nie jest spowodowanie znaczącej dezorganizacji. Zwiększone odstęp pomiędzy dronami mogą ponadto skutkować trudnością z powrotem na pozycje po przelocie drona intruza. Dodatkowo warto nadmienić, iż zbyt intensywne reakcje dronów w zachowaniach kooperatywnych również nie są pożądane.



Rysunek 55. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa normalnego przelotu $P(L)$ w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów

Rezultaty wartości SHAP dla predykcji prawdopodobieństwa normalnego przelotu przedstawiono na rysunku 55. Największy wpływ na ten model mają parametry: R_1 , rozmiar formacji oraz odstęp. Pozostałe


cechy takie jak R_2 , q oraz τ , są mniej istotne. Dalsza analiza wykazała, że im niższe wartości promienia R_1 oraz im mniejszy rozmiar formacji, tym większe prawdopodobieństwo normalnego przelotu. Z kolei im mniejszy odstęp i oraz promień R_2 , tym mniejsze prawdopodobieństwo normalnego przelotu. Dla parametrów q oraz τ brak jednoznacznych zależności, aczkolwiek można sformułować wniosek, że im większe wartości q , tym mniejsze prawdopodobieństwo normalnego przelotu.

W poniższej tabeli 24 zestawione zostały wyniki uzyskane przez modele uczenia maszynowego, mające na celu predykcje stanów stabilności, opracowane na podstawie drugiej grupy parametrów.

Tabela 24. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia oscylacji, wibracji i normalnego przelotu na podstawie drugiej grupy parametrów


Model	Zmienna wyjściowa	R^2	MAE	MSE	RSME
XGBoost	P(W)	0.870	0.034763	0.0033355	0.057754
	P(O)	0.942	0.017185	0.002048	0.045261
	P(L)	0.921	0.040861	0.004385	0.066222
Random Forest	P(W)	0.839	0.035958	0.004130	0.064268
	P(O)	0.931	0.018644	0.002467	0.049672
	P(L)	0.921	0.039449	0.004353	0.065977
Decision Tree	P(W)	0.658	0.049389	0.008765	0.093624
	P(O)	0.882	0.023151	0.004216	0.064936
	P(L)	0.817	0.055371	0.010173	0.100863
CatBoost	P(W)	0.918	0.029472	0.002103	0.045858
	P(O)	0.971	0.013748	0.001018	0.031919
	P(L)	0.958	0.030985	0.002280	0.047755
SVR	P(W)	0.842	0.038410	0.004052	0.063660
	P(O)	0.941	0.020286	0.002115	0.045998
	P(L)	0.931	0.037468	0.003832	0.061905
K Neighbors Regressor	P(W)	0.736	0.048532	0.006764	0.082246
	P(O)	0.886	0.023869	0.004094	0.063988
	P(L)	0.879	0.049703	0.006698	0.081844

Ponownie Catboost okazał się najlepszym modelem, gdzie współczynnik determinacji dla predykcji każdego ze stanów wyniósł więcej niż 91%.



Rysunek 56. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów

Na wykresie z rysunku 56 przedstawiono wpływ poszczególnych cech na predykcję modelu dotyczącego prawdopodobieństwa oscylacji w postaci wartości SHAP. Największy wpływ na wynik ma parametr D_2 , a następnie D_1 i R_1 . W dalszej kolejności mniej istotnymi parametrami są rozmiar, q oraz τ . Na samym końcu i zarazem najmniej istotne są cechy: odstęp, D_3 oraz R_2 . Z analizy powyższych wartości wynika również, że im mniejsza wartość parametrów: D_2 , D_1 , q , τ , odstęp i D_3 , tym większe prawdopodobieństwo wystąpienia oscylacji. Z kolei im mniejszy rozmiar formacji oraz promienie R_1 i R_2 wyznaczające strefy bezpieczeństwa, tym mniejsze prawdopodobieństwo wystąpienia oscylacji.




Rysunek 57. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji $P(W)$ w modelu Catboost opracowanym na podstawie drugiej grupy parametrów

Jak wynika z przeprowadzonych badań w zakresie wyjaśnialności modelu predykcji prawdopodobieństwa wibracji $P(W)$ przedstawionych w formie wykresu na rysunku 57, największy wpływ na decyzyjność modelu mają parametry, takie jak: rozmiar, R_1 oraz D_2 . Kolejnymi są q , D_1 oraz odstęp. τ , D_3 oraz R_2 to parametry, które mają najmniejszy wpływ na decyzyjność modelu.

Porównując dwa powyższe stany dezorganizacji, można stwierdzić, że ten sam system pod wpływem innego rodzaju zakłócenia cechuje się odmiennymi charakterystykami, a także dynamiką systemu. Zauważalna różnica występuje także w zależnościach dystrybucji wartości SHAP w kontekście parametrów modelu oraz ich wpływu na predykcję i jego decyzyjność. Po pierwsze jest to istotnie zauważalne w przypadku parametrów q , τ , odstęp oraz D_3 . W przypadku modelu dokonującego predykcji wibracji im mniejsze q oraz τ , tym mniejsze prawdopodobieństwo wystąpienia wibracji. Z kolei im większy odstęp pomiędzy dronami i większa wartość parametru D_3 , tym prawdopodobieństwo wibracji jest większe. Z kolei dla predykcyjnego modelu prawdopodobieństwa oscylacji sytuacja jest odmienna. Im

mniejsza wartość parametrów q oraz t , tym wyższe prawdopodobieństwo oscylacji. Poza tym im większy odstęp pomiędzy dronami, tym mniejsze prawdopodobieństwo oscylacji. Analogiczna zależność występuje dla parametru D_3 . Pomimo omówionych powyżej różnic podobieństwo dla obu stanów wykazują dwa parametry: rozmiar formacji oraz rozmiar promienia R_1 strefy bezpieczeństwa. Im wartości tych parametrów są mniejsze, tym mniejsze jest prawdopodobieństwo wystąpienia obu stanów.



Rysunek 58. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa normalnego przelotu $P(L)$ w modelu Catboost opracowanym na podstawie drugiej grupy parametrów

Dla predykcji prawdopodobieństwa normalnego przelotu, jak przedstawiono na wykresie z rysunku 58, można zidentyfikować następujące zależności. Po pierwsze największy wpływ na decyzyjność modelu mają parametry R_1 , rozmiar oraz D_2 . Kolejnymi są parametry: D_1 , odstęp oraz q . Najmniejszy wpływ na decyzyjność modelu mają parametry: R_2 , D_3 i τ .

W celu porównania wpływu wartości parametrów na predykcję prawdopodobieństwa normalnego przelotu dla zachowań kooperatywnych i niekooperatywnych opracowano tabelę 25.

Tabela 25. Tabela porównawcza wpływu i zależności parametrów na modele predyktywne prawdopodobieństwa normalnego przelotu dla dwóch systemów z odmiennymi typami zakłóceń

Parametr	Zachowania kooperatywne		Zachowania niekooperatywne	
	Kolejność	Zależność	Kolejność	Zależność
R_1	1	Im mniejszy, tym większe prawdopodobieństwo normalnego przejścia	2	Im mniejszy, tym większe prawdopodobieństwo normalnego przejścia
R_2	7	Brak jednoznacznych zależności	9	Brak jednoznacznych zależności
Rozmiar	2	Im mniejszy, tym większe prawdopodobieństwo normalnego przejścia	6	Im mniejszy, tym większe prawdopodobieństwo normalnego przejścia
τ	9	Brak jednoznacznie określonych zależności	5	Im większy, tym większe prawdopodobieństwo normalnego przejścia
q	6	Im większy, tym mniejsze prawdopodobieństwo normalnego przejścia	3	Im większy, tym większe prawdopodobieństwo normalnego przejścia
odstęp	5	Im większy, tym większe prawdopodobieństwo normalnego przejścia	7	Im większy, tym większe prawdopodobieństwo normalnego przejścia
D_1	4	Im większy, tym większe prawdopodobieństwo normalnego przejścia	4	Im większy, tym większe prawdopodobieństwo normalnego przejścia
D_2	3	Im większy, tym większe prawdopodobieństwo normalnego przejścia	1	Im większy, tym większe prawdopodobieństwo normalnego przejścia
D_3	8	Brak jednoznacznych zależności	8	Im większy, tym większe prawdopodobieństwo normalnego przejścia

