

Prof. dr hab. inż. Wacław Szczesniak

Warszawa, 8.09. 2025 r.

Full emer. prof. in Warsaw University of Technology

Recenzja rozprawy doktorskiej

pt.

Health Structural Monitoring of Wind turbines components using Machine Learning

polski tytuł:

Monitorowanie stanu technicznego turbin wiatrowych z wykorzystaniem uczenia maszynowego

Podstawa Prawna Opracowania

Pismo Przewodniczącej Rady Doskonałości Naukowej Pani dr inż.
Justyny Sobczak Piąstka z dnia 06. 08. 2025 r.

1. Układ pracy

Rozprawa w języku angielskim o łącznej objętości 201 stron jest złożona z pięciu rozdziałów merytorycznych : wprowadzenia, przeglądu literatury, metodologii i metod badań, monitorowania stanu konstrukcji z wykorzystaniem uczenia maszynowego oraz konkluzji. Spis literatury obejmuje 283 pozycje cytowane w treści opracowania. Praca jest zilustrowana 48-ma rysunkami oraz 19-toma tablicami otrzymanych wyników analizy, głównie w zasadniczym rozdziale 4-tym. Na początku opracowania podano źródła finansowania pracy, listę skrótów, listę symboli oraz spis treści rozprawy. W zakończeniu pracy podano jej streszczenie w trzech językach angielskim, polskim i portugalskim.

Rozdział pierwszy zatytułowany „Wprowadzenie” zawarty na stronach 11-23 składa się z trzech podrozdziałów: Motywacja, Cele i układ rozprawy . Autor stwierdza tu, że nowoczesne konstrukcje inżynierskie stoją przed coraz większymi wyzwaniami ze względu na zmianę klimatu, starzejącą się infrastrukturę i rosnące wymagania dotyczące monitorowania. Energetyka wiatrowa zyskała na znaczeniu w ostatniej dekadzie ze względu na swój potencjał czystego, odnawialnego źródła energii elektrycznej. Szybki postęp technologii cyfrowych wpływa na monitorowanie stanu konstrukcji (SHM).

Rozdział drugi nosi tytuł „Przegląd Literatury” i jest zawarty na stronach 4 do 46 składa się z czterech podrozdziałów 2.1-2.4. Podrozdział 2.2 zawiera jeszcze jeden punkt 2.2.1, zaś podrozdział 3 zawiera 5 punktów. Przegląd dotyczy dotychczasowych badań i kierunków rozwoju związanych z niniejszą pracą doktorską. Rozpoczyna się od prac z

zakresu technik uczenia maszynowego, bowiem ciągła ocena stanu technicznego konstrukcji SHM umożliwia wczesne wykrywanie potencjalnych uszkodzeń lub anomalii umożliwiając terminową konserwację i naprawy zarówno elementów i komponentów turbin jak również konstrukcji nośnej i ruchomego śmigła. Podrozdział 2.2 dotyczy bezpośrednio prac o maszynowym uczeniu. Bazując na pracach [44-45] Autor przytacza pięć poziomów diagnostyki określonych następująco: 1 poziom wykrywanie: dostarcza informacji o obecności uszkodzeń, 2 poziom lokalizacja: dostarcza informacji o lokalizacji i rodzaju uszkodzeń, 3 poziom-klasyfikacja: dostarcza informacji o rodzajach uszkodzeń, poziom 4 ocena: dostarcza informacji o zakresie uszkodzeń, poziom 5-ty prognoza informuje o pozostałej żywotności i bezpieczeństwie istniejących konstrukcji. Awans na kolejny poziom zależy od pomyślnego ukończenia poprzednich. Statystyczne rozpoznawanie wzorców monitorowanie stanu konstrukcji z uczeniem maszynowym i statystyczne rozpoznawanie wzorców (SPR) są ze sobą ściśle powiązane, ponieważ (SHM) zintegrowane z (ML) opiera się na zasadach SPR w zakresie wykrywania, klasyfikacji i prognozowania uszkodzeń [59]. Przegląd literatury dotyczy 283-ech pozycji literatury i zawiera prawie komplet prac dotyczących tematycznie tego opracowania wraz z pracami przeglądowymi. W końcowym podrozdziale 2.4 Autor praktycznie definiuje cel pracy:

„Niniejsza praca wykorzystuje techniki uczenia maszynowego i SHM, koncentrując się na analizie sygnatur drgań, do identyfikacji poluzowania śrub i usterek w działaniu turbiny wiatrowej w różnych scenariuszach awarii, takich jak niewyważenie aerodynamiczne łopat, oblodzenie wirnika i awaria elastycznego sprzęgła. Te zaawansowane techniki oferują szereg korzyści, w tym wczesne wykrywanie uszkodzeń i usterek w działaniu, precyzyjną identyfikację wzorców uszkodzeń, zwiększoną dokładność inspekcji, przewidywanie okresu eksploatacji i poprawę efektywności konserwacji. Łącznie, te działania mogą znacznie zwiększyć niezawodność i trwałość turbin wiatrowych. Biorąc pod uwagę ograniczoną liczbę badań przeprowadzonych w tej dziedzinie w stosunku do jej znaczenia, istnieje pilna potrzeba opracowania i wykorzystania dokładnych i niezawodnych narzędzi do ich realizacji.

Celem tych badań jest pogłębienie wiedzy i zastosowanie SHM (monitorowanie stanu konstrukcji) w konserwacji turbin wiatrowych poprzez wypełnienie tej luki inżynierii, co ostatecznie przyczyni się do wsparcia bezpieczniejszych i bardziej wydajnych systemów energetyki wiatrowej.”

Rozdział trzeci nosi tytuł „Metodologia i Metody”, obejmuje strony 48-92 wraz z rozdziałem czwartym stanowiąc razem, zasadniczą część badawczą tej pracy. Rozdział ten jest złożony z trzech podrozdziałów przy czym podrozdział 3.2 zawiera cztery punkty 3.2.1-3.2.4, zaś podrozdział 3.3 zawiera aż sześć punktów 3.3.1-3.3.6. Opisano tu proces uszkodzeń w tym metodologicznej oceny stanu podzespołów turbin wiatrowych obejmujący wykrywanie i kwantyfikacje uszkodzeń z wykorzystaniem modelu uczenia maszynowego ML. Strategia obejmuje przetwarzanie istniejących danych z testów wibracyjnych, ekstrakcję cech, strategię rozszerzania danych poprzez wirtualny czujnik, selekcję cech, klasyfikację uszkodzeń, kwantyzację uszkodzeń oraz wykonanie algorytmów wykrywania i regresji w celu kwantyfikacji uszkodzeń z kwantyzacją niepewności. Proponowany w pracy proces SHM-ML przekształca się w narzędzie o otwartym kodzie w języku Python. Na rysunku 3.1