Istotną różnicę pomiędzy systemami obserwuje się w przypadku parametrów τ i q dotyczących intensywności reakcji drona. Po pierwsze analiza wskazuje na wyraźny wpływ parametru τ dla zachowania niekooperatywnego oraz na minimalne znaczenie dla zachowania kooperatywnego. Po drugie dla zachowań niekooperatywnych im większa wartość parametru q , tym większe prawdopodobieństwo normalnego przejścia. Wskazuje to na fakt, że gdy zakłócenie w postaci drona intruza próbuje przyczynić się do zwiększenia dezorganizacji, większa intensywność reakcji jest niezbędna. Z kolei dla zachowania kooperatywnego zbyt intensywna reakcja może spowodować trudność w utrzymaniu organizacji. Poza tym pomimo różnic w istotności parametrów w kontekście decyzyjności modelu i odmiennej kolejności wpływu dla pozostałych parametrów zależności pozostają jednakowe. Na podstawie analizy powyższych wyników wnioskować można, że normalny przelot warunkowany jest tymi samymi zależnościami parametrów, a szczególnie istotne jest dostosowanie intensywności reakcji na zakłócenia.

9. PODSUMOWANIE I WNIOSKI

W rozprawie skupiono się na opracowaniu i ocenie modeli predykcyjnych, które umożliwiają analizę oraz prognozowanie dezorganizacji stacjonarnej formacji roju dronów w obliczu zakłóceń, takich jak wtargnięcie drona intruza. W tym kontekście skupiono się na stacjonarnej formacji roju dronów. Modele analizowano pod kątem kooperatywnych i niekooperatywnych zachowań zarówno roju, jak i intruza, a dodatkowo przeprowadzono analizę wyjaśnialności w celu lepszego zrozumienia wpływu poszczególnych parametrów na stopień dezorganizacji. Przeprowadzone badania umożliwiły identyfikację kluczowych parametrów wpływających na poziom dezorganizacji, co ma praktyczne znaczenie dla zarządzania ryzykiem w kontekście dezorganizacji.

Tezy pracy zostały udowodnione zgodnie z przyjętą metodologią badawczą oraz za pośrednictwem przeprowadzonych badań i analiz. Pierwsza z tez „*Dezorganizacja stacjonarnej formacji roju dronów w obliczu zakłóceń jest przewidywalna*” została udowodniona poprzez wykorzystanie wygenerowanych za pośrednictwem dwuwymiarowego symulatora dwóch zbiorów danych (podrozdziały 6.3 oraz 6.4) oraz opracowanie na ich podstawie wybranych modeli predykcyjnych, co przedstawiono w rozdziale 8. Badania przeprowadzone zostały dla określonego systemu oraz dwóch rodzajów zakłóceń w postaci pojedynczego drona, określanego mianem intruza, a dezorganizację mierzono entropią krzyżową. W jednym ze scenariuszy testowanego systemu intruz posiadał zaimplementowany algorytm antykolizyjny (zachowania kooperatywne), w drugim zaś nie był w niego wyposażony (zachowania niekooperatywne). Finalnie najlepsze modele predykcyjne dla obu typów zakłóceń uzyskały współczynnik determinacji wyższy niż 82% oraz okazały się lepsze od modeli bazowych, opracowanych w rozdziale 7. Istotnym wkładem badawczym prowadzącym do udowodnienia tej tezy było opracowanie probabilistycznego modelu systemu umożliwiającego systematyzację podejścia, przedstawionego w rozdziale 3. Ponadto podczas analizy danych pochodzących z symulacji zaobserwowano ciekawą sytuację, a mianowicie prawie chaotyczne zachowanie roju, tzn. przypadki, w których entropia krzyżowa osiąga wysokie wartości, są bliskie przypadkom o niskich wartościach, co wskazuje, że nawet niewielka zmiana przesunięcia punktu wejścia może skutkować znaczącą zmianą entropii krzyżowej.

Podstawową kwestią umożliwiającą udowodnienie kolejnej tezy „*Opracowanie i porównanie serii predykcyjnych modeli, opartych na analizie zmian entropii krzyżowej, pozwala na wyłonienie najbardziej skutecznego modelu zdolnego do precyzyjnego przewidywania stanów dezorganizacji w sytuacji wtargnięcia intruza*” było sformalizowanie pojęcia entropii krzyżowej w kontekście omawianego systemu roju dronów oraz odpowiednia implementacja tej miary w symulatorze, o czym mowa w podrozdziale 6.2. Dzięki wygenerowanym zbiorom danych, o których wspomniano powyżej w kontekście udowodnienia pierwszej z tez, możliwe było opracowanie względnie prostych regresyjnych modeli bazowych, które stanowiły punkt odniesienia dla kolejnych analiz modeli predykcyjnych. Opracowane modele obejmowały kilka rodzin modeli uczenia maszynowego: modele oparte na drzewach decyzyjnych, modele gradientowe, maszyny wektorów nośnych, a także k-najbliższych sąsiadów. Dzięki opracowaniu i porównaniu serii modeli dokonujących predykcję dezorganizacji mierzonej entropią krzyżową w oparciu o dwa zbiory danych oraz wprowadzeniu dodatkowych zmiennych, pozwalających na lepsze uchwycenie zależności w zachowaniu roju możliwe było uzyskanie najlepszego modelu, jakim w jednym i drugim przypadku okazał się CatBoost. Dzięki temu, że współczynnik determinacji dla zachowań niekooperacyjnych 0,8335 oraz dla zachowań kooperacyjnych wyniósł 0,8370 możliwe było wyłonienie najlepszych modeli, które w zadowalającym stopniu dokonują predykcji dezorganizacji. Trzecią z tez „*Przewidywanie prawdopodobieństwa wystąpienia określonych stanów dezorganizacji pozwala na identyfikację potencjalnych zagrożeń związanych z utrzymaniem formacji*” udowodniono na podstawie przyjętej metodologii badawczej. Po pierwsze, jak przedstawiono w rozdziale 3 dotyczącym formalizacji modelu roju, w systemie wyróżnia się cztery stany stabilne, w tym jeden stan organizacji, określany jako regularny oraz trzy stany dezorganizacji – wibracje, kolizje i oscylacje. Na podstawie opracowanego modelu oraz wiedzy domenowej w symulatorze zaimplementowano funkcjonalności dotyczące obliczenia prawdopodobieństw wystąpienia tych zjawisk. Jak przedstawiono w podrozdziałach 6.3 oraz 6.4, dane te zostały zawarte w wygenerowanych zbiorach danych. W podrozdziałach 8.2 oraz 8.4 przedstawiono wyniki modeli predykcyjnych dla określonych stanów stabilności. W toku badań uzyskano szczególnie zadowalające wyniki (powyżej 85%) dla prawdopodobieństwa wystąpienia kolizji oraz oscylacji dla obu zbiorów danych. Są to kluczowe stany mające

potencjalny bezpośredni wpływ na dezorganizację systemu. Ciekawych spostrzeżeń dostarczyła analiza wyników modeli dokonujących predykcję prawdopodobieństwa wibracji. Podczas gdy model predykcyjny dla zbioru danych dotyczących zachowań kooperatywnych uzyskał współczynnik determinacji R^2 równy 0,858, model w oparciu o zachowania niekooperatywne osiągnął R^2 na poziomie 0.3368. Wartość ta wskazuje, że model w niedostateczny sposób wyjaśnia zmienność danych. Bazując natomiast na uzyskanej wiedzy domenowej oraz analizie stanu dezorganizacji, jakim są wibracje, wskazuje to wysoki stopień zaawansowania tego zjawiska.

Ostatnia z tez, która dowodzi, że analiza wyjaśnialności modeli predykcyjnych umożliwia precyzyjną identyfikację parametrów mających bezpośredni wpływ na poziom dezorganizacji, została potwierdzona poprzez zastosowanie techniki SHAP (SHapley Additive exPlanations), co przedstawiono w rozdziale 8. Wprowadzono techniki wyjaśnialności w celu poszerzenia zakresu stosowalności modeli ze względu na pewne ograniczenia, takie jak punktowe predykcje. Ponadto w toku badań zidentyfikowano parametry, które po pierwsze mają wpływ na decyzyjność modeli predykcyjnych, a po drugie, zakres ich wartości ma wpływ na dezorganizację mierzoną entropią krzyżową, a także prawdopodobieństwo wystąpienia określonych stanów stabilności systemu. Finalnie pozwala to na ustalenie, jakie wartości parametrów roju i algorytmu antykolizyjnego powinny zostać dobrane, aby zminimalizować ryzyko dezorganizacji w systemie.

Ponadto w kontekście całej pracy istotny jest fakt, że wykazany został spadek błędu predykcyjnego, co sugeruje możliwość opracowania jeszcze bardziej precyzyjnych modeli w przyszłości, a w przyszłości – rozwój badań nad stabilnością formacji rojowych w zmiennych warunkach środowiskowych. Formalizacja oparta na probabilistycznym grafie z przejściami okazała się skuteczna, co sprawia, że może być z powodzeniem stosowana do badań nad innymi złożonymi systemami, w których zachodzi potrzeba modelowania multistabilnych i nieregularnych zachowań.

Zastosowana symulacja jako metoda generowania danych okazała się niezwykle efektywna w kontekście analizy zmian w strukturze roju, umożliwiając zobrazowanie niemal chaotycznych zmian roju pod wpływem intruza. Dzięki tej metodzie możliwe było przygotowanie dwóch zestawów danych – jednego dotyczącego intruza o zachowaniach niekooperatywnych, drugiego – intruza wyposażonego w algorytm unikania kolizji, który zachowuje się kooperatywnie. To rozróżnienie

umożliwiło ocenę reakcji roju na różne typy zakłóceń, co znacząco wzbogaciło analizę modelową.

Entropia krzyżowa, zastosowana jako miara dezorganizacji, okazała się odpowiednia do opisanego stopnia zaburzeń w formacji roju, pozwalając na precyzyjne oszacowanie zmian organizacyjnych w odpowiedzi na zakłócenia. Wyniki uzyskane za pomocą tej miary potwierdzają jej przydatność w analizach tego typu i sugerują możliwość jej zastosowania w dalszych badaniach nad stabilnością struktur w systemach rojowych.

W kontekście aplikowalności badań i analiz przeprowadzonych w rozprawie wyniki dotyczące procesu dezorganizacji formacji stacjonarnych rojów dronów mogą znaleźć zastosowanie w rozwoju kolejnych etapów koncepcji U-Space, co umożliwi wdrożenie zaawansowanych mechanizmów kontroli i zarządzania przestrzenią powietrzną. Zbadanie dynamiki i mechanizmów prowadzących do dezorganizacji w strukturach rojowych jest kluczowe dla identyfikacji potencjalnych zagrożeń i opracowania metod, które pozwolą na bardziej precyzyjną, bezpieczną koordynację lotów bezzałogowych statków powietrznych oraz lotów załogowych. Włączenie wyników takich badań do architektury U-Space przyczyni się do zwiększenia poziomu bezpieczeństwa poprzez minimalizację ryzyka kolizji i usprawnienie reakcji systemów na sytuacje awaryjne w zatłoczonej przestrzeni powietrznej.

BIBLIOGRAFIA

- [1] S. Javed *et al.*, “State-of-the-Art and Future Research Challenges in UAV Swarms,” *IEEE Internet Things J*, vol. 11, no. 11, pp. 19023–19045, Jun. 2024, doi: 10.1109/JIOT.2024.3364230.
- [2] “Słownik Języka Polskiego PWN.” Accessed: Oct. 27, 2024. [Online]. Available: <https://sjp.pwn.pl/sjp/dezorganizacja;2554985.html>
- [3] E. van der Maarel, “Some remarks on disturbance and its relations to diversity and stability,” *Journal of Vegetation Science*, vol. 4, no. 6, pp. 733–736, Dec. 1993, doi: 10.2307/3235608.
- [4] N. Wiener, “Cybernetics: Or Control and Communication in the Animal and the Machine,” *MIT University Press, Cambridge*, 1948.
- [5] Niklas Luhmann, *Social Systems* . 1984.
- [6] C. Gershenson and F. Heylighen, “When Can We Call a System Self-Organizing?,” 2003, pp. 606–614. doi: 10.1007/978-3-540-39432-7_65.
- [7] K. Wu, S. Zhang, and T. Wu, “The Complex Relations between Organization and Disorganization and Their Conceptual System,” *Complexity*, vol. 2021, no. 1, Jan. 2021, doi: 10.1155/2021/2907061.
- [8] A. Chaudhury, Pi-Sheng Deng, and S. Rathnam, “A computational model of coordination,” *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 26, no. 1, pp. 132–141, 1996, doi: 10.1109/3468.477868.
- [9] J. A. S. Kelso, “Coordination Dynamics,” in *Encyclopedia of Complexity and Systems Science*, New York, NY: Springer New York, 2009, pp. 1537–1565. doi: 10.1007/978-0-387-30440-3_101.
- [10] Z. Yan, N. Jouandeau, and A. A. Cherif, “A Survey and Analysis of Multi-Robot Coordination,” *Int J Adv Robot Syst*, vol. 10, no. 12, Dec. 2013, doi: 10.5772/57313.
- [11] V. Chandola, A. Banerjee, and V. Kumar, “Anomaly detection,” *ACM Comput Surv*, vol. 41, no. 3, pp. 1–58, Jul. 2009, doi: 10.1145/1541880.1541882.
- [12] K. Schultz, A. Saksena, E. P. Reilly, R. Hingorani, and M. Villafane-Delgado, “Detecting Anomalous Swarming Agents With Graph Signal Processing,” in *2021 IEEE International Conference on Autonomous*

- Systems (ICAS)*, IEEE, Aug. 2021, pp. 1–5. doi: 10.1109/ICAS49788.2021.9551164.
- [13] H. Van Dyke Parunak, “Go to the ant: engineering principles from natural multi-agent systems,” *Ann Oper Res*, vol. 75, pp. 69–101, 1997, doi: 10.1023/A:1018980001403.
- [14] S. M. Cully and T. D. Seeley, “Self-assemblage formation in a social insect: the protective curtain of a honey bee swarm,” *Insectes Soc*, vol. 51, no. 4, pp. 317–324, Nov. 2004, doi: 10.1007/s00040-004-0743-3.
- [15] J. K. Parrish, S. V. Viscido, and D. Grünbaum, “Self-organized fish schools: an examination of emergent properties,” *Biol Bull*, vol. 202, no. 3, pp. 296–305, Jun. 2002, doi: 10.2307/1543482.
- [16] C. W. Reynolds, “Flocks, herds and schools: A distributed behavioral model,” in *Proceedings of the 14th annual conference on Computer graphics and interactive techniques*, New York, NY, USA: ACM, Aug. 1987, pp. 25–34. doi: 10.1145/37401.37406.
- [17] W. R. Ashby, “Principles of the Self-Organizing Dynamic System,” *J Gen Psychol*, vol. 37, no. 2, pp. 125–128, Oct. 1947, doi: 10.1080/00221309.1947.9918144.
- [18] “The science of self-organization and adaptivity.” Accessed: Oct. 27, 2024. [Online]. Available: <https://www.eolss.net/sample-chapters/c15/E1-29-01-05.pdf>
- [19] C. Gershenson, V. Trianni, J. Werfel, and H. Sayama, “Self-Organization and Artificial Life,” *Artif Life*, vol. 26, no. 3, pp. 391–408, Sep. 2020, doi: 10.1162/artl_a_00324.
- [20] M. Mamei, R. Menezes, R. Tolksdorf, and F. Zambonelli, “Case studies for self-organization in computer science,” *Journal of Systems Architecture*, vol. 52, no. 8–9, pp. 443–460, Aug. 2006, doi: 10.1016/j.sysarc.2006.02.002.
- [21] J. Kallinikos, “The order of technology: Complexity and control in a connected world,” *Information and Organization*, vol. 15, no. 3, pp. 185–202, Jul. 2005, doi: 10.1016/j.infoandorg.2005.02.001.
- [22] N. Luhmann, *The Sociology of Risk*. de Gruyter, Berlin 1993.
- [23] Linda in contex, “Technical correspondence,” *Commun ACM*, vol. 32, no. 10, pp. 1241–1258, Oct. 1989, doi: 10.1145/67933.315999.