pokazano schematycznie metodologię monitorowania stanu konstrukcji z wykorzystaniem uczenia maszynowego, przedstawiając każdy etap metodologii wykrywania i kwantyfikacji uszkodzeń. W podrozdziale 3.1 opisano 8-ośmio punktowy algorytm SHL-ML. Struktury i systemy różnią się, a podejście zastosowane w niniejszej pracy koncentruje się na indywidualnym monitorowaniu. Dlatego każdy system należy oceniać niezależnie, biorąc pod uwagę następujące kwestie: • zidentyfikuj konkretne rozpatrywane uszkodzenia i usterki, • określ informacje dostępne z systemu, np. odpowiedzi czasowe, widmo częstotliwości lub właściwości modalne, • oceń, czy zapewnione są zarówno warunki normalne, jak i warunki awarii, • zbierz informacje o uszkodzeniu lub usterce, w tym o jego przyczynach naturalnych, prawdopodobnych uszkodzonych komponentach i możliwych ich lokalizacjach, • rozpoznaj, lokalizację uszkodzenia którą można zidentyfikować za pomocą uczenia bez nadzoru, określenie rodzaju i stopnia uszkodzenia zazwyczaj wymaga uczenia z nadzorem [167], potwierdź, że czujniki nie mierzą bezpośrednio uszkodzeń. Ekstrakcja cech poprzez przetwarzanie sygnału i klasyfikację statystyczną jest niezbędna do przekształcenia danych z czujnika w sensowne informacje o uszkodzeniach [167], należy zapewnić odpowiednią ekstrakcję cech, ponieważ niewłaściwe metody mogą prowadzić do wysokiej wrażliwości na zmiany operacyjne i środowiskowe, a nie na rzeczywiste uszkodzenia [167]. • Należy rozważyć, czy niedobór danych będzie stanowił wyzwanie w celu monitorowania. Po zmapowaniu i zaplanowaniu strategii monitorowania ocenianego systemu, zaleca się zastosowanie proponowanej metody SHM-ML. W niniejszym badaniu analizowano cztery aplikacje wykorzystujące dynamiczne informacje wejściowe: jedną opartą na właściwościach modalnych, a konkretnie na częstotliwościach drgań własnych, jak szczegółowo opisano w [143], dwie oparte na analizie widma częstotliwościowego i jedną wykorzystującą dane odpowiedzi czasowej. Poza klasyfikacją i kwantyfikacją uszkodzeń, problem niedoboru danych jest rozwiązywany poprzez integrację wirtualnego czujnika z modelem w celu rozszerzenia danych. Odpowiednie trzy algorytmy postępowania zamieszczono i objaśniono na stronach 49-72. Podprogram SHM-ML (monitorowanie stanu konstrukcji) przetwarza odpowiedzi czasowe w celu wykrywania i klasyfikacji błędów w algorytmie 3 (Alg3), wykorzystując dane odpowiedzi częstotliwościowej do wykrywania i kwantyfikacji uszkodzeń w algorytmie 1 (Alg1) oraz usprawnia kwantyfikację uszkodzeń poprzez rozszerzenie danych w algorytmie 2 (Alg2). Autor definiuje tzw. Support Vector Machine (czyli maszyna wektorów nośnych nadzorowania techniki uczenia maszynowego do klasyfikowania i regresji danych wejściowych). W niniejszym rozdziale również szczegółowo opisano ramy metodologiczne zastosowane w badaniu, obejmujące przetwarzanie danych, ekstrakcję cech, strategie uczenia maszynowego oraz kwantyfikację niepewności. Proponowane podejście integruje analizy w dziedzinie częstotliwości i czasu z technikami augmentacji danych, aby zwiększyć solidność ekstrakcji cech. Kroki te zapewniają, że dane wejściowe są dobrze ustrukturyzowane i reprezentatywne w przypadkach rzeczywistych warunków SHM. Wybór algorytmów uczenia maszynowego, w tym technik uczenia nadzorowanego i nienadzorowanego, został uzasadniony ich zdolnością do wykrywania, klasyfikowania i kwantyfikacji uszkodzeń strukturalnych na podstawie danych widmowych drgań. Wykorzystanie zarówno tradycyjnych, jak i zaawansowanych modeli regresji do kwantyfikacji uszkodzeń wzmacnia wiarygodność proponowanej metodologii. Ponadto, wprowadzono techniki kwantyfikacji niepewności, aby uwzględnić zmienność w

warunkach rzeczywistych i poprawić interpretowalność wyników. Chociaż metodologia ta stanowi podstawę badania, starannie rozważono takie wyzwania, jak nierównowaga danych, interpretowalność modelu i koszty obliczeniowe. Struktury i systemy różnią się, a podejście zastosowane w niniejszej pracy koncentruje się na indywidualnym monitorowaniu. Dlatego każdy system należy oceniać niezależnie, biorąc pod uwagę następujące kwestie: • zidentyfikuj konkretne rozpatrywane uszkodzenia i usterki, • określić informacje dostępne z systemu, np. odpowiedzi czasowe, widmo częstotliwości lub właściwości modalne, • ocenić, czy zapewnione są zarówno warunki normalne, jak i warunki awarii, • zbierać informacje o uszkodzeniu lub usterce, w tym o jego przyczynach naturalnych, prawdopodobnych uszkodzonych komponentach i możliwych ich lokalizacjach, • rozpoznać, że chociaż istnienie i lokalizację uszkodzenia można zidentyfikować za pomocą uczenia bez nadzoru, określenie rodzaju i stopnia uszkodzenia zazwyczaj wymaga uczenia z nadzorem [167], potwierdzić, że czujniki nie mierzą bezpośrednio uszkodzeń.