- [24] D. Gelernter and N. Carriero, “Coordination languages and their significance,” *Commun ACM*, vol. 35, no. 2, pp. 97–107, Feb. 1992, doi: 10.1145/129630.129635.
- [25] H.-J. Bungartz, S. Zimmer, M. Buchholz, and D. Pflüger, “Chaos Theory,” 2014, pp. 291–314. doi: 10.1007/978-3-642-39524-6_12.
- [26] M. Prokopenko, “Information dynamics at the edge of chaos: Measures, examples, and principles,” in *2013 IEEE Symposium on Artificial Life (ALife)*, IEEE, Apr. 2013, pp. 140–144. doi: 10.1109/ALIFE.2013.6602443.
- [27] L. O. Chua, “The genesis of Chua’s circuit. ,” *Berkeley, CA, USA: Electronics Research Laboratory, College of Engineering, University of California, 1992..*
- [28] R. N. Madan, *Chua’s Circuit: A Paradigm for Chaos*, vol. 1. WORLD SCIENTIFIC, 1993. doi: 10.1142/1997.
- [29] R. A. Thiétart and B. Forgues, “Chaos Theory and Organization,” *Organization Science*, vol. 6, no. 1, pp. 19–31, Feb. 1995, doi: 10.1287/orsc.6.1.19.
- [30] D. Toker, F. T. Sommer, and M. D’Esposito, “A simple method for detecting chaos in nature,” *Commun Biol*, vol. 3, no. 1, p. 11, Jan. 2020, doi: 10.1038/s42003-019-0715-9.
- [31] E. NEBE, M. L. SANNI, R. A. ADETONA, B. O. AKINYEMI, S. A. BELLO, and G. A. ADEROUNMU, “Chaos Detection and Mitigation in Swarm of Drones Using Machine Learning Techniques and Chaotic Attractors,” *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 6, 2022, doi: 10.14569/IJACSA.2022.0130656.
- [32] G. I. Sayed, G. Khoriba, and M. H. Haggag, “A novel Chaotic Equilibrium Optimizer Algorithm with S-shaped and V-shaped transfer functions for feature selection,” *J Ambient Intell Humaniz Comput*, vol. 13, no. 6, pp. 3137–3162, Jun. 2022, doi: 10.1007/s12652-021-03151-7.
- [33] A. Adewumi, J. Kagamba, and A. Alochukwu, “Application of Chaos Theory in the Prediction of Motorised Traffic Flows on Urban Networks,” *Math Probl Eng*, vol. 2016, pp. 1–15, 2016, doi: 10.1155/2016/5656734.
- [34] E. B. McKinsey Quarterly, *Strategy at the Edge of Chaos* , vol. January. 1997.

- [35] T. Carroll and R. M. Burton, “Organizations and Complexity: Searching for the Edge of Chaos. ,” *Comput Math Organ Theory*, vol. 6, no. 4, pp. 319–337, 2000, doi: 10.1023/A:1009633728444.
- [36] E. Barsky, “Brief history: properties and problems of entropy parameter,” in *Entropy of Complex Processes and Systems*, Elsevier, 2020, pp. 1–37. doi: 10.1016/B978-0-12-821662-0.00001-0.
- [37] N. H. Packard, “Dynamic Patterns in Complex Systems,” in *Dynamic Patterns in Complex Systems*, A. J. M. and M. F. S. J. A. S. Kelso, Ed., Singapore: World Scientific, 1988, pp. 293–301.
- [38] X. Li and X. Li, “Self-organizing and edge of chaos analysis of the multi-agent traffic evolution model,” in *2016 International Conference on Logistics, Informatics and Service Sciences (LISS)*, IEEE, Jul. 2016, pp. 1–6. doi: 10.1109/LISS.2016.7854387.
- [39] C. Teuscher, “Revisiting the edge of chaos: Again?,” *Biosystems*, vol. 218, p. 104693, Aug. 2022, doi: 10.1016/j.biosystems.2022.104693.
- [40] T. L. Carroll, “Do reservoir computers work best at the edge of chaos?,” *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 30, no. 12, Dec. 2020, doi: 10.1063/5.0038163.
- [41] G. Werner, “Metastability, criticality and phase transitions in brain and its models,” *Biosystems*, vol. 90, no. 2, pp. 496–508, Sep. 2007, doi: 10.1016/j.biosystems.2006.12.001.
- [42] M. Cassandro, A. Galves, E. Olivieri, and M. E. Vares, “Metastable behavior of stochastic dynamics: A pathwise approach,” *J Stat Phys*, vol. 35, no. 5–6, pp. 603–634, Jun. 1984, doi: 10.1007/BF01010826.
- [43] L. Miclo, “On metastability,” *Probab Theory Relat Fields*, vol. 184, no. 1–2, pp. 275–322, Oct. 2022, doi: 10.1007/s00440-022-01147-8.
- [44] R. H. Schonmann, “Metastability for the contact process,” *J Stat Phys*, vol. 41, no. 3–4, pp. 445–464, Nov. 1985, doi: 10.1007/BF01009017.
- [45] A. N. Pisarchik and U. Feudel, “Control of multistability,” *Phys Rep*, vol. 540, no. 4, pp. 167–218, Jul. 2014, doi: 10.1016/j.physrep.2014.02.007.
- [46] P. A. del G. C. A. A. Boccaletti S, “Multistable Systems, Coupled Neurons, and Applications,” in *Synchronization: From Coupled Systems to Complex Networks*, Cambridge University Press, 2018, pp. 77-123.

- [47] V.-T. Pham, S. Vaidyanathan, and T. Kapitaniak, “Complexity, Dynamics, Control, and Applications of Nonlinear Systems with Multistability,” *Complexity*, vol. 2020, pp. 1–7, Sep. 2020, doi: 10.1155/2020/8510930.
- [48] K. Parlin, M. M. Alam, and Y. Le Moullec, “Jamming of UAV remote control systems using software defined radio,” in *2018 International Conference on Military Communications and Information Systems (ICMCIS)*, IEEE, May 2018, pp. 1–6. doi: 10.1109/ICMCIS.2018.8398711.
- [49] R. Rashad, J. Goerres, R. Aarts, J. B. C. Engelen, and S. Stramigioli, “Fully Actuated Multirotor UAVs: A Literature Review,” *IEEE Robot Autom Mag*, vol. 27, no. 3, pp. 97–107, Sep. 2020, doi: 10.1109/MRA.2019.2955964.
- [50] S. M. Cully and T. D. Seeley, “Self-assemblage formation in a social insect: the protective curtain of a honey bee swarm,” *Insectes Soc*, vol. 51, no. 4, pp. 317–324, Nov. 2004, doi: 10.1007/s00040-004-0743-3.
- [51] H. A. Kurdi *et al.*, “Autonomous task allocation for multi-UAV systems based on the locust elastic behavior,” *Appl Soft Comput*, vol. 71, pp. 110–126, Oct. 2018, doi: 10.1016/j.asoc.2018.06.006.
- [52] J. K. Parrish, S. V. Viscido, and D. Grünbaum, “Self-Organized Fish Schools: An Examination of Emergent Properties,” *Biol Bull*, vol. 202, no. 3, pp. 296–305, Jun. 2002, doi: 10.2307/1543482.
- [53] A. OKUBO, “Dynamical aspects of animal grouping: Swarms, schools, flocks, and herds,” *Adv Biophys*, vol. 22, pp. 1–94, 1986, doi: 10.1016/0065-227X(86)90003-1.
- [54] J. Toner and Y. Tu, “Flocks, herds, and schools: A quantitative theory of flocking,” *Phys Rev E*, vol. 58, no. 4, pp. 4828–4858, Oct. 1998, doi: 10.1103/PhysRevE.58.4828.
- [55] C. W. Reynolds, “Flocks, herds and schools: A distributed behavioral model,” in *Proceedings of the 14th annual conference on Computer graphics and interactive techniques*, New York, NY, USA: ACM, Aug. 1987, pp. 25–34. doi: 10.1145/37401.37406.
- [56] R. Arnold, K. Carey, B. Abruzzo, and C. Korpela, “What is A Robot Swarm: A Definition for Swarming Robotics,” in *2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication*

- Conference (UEMCON)*, IEEE, Oct. 2019, pp. 0074–0081. doi: 10.1109/UEMCON47517.2019.8993024.
- [57] M. Schranz *et al.*, “Swarm Intelligence and cyber-physical systems: Concepts, challenges and future trends,” *Swarm Evol Comput*, vol. 60, p. 100762, Feb. 2021, doi: 10.1016/j.swevo.2020.100762.
- [58] G. Guban and A. Haque, “Path Planning for Autonomous Drones: Challenges and Future Directions,” *Drones*, vol. 7, no. 3, p. 169, Feb. 2023, doi: 10.3390/drones7030169.
- [59] M. Hussein *et al.*, “Key technologies for safe and autonomous drones,” *Microprocess Microsyst*, vol. 87, p. 104348, Nov. 2021, doi: 10.1016/j.micpro.2021.104348.
- [60] A. Phadke and F. A. Medrano, “Towards Resilient UAV Swarms—A Breakdown of Resiliency Requirements in UAV Swarms,” *Drones*, vol. 6, no. 11, p. 340, Nov. 2022, doi: 10.3390/drones6110340.
- [61] Y. Jiang, Y. Gao, W. Song, Y. Li, and Q. Quan, “Bibliometric analysis of UAV swarms,” *Journal of Systems Engineering and Electronics*, vol. 33, no. 2, pp. 406–425, Apr. 2022, doi: 10.23919/JSEE.2022.000042.
- [62] Z. Wei, Z. Meng, M. Lai, H. Wu, J. Han, and Z. Feng, “Anti-Collision Technologies for Unmanned Aerial Vehicles: Recent Advances and Future Trends,” *IEEE Internet Things J*, vol. 9, no. 10, pp. 7619–7638, May 2022, doi: 10.1109/JIOT.2021.3135578.
- [63] K. Dushime, L. Nkenyereye, S. K. Yoo, and J. Song, “A Review on Collision Avoidance Systems for Unmanned Aerial Vehicles,” in *2021 International Conference on Information and Communication Technology Convergence (ICTC)*, IEEE, Oct. 2021, pp. 1150–1155. doi: 10.1109/ICTC52510.2021.9621120.
- [64] J. N. Yasin, S. A. S. Mohamed, M.-H. Haghbayan, J. Heikkonen, H. Tenhunen, and J. Plosila, “Unmanned Aerial Vehicles (UAVs): Collision Avoidance Systems and Approaches,” *IEEE Access*, vol. 8, pp. 105139–105155, 2020, doi: 10.1109/ACCESS.2020.3000064.
- [65] S. S. , R. M. N. , T. P. S. , & F. J. E. Panda, “Remote sensing systems – Platforms and sensors: Aerial, satellites, UAVs, optical, radar, and LiDAR. ,” In *CRC Press (Ed.), Remotely sensed data characterization, classification, and accuracies (pp. 3–57). CRC Press., 2015.*

- [66] B. N. Chand, P. Mahalakshmi, and V. P. S. Naidu, "Sense and avoid technology in unmanned aerial vehicles: A review," in *2017 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICECCOT)*, IEEE, Dec. 2017, pp. 512–517. doi: 10.1109/ICECCOT.2017.8284558.
- [67] P. Tosato, D. Facinelli, M. Prada, L. Gemma, M. Rossi, and D. Brunelli, "An Autonomous Swarm of Drones for Industrial Gas Sensing Applications," in *2019 IEEE 20th International Symposium on "A World of Wireless, Mobile and Multimedia Networks" (WoWMoM)*, IEEE, Jun. 2019, pp. 1–6. doi: 10.1109/WoWMoM.2019.8793043.
- [68] E. Yanmaz, S. Yahyanejad, B. Rinner, H. Hellwagner, and C. Bettstetter, "Drone networks: Communications, coordination, and sensing," *Ad Hoc Networks*, vol. 68, pp. 1–15, Jan. 2018, doi: 10.1016/j.adhoc.2017.09.001.
- [69] Y. Altshuler, A. Pentland, and A. M. Bruckstein, *Swarms and Network Intelligence in Search*, vol. 729. Cham: Springer International Publishing, 2018. doi: 10.1007/978-3-319-63604-7.
- [70] M. Bekhti, N. Achir, and K. Boussetta, "Swarm of Networked Drones for Video Detection of Intrusions," 2018, pp. 221–231. doi: 10.1007/978-3-319-90802-1_19.
- [71] A. H. Fitwi, D. Nagothu, Y. Chen, and E. Blasch, "A Distributed Agent-Based Framework for a Constellation of Drones in a Military Operation," in *2019 Winter Simulation Conference (WSC)*, IEEE, Dec. 2019, pp. 2548–2559. doi: 10.1109/WSC40007.2019.9004907.
- [72] J.-W. Park, H.-D. Oh, and M.-J. Tahk, "UAV collision avoidance based on geometric approach," in *2008 SICE Annual Conference*, IEEE, Aug. 2008, pp. 2122–2126. doi: 10.1109/SICE.2008.4655013.
- [73] H. L. N. N. Thanh, N. N. Phi, and S. K. Hong, "Simple nonlinear control of quadcopter for collision avoidance based on geometric approach in static environment," *Int J Adv Robot Syst*, vol. 15, no. 2, Mar. 2018, doi: 10.1177/1729881418767575.
- [74] Y. Zou, H. Zhang, G. Zhong, H. Liu, and D. Feng, "Collision probability estimation for small unmanned aircraft systems," *Reliab Eng Syst Saf*, vol. 213, p. 107619, Sep. 2021, doi: 10.1016/j.ress.2021.107619.
- [75] K. CHOUTRI, M. LAGHA, L. DALA, and M. LIPATOV, "Quadrotors UAVs Swarming Control Under Leader-Followers Formation," in *2018*

22nd International Conference on System Theory, Control and Computing (ICSTCC), IEEE, Oct. 2018, pp. 794–799. doi: 10.1109/ICSTCC.2018.8540747.

- [76] J. Lwowski, A. Majumdar, P. Benavidez, J. J. Prevost, and M. Jamshidi, “Bird Flocking Inspired Formation Control for Unmanned Aerial Vehicles Using Stereo Camera,” *IEEE Syst J*, vol. 13, no. 3, pp. 3580–3589, Sep. 2019, doi: 10.1109/JSYST.2018.2884051.
- [77] I. Skyrda, “Decentralized Autonomous Unmanned Aerial Vehicle Swarm Formation and Flight Control,” 2019, pp. 197–219. doi: 10.1007/978-3-030-13929-2_10.
- [78] Q. Bi and Y. Huang, “A Self-organized Shape Formation Method for Swarm Controlling,” in *2018 37th Chinese Control Conference (CCC)*, IEEE, Jul. 2018, pp. 7205–7209. doi: 10.23919/ChiCC.2018.8482719.
- [79] J. Hu, M. Wang, C. Zhao, Q. Pan, and C. Du, “Formation control and collision avoidance for multi-UAV systems based on Voronoi partition,” *Sci China Technol Sci*, vol. 63, no. 1, pp. 65–72, Jan. 2020, doi: 10.1007/s11431-018-9449-9.
- [80] A. Lakas, A. N. Belkacem, and S. Al Hassani, “An Adaptive Multi-clustered Scheme for Autonomous UAV Swarms,” in *2020 International Wireless Communications and Mobile Computing (IWCMC)*, IEEE, Jun. 2020, pp. 1567–1572. doi: 10.1109/IWCMC48107.2020.9148449.
- [81] A. L. Alfeo, M. G. C. A. Cimino, N. De Francesco, M. Lega, and G. Vaglini, “Design and simulation of the emergent behavior of small drones swarming for distributed target localization,” *J Comput Sci*, vol. 29, pp. 19–33, Nov. 2018, doi: 10.1016/j.jocs.2018.09.014.
- [82] G. Vásárhelyi, C. Virágh, G. Somorjai, T. Nepusz, A. E. Eiben, and T. Vicsek, “Optimized flocking of autonomous drones in confined environments,” *Sci Robot*, vol. 3, no. 20, Jul. 2018, doi: 10.1126/scirobotics.aat3536.
- [83] M. Bekhti, N. Achir, and K. Boussetta, “Swarm of Networked Drones for Video Detection of Intrusions,” 2018, pp. 221–231. doi: 10.1007/978-3-319-90802-1_19.
- [84] J. J. Roldan, P. Garcia-Aunon, E. Pena-Tapia, and A. Barrientos, “SwarmCity Project: Can an Aerial Swarm Monitor Traffic in a Smart City?,” in *2019 IEEE International Conference on Pervasive Computing*