W badaniu analizowano cztery aplikacje wykorzystujące dynamiczne informacje wejściowe. Poza tym w niniejszym rozdziale szczegółowo opisano również ramy metodologiczne zastosowane w pracy, obejmujące przetwarzanie danych, ekstrakcję cech, strategie uczenia maszynowego oraz kwantyfikację niepewności. Proponowane podejście integruje analizy w dziedzinie częstotliwości i czasu z technikami augmentacji danych, aby zwiększyć solidność ekstrakcji cech. Kroki te zapewniają, że dane wejściowe są dobrze ustrukturyzowane i reprezentatywne dla rzeczywistych warunków SHM. Wybór algorytmów uczenia maszynowego, w tym technik uczenia nadzorowanego i nienadzorowanego, został uzasadniony ich zdolnością do wykrywania, klasyfikowania i kwantyfikacji uszkodzeń strukturalnych na podstawie danych widmowych drgań. Wykorzystanie zarówno tradycyjnych, jak i zaawansowanych modeli regresji do kwantyfikacji uszkodzeń wzmacnia wiarygodność proponowanej metodologii. Ponadto, wprowadzono techniki kwantyfikacji niepewności, aby uwzględnić zmienność w warunkach rzeczywistych i poprawić interpretowalność wyników. Chociaż metodologia ta stanowi podstawę badania, starannie rozważono takie wyzwania, jak nierównowaga danych, interpretowalność modelu i koszty obliczeniowe. Kolejny rozdział przedstawia wyniki zastosowania tych metod, oferując wgląd w ich skuteczność i ograniczenia w rzeczywistych scenariuszach. Moim zdaniem podstawą teoretyczną, badań statystycznych w tym rozdziale jest znana odpowiednio zaadaptowana metoda najmniejszych kwadratów (wzór 3.18) stosowana szeroko w tego typu opracowaniach tego typu..

Rozdział 4 pod tytułem: „Monitorowanie stanu konstrukcji z wykorzystaniem uczenia maszynowego opartego na danych: Eksperymentalne studia przypadków” jest zawarty na stronach 93-158 i stanowi zasadniczą oryginalną część tej rozprawy, jest on zilustrowany 38 rysunkami i dwudziestoma tablicami wyników obliczeń komputerowych. Rozdział ten jest złożony z czterech podrozdziałów, przy czym podrozdział 4.1 składa się z trzech punktów, podrozdział 4.2 jest z kolei złożony również z trzech punktów. Końcowy podrozdział 4.3 jest złożony z jednego rozbudowanego punktu 4.3.1 na stronach 121-152 . Rozdział 4-ty kończy podrozdział „uwagi końcowe” napisany na stronach 157-158. System turbiny wiatrowej składa się z podsystemów połączonych głównie za pomocą śrub lub połączeń śrubowych.

Niniejszy rozdział przedstawia studia przypadków zastosowania praktycznego procesu SHM-ML zaproponowanego w niniejszej pracy. Pierwsze badanie (sekcja 4.1) ma na celu monitorowanie i ocenę uszkodzeń trzech komponentów podczas rzeczywistej pracy turbiny wiatrowej Aventa. W tym przypadku, surowymi danymi wykorzystanymi do monitorowania jest widmo czasowe przyspieszenia, a wykorzystywany jest wskaźnik Al_{111} . Połączenia śrubowe, występujące w wielu częściach turbiny, są oceniane przy użyciu laboratoryjnego zestawu eksperymentalnego. Drugi przypadek (sekcja 4.2) ma na celu identyfikację i klasyfikację luzowania momentu obrotowego w połączeniach śrubowych konstrukcji przy użyciu surowych sygnałów widmowych w dziedzinie częstotliwości z badań eksperymentalnych. Podejście łączyło techniki nadzorowane i nienadzorowane oraz wykorzystywało wskaźnik Al_{11} , oraz wskaźnik uszkodzenia obliczony na podstawie odpowiedzi częstotliwościowej układu połączeń jako dane wejściowe. Trzeci przypadek (sekcja 4.3) integruje algorytmy regresji z technikami augmentacji danych, aby dokładniej oszacować luzowanie momentu obrotowego z wykorzystaniem surowych widm drgań w konstrukcji skręcanej. Badania te demonstrują efektywność opracowanego procesu SHM-ML, który przyczynia się do wykrywania usterek i poprawia niezawodność złożonych konstrukcji i systemów mechanicznych. Na szczególną uwagę zwracają opracowane szczegółowo graficzne wyniki zawarte na stronach 138-155 dotyczące np. gęstości prawdopodobieństwa szacowanego momentu obrotowego przewidzianego za pomocą danych z algorytmów regresji jak również tablice wartości średnich i odchyłeń standardowych modeli regresji wykonanych na podstawie oryginału i 50%-200% losowych próbek wybranych metodą statystyczną.