- and Communications Workshops (PerCom Workshops)*, IEEE, Mar. 2019, pp. 862–867. doi: 10.1109/PERCOMW.2019.8730677.
- [85] M. Mozaffari, W. Saad, M. Bennis, and M. Debbah, “Efficient Deployment of Multiple Unmanned Aerial Vehicles for Optimal Wireless Coverage,” *IEEE Communications Letters*, vol. 20, no. 8, pp. 1647–1650, Aug. 2016, doi: 10.1109/LCOMM.2016.2578312.
- [86] T. R. Beegum, M. Y. I. Idris, M. N. Bin Ayub, and H. A. Shehadeh, “Optimized Routing of UAVs Using Bio-Inspired Algorithm in FANET: A Systematic Review,” *IEEE Access*, vol. 11, pp. 15588–15622, 2023, doi: 10.1109/ACCESS.2023.3244067.
- [87] L. Abualigah, A. Diabat, P. Sumari, and A. H. Gandomi, “Applications, Deployments, and Integration of Internet of Drones (IoD): A Review,” *IEEE Sens J*, vol. 21, no. 22, pp. 25532–25546, Nov. 2021, doi: 10.1109/JSEN.2021.3114266.
- [88] M. Gharibi, R. Boutaba, and S. L. Waslander, “Internet of Drones,” *IEEE Access*, vol. 4, pp. 1148–1162, 2016, doi: 10.1109/ACCESS.2016.2537208.
- [89] V. A. Zorich, “Entropy in Thermodynamics and in Information Theory,” *Problems of Information Transmission*, vol. 58, no. 2, pp. 103–110, Apr. 2022, doi: 10.1134/S0032946022020016.
- [90] N. Rohatgi, “The Physical Meaning of Entropy—1,” *Resonance*, vol. 25, no. 12, pp. 1731–1740, Dec. 2020, doi: 10.1007/s12045-020-1093-9.
- [91] E. Barsky, “Overcoming the Problems Associated with the Entropy Parameter,” *Refractories and Industrial Ceramics*, vol. 62, no. 6, pp. 680–686, Mar. 2022, doi: 10.1007/s11148-022-00662-4.
- [92] J. W. Gibbs, “Elementary Principles of Statistical Mechanics. ,” *Yale University Press, New Haven. (Reprinted by Dover, New York, 1960) - references - scientific research publishing. (n.d.). Scirp.org. Retrieved October 28, 2024, 1902.*
- [93] C. E. and W. W. Shannon, “The mathematical theory of communication.,” *Baltimore, MD: University of Illinois Press., 1949.*
- [94] A. Wehrl, “General properties of entropy,” *Rev Mod Phys*, vol. 50, no. 2, pp. 221–260, Apr. 1978, doi: 10.1103/RevModPhys.50.221.

- [95] B. Bouchon-Meunier and C. Marsala, “Entropy Measures and Views of Information,” 2017, pp. 47–63. doi: 10.1007/978-3-319-40314-4_3.
- [96] C. O. Marsh, “Introduction to continuous entropy,,” <https://api.semanticscholar.org/CorpusID:28737847>, 2013.
- [97] S. B. Niku, “Entropy,” 2016, pp. 1–21. doi: 10.1007/978-3-031-79372-1_1.
- [98] M. I. Shterenberg, “Basic concepts of entropy, order, organization, information, knowledge, and meaning,” *Scientific and Technical Information Processing*, vol. 40, no. 3, pp. 131–136, Jul. 2013, doi: 10.3103/S0147688213030039.
- [99] R. P. , L. R. B. , & S. M. L. Feynman, *The Feynman lectures on physics*. . 1963.
- [100] B. Bein, “Entropy,” *Best Pract Res Clin Anaesthesiol*, vol. 20, no. 1, pp. 101–109, Mar. 2006, doi: 10.1016/j.bpa.2005.07.009.
- [101] L. Jost, “Entropy and diversity,” *Oikos*, vol. 113, no. 2, pp. 363–375, May 2006, doi: 10.1111/j.2006.0030-1299.14714.x.
- [102] T. M. ADDISCOTT, “Entropy and sustainability,” *Eur J Soil Sci*, vol. 46, no. 2, pp. 161–168, Jun. 1995, doi: 10.1111/j.1365-2389.1995.tb01823.x.
- [103] S. V. Chuprov, “Stability And Criteria For Self-Organization Of Industrial Economic Systems,” Jun. 2022, pp. 213–221. doi: 10.15405/epsbs.2022.06.24.
- [104] S. M. Pincus, “Approximate entropy as a measure of system complexity,,” *Proceedings of the National Academy of Sciences*, vol. 88, no. 6, pp. 2297–2301, Mar. 1991, doi: 10.1073/pnas.88.6.2297.
- [105] G. Canfora, L. Cerulo, M. Cimitile, and M. Di Penta, “How changes affect software entropy: an empirical study,” *Empir Softw Eng*, vol. 19, no. 1, pp. 1–38, Feb. 2014, doi: 10.1007/s10664-012-9214-z.
- [106] H. Van Dyke Parunak and S. Brueckner, “Entropy and self-organization in multi-agent systems,” in *Proceedings of the fifth international conference on Autonomous agents*, New York, NY, USA: ACM, May 2001, pp. 124–130. doi: 10.1145/375735.376024.

- [107] K. Wu, Q. Nan, and T. Wu, “Philosophical Analysis of the Meaning and Nature of Entropy and Negative Entropy Theories,” *Complexity*, vol. 2020, pp. 1–11, Aug. 2020, doi: 10.1155/2020/8769060.
- [108] C. R. Rao, “Entropy and Cross Entropy: Characterizations and Applications.,” in *In The Legacy of Alladi Ramakrishnan in the Mathematical Sciences; Springer: New York, NY, USA*, K. J. , R. C. , Eds. ; Alladi, Ed., 2010.
- [109] X. Zhang, K. Ben, and J. Zeng, “Cross-Entropy: A New Metric for Software Defect Prediction,” in *2018 IEEE International Conference on Software Quality, Reliability and Security (QRS)*, IEEE, Jul. 2018, pp. 111–122. doi: 10.1109/QRS.2018.00025.
- [110] B. Ray, V. Hellendoorn, S. Godhane, Z. Tu, A. Bacchelli, and P. Devanbu, “On the ‘naturalness’ of buggy code,” in *Proceedings of the 38th International Conference on Software Engineering*, New York, NY, USA: ACM, May 2016, pp. 428–439. doi: 10.1145/2884781.2884848.
- [111] Y. S. Aurelio, G. M. de Almeida, C. L. de Castro, and A. P. Braga, “Learning from Imbalanced Data Sets with Weighted Cross-Entropy Function,” *Neural Process Lett*, vol. 50, no. 2, pp. 1937–1949, Oct. 2019, doi: 10.1007/s11063-018-09977-1.
- [112] Y. Kim, Y. Lee, and M. Jeon, “Imbalanced image classification with complement cross entropy,” *Pattern Recognit Lett*, vol. 151, pp. 33–40, Nov. 2021, doi: 10.1016/j.patrec.2021.07.017.
- [113] Y. Dong, X. Shen, Z. Jiang, and H. Wang, “Recognition of imbalanced underwater acoustic datasets with exponentially weighted cross-entropy loss,” *Applied Acoustics*, vol. 174, p. 107740, Mar. 2021, doi: 10.1016/j.apacoust.2020.107740.
- [114] H. Chen *et al.*, “Adaptive Cross Entropy for ultrasmall object detection in Computed Tomography with noisy labels,” *Comput Biol Med*, vol. 147, p. 105763, Aug. 2022, doi: 10.1016/j.combiomed.2022.105763.
- [115] Q. Jodelet, X. Liu, and T. Murata, “Balanced softmax cross-entropy for incremental learning with and without memory,” *Computer Vision and Image Understanding*, vol. 225, p. 103582, Dec. 2022, doi: 10.1016/j.cviu.2022.103582.

- [116] C. Blum and X. Li, “Swarm Intelligence in Optimization,” in *Swarm Intelligence*, Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 43–85. doi: 10.1007/978-3-540-74089-6_2.
- [117] T.-Y. Ma and J.-P. Lebacque, “A Cross Entropy Based Multi-Agent Approach to Traffic Assignment Problems,” in *Traffic and Granular Flow '07*, Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, pp. 161–170. doi: 10.1007/978-3-540-77074-9_14.
- [118] W. Guo, L. Zhu, L. Wang, Q. Wu, and F. Kong, “An Entropy-Assisted Particle Swarm Optimizer for Large-Scale Optimization Problem,” *Mathematics*, vol. 7, no. 5, p. 414, May 2019, doi: 10.3390/math7050414.
- [119] Y. G. Petalas, K. E. Parsopoulos, and M. N. Vrahatis, “Entropy-based Memetic Particle Swarm Optimization for computing periodic orbits of nonlinear mappings,” in *2007 IEEE Congress on Evolutionary Computation*, IEEE, Sep. 2007, pp. 2040–2047. doi: 10.1109/CEC.2007.4424724.
- [120] D. N. Anisimov, T. S. Dang, S. Banerjee, and T. A. Mai, “Design and implementation of fuzzy-PD controller based on relation models: A cross-entropy optimization approach,” *Eur Phys J Spec Top*, vol. 226, no. 10, pp. 2393–2406, Jul. 2017, doi: 10.1140/epjst/e2017-70069-y.
- [121] M. A. Olivares-Mendez, L. Mejias, P. Campoy, and I. Mellado-Bataller, “Cross-Entropy Optimization for Scaling Factors of a Fuzzy Controller: A See-and-Avoid Approach for Unmanned Aerial Systems,” *J Intell Robot Syst*, vol. 69, no. 1–4, pp. 189–205, Jan. 2013, doi: 10.1007/s10846-012-9791-5.
- [122] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput Sci*, vol. 7, p. e623, Jul. 2021, doi: 10.7717/peerj-cs.623.
- [123] “r, Multiple R, r², R², R Square, R² Adjusted,” in *Statistics from A to Z: Confusing Concepts Clarified*, Hoboken, NJ, USA: John Wiley & Sons, Inc., 2016, pp. 274–319. doi: 10.1002/9781119272021.ch12.
- [124] P.; L. D.; Ś. S.; G. M.; J. N. Cofta, “System komunikacji roju dronów mający na celu unikanie kolizji.,” Zgłoszenie patentowe 431104, 2019

- [125] P. Cofta, D. Ledziński, S. Śmigiel, and M. Gackowska, “Cross-Entropy as a Metric for the Robustness of Drone Swarms,” *Entropy*, vol. 22, no. 6, p. 597, May 2020, doi: 10.3390/e22060597.
- [126] A. Smiti, “A critical overview of outlier detection methods,” *Comput Sci Rev*, vol. 38, p. 100306, Nov. 2020, doi: 10.1016/j.cosrev.2020.100306.
- [127] M. Gackowska, P. Cofta, M. Śrutek, and B. Marciniak, “Multivariate linear regression model based on cross-entropy for estimating disorganisation in drone formations,” *Sci Rep*, vol. 13, no. 1, p. 12750, Aug. 2023, doi: 10.1038/s41598-023-39926-5.
- [128] P. J. Huber, “Robust Estimation of a Location Parameter,” *The Annals of Mathematical Statistics*, vol. 35, no. 1, pp. 73–101, Mar. 1964, doi: 10.1214/aoms/1177703732.
- [129] G. C. McDonald, “Ridge regression,” *WIREs Computational Statistics*, vol. 1, no. 1, pp. 93–100, Jul. 2009, doi: 10.1002/wics.14.
- [130] D. E. , S. D. W. Hilt, “Ridge, a computer program for calculating ridge regression estimates ,” *Northeastern Forest Experiment Station (Radnor, Pa.), & United States. (1977). / Upper Darby, Pa : Dept. of Agriculture, Forest Service, Northeastern Forest Experiment Station, .*
- [131] H. Theil, “A Rank-Invariant Method of Linear and Polynomial Regression Analysis,” 1992, pp. 345–381. doi: 10.1007/978-94-011-2546-8_20.
- [132] H. Zou and T. Hastie, “Regularization and Variable Selection Via the Elastic Net,” *J R Stat Soc Series B Stat Methodol*, vol. 67, no. 2, pp. 301–320, Apr. 2005, doi: 10.1111/j.1467-9868.2005.00503.x.
- [133] L. Breiman, “Random Forest,” *Mach Learn*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [134] A. V. , E. V. , & G. A. Dorogush, “ CatBoost: gradient boosting with categorical features support. ,” *In arXiv [cs.LG]. https://doi.org/10.48550/ARXIV.1810.11363*, 2018.
- [135] T. , & G. C. Chen, “XGBoost: A Scalable Tree Boosting System,” *. In arXiv [cs.LG]. http://arxiv.org/abs/1603.02754*, 2016.
- [136] M. Awad and R. Khanna, “Support Vector Regression,” in *Efficient Learning Machines*, Berkeley, CA: Apress, 2015, pp. 67–80. doi: 10.1007/978-1-4302-5990-9_4.

- [137] O. Kramer, “K-Nearest Neighbors,” 2013, pp. 13–23. doi: 10.1007/978-3-642-38652-7_2.
- [138] S. B. Kotsiantis, “Supervised machine learning: A review of classification techniques.,” 2007.
- [139] M. Gackowska-Kątek and P. Cofta, “Explainable machine learning model of disorganisation in swarms of drones,” *Sci Rep*, vol. 14, no. 1, p. 22519, Sep. 2024, doi: 10.1038/s41598-024-73220-2.
- [140] M. Choraś, M. Pawlicki, D. Puchalski, and R. Kozik, “Machine Learning – The Results Are Not the only Thing that Matters! What About Security, Explainability and Fairness?,” 2020, pp. 615–628. doi: 10.1007/978-3-030-50423-6_46.
- [141] R. Roscher, B. Bohn, M. F. Duarte, and J. Garcke, “Explainable Machine Learning for Scientific Insights and Discoveries,” *IEEE Access*, vol. 8, pp. 42200–42216, 2020, doi: 10.1109/ACCESS.2020.2976199.
- [142] L. von Rueden *et al.*, “Informed Machine Learning - A Taxonomy and Survey of Integrating Prior Knowledge into Learning Systems,” *IEEE Trans Knowl Data Eng*, pp. 1–1, 2021, doi: 10.1109/TKDE.2021.3079836.
- [143] R. Zhou and T. Hu, “Evolutionary Approaches to Explainable Machine Learning,” 2024, pp. 487–506. doi: 10.1007/978-981-99-3814-8_16.
- [144] S. M. , & L. S.-I. Lundberg, “A unified approach to interpreting model predictions. ,” in *Proceedings of the 31st International Conference on Neural Information Processing Systems.*, 2017, pp. 4768–4777.
- [145] S. Hu, C. Xiong, P. Chen, and P. Schonfeld, “Examining nonlinearity in population inflow estimation using big data: An empirical comparison of explainable machine learning models,” *Transp Res Part A Policy Pract*, vol. 174, p. 103743, Aug. 2023, doi: 10.1016/j.tra.2023.103743.
- [146] S. Lipovetsky and M. Conklin, “Analysis of regression in game theory approach,” *Appl Stoch Models Bus Ind*, vol. 17, no. 4, pp. 319–330, Oct. 2001, doi: 10.1002/asmb.446.
- [147] E. Štrumbelj and I. Kononenko, “Explaining prediction models and individual predictions with feature contributions,” *Knowl Inf Syst*, vol. 41, no. 3, pp. 647–665, Dec. 2014, doi: 10.1007/s10115-013-0679-x.

SPIS RYSUNKÓW

Rysunek 1. Konceptyjny schemat organizacji i dezorganizacji [opracowanie własne]	13
Rysunek 2. Podział dezorganizacji i organizacji organizacji na podstawie [7]	16
Rysunek 3. Schemat krawędzi chaosu na podstawie McKinsey [36]	20
Rysunek 4. Schematyczne przedstawienie zachowania systemu [opracowanie własne]	22
Rysunek 5. Główne grupy metod unikania kolizji	25
Rysunek 6. Probabilistyczny graf przejść	33
Rysunek 7. Strefy bezpieczeństwa w algorytmie	43
Rysunek 8. Składowe algorytmu	43
Rysunek 9. Schematyczny rysunek formacji realizującej algorytm unikania kolizji oraz intruza	49
Rysunek 10. Schematyczny rysunek formacji i intruza realizujących algorytm unikania kolizji	49
Rysunek 11. Schematyczny rysunek formacji oraz intruza realizującego algorytm unikania kolizji	50
Rysunek 12. Etapy generowania zbioru danych	52
Rysunek 13. Schemat ataku intruza pod różnymi kątami	53
Rysunek 14. Zależność entropii krzyżowej od kąta natarcia intruza	54
Rysunek 15. Najwyższe wartości entropii w danych zakresach kątów	55
Rysunek 16. Schemat przedstawiający punkt wejścia intruza	56
Rysunek 17. Zależność między punktem wejścia a entropią krzyżową	57
Rysunek 18. Zależność pomiędzy interwałem próbkowania a błędem pomiaru dla kąta natarcia	59
Rysunek 19. Zależność pomiędzy interwałem próbkowania a błędem pomiaru dla punktu wejścia	59
Rysunek 20. Histogram wartości entropii krzyżowej w zbiorze danych	63
Rysunek 21. Analiza korelacji parametrów z entropią krzyżową	64
Rysunek 22. Histogram wartości entropii krzyżowej w drugim zbiorze danych	66
Rysunek 23. Schemat badań nad modelami bazowymi	67
Rysunek 24. Mapa cieplna korelacji	71
Rysunek 25. Mapa korelacji zmiennych w drugim zbiorze danych	74
Rysunek 26. Schemat dalszych prac badawczych po ustaleniu modelu bazowego	76
Rysunek 27. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i pierwszej grupy parametrów	82

Rysunek 28. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i drugiej grupy parametrów.	83
Rysunek 29. Wykres zależności pomiędzy parametrem R1 a wartościami SHAP.....	84
Rysunek 30. Wykres zależności pomiędzy rozmiarem formacji a wartościami SHAP.....	85
Rysunek 31. Wykres zależności między parametrem D2 a wartościami SHAP	86
Rysunek 32. Wykres zależności między parametrem D1 a wartościami SHAP	86
Rysunek 33. Wykres zależności między parametrem q a wartościami SHAP	87
Rysunek 34. Wykres zależności między parametrem τ a wartościami SHAP	88
Rysunek 35. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu SVR opracowanym na podstawie pierwszej grupy parametrów.	89
Rysunek 36. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu SVR opracowanym na podstawie drugiej grupy parametrów.	90
Rysunek 37. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa kolizji P(K) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów.....	98
Rysunek 38. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa kolizji P(K) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów.....	99
Rysunek 39. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów.....	100
Rysunek 40. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów.....	101
Rysunek 41. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji P(W) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów	102
Rysunek 42. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji P(W) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów.....	103
Rysunek 43. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa przejścia drona intruza P(L)	

w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów	104
Rysunek 44. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa przejścia drona intruza P(L) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów	104
Rysunek 45. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i pierwszej grupy parametrów dla zachowań kooperatywnych.	112
Rysunek 46. Wykres dystrybucji wartości SHAP związanych z parametrami w modelu CatBoost i drugiej grupy parametrów dla zachowań kooperatywnych.	113
Rysunek 47. Wykres zależności między rozmiarem a wartościami SHAP	114
Rysunek 48. Wykres zależności między parametrem R1 a wartościami SHAP	115
Rysunek 49. Wykres zależności między parametrem D1 a wartościami SHAP	116
Rysunek 50. Wykres zależności między parametrem D2 a wartościami SHAP	117
Rysunek 51. Wykres zależności między parametrem τ a wartościami SHAP	118
Rysunek 52. Wykres zależności między parametrem q a wartościami SHAP	118
Rysunek 53. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów	123
Rysunek 54. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji P(W) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów	123
Rysunek 55. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa normalnego przelotu P(L) w modelu Catboost opracowanym na podstawie pierwszej grupy parametrów	124
Rysunek 56. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa oscylacji P(O) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów	126
Rysunek 57. Wykres dystrybucji wartości SHAP dla predykcji prawdopodobieństwa wibracji P(W) w modelu Catboost opracowanym na podstawie drugiej grupy parametrów	127

Rysunek 58. Wykres dystrybucji wartości SHAP dla predykcji
prawdopodobieństwa normalnego przelotu $P(L)$ w modelu
Catboost opracowanym na podstawie drugiej grupy parametrów 128

SPIS TABEL

Tabela 1. Parametry roju w symulatorze	47
Tabela 2. Parametry algorytmu antykolizyjnego w symulatorze	48
Tabela 3. Statystyczny opis parametrów w zbiorze danych dotyczącym zachowania niekooperatywnego	62
Tabela 4. Analiza statystyczna zbioru danych związana z zachowaniem kooperatywnym drona intruza.....	65
Tabela 5. Linearyzacja podstawowych parametrów	69
Tabela 6. Wyniki modeli regresji liniowej w oparciu o podstawowe parametry	70
Tabela 7. Analiza statystyczna dodatkowo wprowadzonych zmiennych	71
Tabela 8. Linearyzacja dodatkowych parametrów	72
Tabela 9. Wyniki modeli regresji liniowej w oparciu o podstawowe i dodatkowe parametry	72
Tabela 10. Modele regresji liniowej opracowane na podstawie drugiego zbioru danych i pierwszej grupy parametrów	73
Tabela 11. Analiza statystyczna dodatkowo wprowadzonych parametrów w zbiorze danych dot. zachowań kooperatywnych.....	74
Tabela 12. Modele regresji liniowej opracowane na podstawie drugiego zbioru danych i drugiej grupy parametrów	74
Tabela 13. Hiperparametry modeli	79
Tabela 14. Ocena opracowanych modeli uczenia maszynowego	80
Tabela 15. Podsumowanie wartości SHAP i wpływu na model CatBoost i SVR w oparciu o pierwszą grupę parametrów	91
Tabela 16. Podsumowanie wartości SHAP i wpływu na model CatBoost i SVR w oparciu o drugą grupę parametrów	92
Tabela 17. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia kolizji, oscylacji, wibracji i normalnego przelotu na podstawie pierwszej grupy parametrów	94
Tabela 18. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia kolizji, oscylacji, wibracji i normalnego przelotu na podstawie drugiej grupy parametrów.	96
Tabela 19. Porównanie wyników wyjaśnialności modeli Catboost w oparciu o pierwszą grupę parametrów.....	105
Tabela 20. Wyniki modeli uczenia maszynowego opracowane na podstawie drugiego zbioru danych.....	109

Tabela 21. Porównanie predykcji entropii krzyżowej najlepszych modeli dla obu zbioru danych	111
Tabela 22. Porównanie zależności pomiędzy parametrami modelu a wartościami SHAP dla zachowań kooperatywnych i niekooperatywnych	119
Tabela 23. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia oscylacji, wibracji i normalnego przelotu na podstawie pierwszej grupy parametrów	122
Tabela 24. Ocena opracowanych modeli uczenia maszynowego dokonujących predykcji prawdopodobieństwa wystąpienia oscylacji, wibracji i normalnego przelotu na podstawie drugiej grupy parametrów	125
Tabela 25. Tabela porównawcza wpływu i zależności parametrów na modele predyktywne prawdopodobieństwa normalnego przelotu dla dwóch systemów z odmiennymi typami zakłóceń.....	129