2. Uwagi o pracy

1. Autor bazuje na pomiarach częstości ω drgań własnych i wymuszonych elementów konstrukcyjnych, głównie połączeń śrubowych, nie podaje jednak przyczyny ich powstania. Wymagało by to między innymi, oszacowania wielkości momentu żyroskopowego wywołanego częstością obrotową śmigła ω_1 oraz prostopadłą do niej, częstością ω_2 wywołaną drganiem czubka wieży, a związaną z odrywaniem się strug i wirów powietrza opływającego wieżę. Moment ten zależy od masowego momentu bezwładności wieży J_0 obliczonego względem osi wieży i opisany jest następującym wzorem:

$M_0 = J_0 \omega_1 \omega_2 \sin(\pi/2 + \delta)$. Ciekawe czy momenty ze strony 114 tzn. 10 kNm, 20 kNm, 30 kNm oraz 80 kNm mieszczą się w przytoczonym wyrażeniu na moment żyroskopowy.

2. Pracę czyta się bardzo trudno bowiem zawiera ona 53 różne skróty napisane dwiema, oraz trzema lub większą liczbą dużych drukowanych liter porozrzucanych na bardzo wielu stronach, co utrudnia znacznie jej czytanie. Przykładowo na stronie 110 mamy 30 różnych skrótów. Niektóre z nich nie zostały opisane np. FRACi j.

3. Niektóre rysunki i fotografie na przykład rysunek 4.1 na stronie 96 i inne są za małe i nieczytelne w przeciwieństwie do rysunku 4.15 na stronie 117 który jest doskonale czytelny.

4. Zabrakło mi jakichkolwiek wyników badań w odniesieniu do fundamentu. Kto ma zaprojektować fundament wiatraka, czy jeden pał jest wystarczający do zamocowania tej

szczegółnej złożonej konstrukcji pracującej w wyjątkowo złożonych warunkach obciążenia. W połączeniu płyty fundamentowej też są śruby. Wieża jest podstawowym elementem nośnym, a wahania prędkości wiatru wpływają na jej stateczność, co zagraża gondoli głównej. Jak szybko wykryć mikro uszkodzenia wieży, co stanowi klucz do jej stateczności.

5. Zdając sobie sprawę z wysokich kosztów zakupu akcelerometrów, nie wiem czy ich 11 sztuk rozmieszczonych strategicznie wzdłuż wieży, rury głównej gondoli, łożyska głównego oraz generatora i 2 tensometry mostkowane do pomiarów przesunąć osi wprzód, w tył i na boki, w pobliżu fundamentu jest wystarczające w tego typu badaniach. Przy tym nie jest wiadomo czy akcelerometry mierzyły przyspieszenia w jednym czy wielu kierunkach.

6. Autor nie wspomina o możliwości rezonansu pojedynczej łopaty śmigła w przypadku kiedy jej częstość drgań własnych może się zbliżyć do zmiennej częstości wiatru. Szkoda, że w spisie literatury pominięto polską monografię: „Metody ekstrakcji w uczeniu maszynowym” M. Topolski, Akad. Oficyna. EXIT, 2023 r. stron 222.

7. Na wiatrak działa również przyspieszenie Coriolisa i siła Coriolisa wynikające z ruchu kuli ziemskiej i strug powietrza zmiennych i prostopadłych łożyska głównego generatora i jego mocujących śrub. Przyspieszenie to określa wzór $\vec{a}_C = 2 \vec{\omega} \times \vec{v}_{wzg.}$. Jak może wpływać siła Coriolisa na obciążenie dynamiczne śrub.

3. Oryginalne elementy rozprawy

1. Oryginalność owej rozprawy polega na pełnym, całościowym i kompletnym zakresie jej opracowania. Począwszy od przeglądu, prawie całkowicie dostępnej z tego zakresu literatury 283 pozycje, następnie nakreślenia celu badań, określenia ich metodologii, wykonania pomiarów i ich żmudnej statystycznej analizy i wyników, z wyciągnięciem wniosków końcowych. Autor użył tu dostępnej już metody komputerowej mechanicznego uczenia ML, co jest aktualnie najnowszym niezwykle silnym i nowoczesnym narzędziem informatycznym, jako podzbiór wykorzystujący całkowicie sztuczną inteligencję AI, oraz wszystkie dostępne programy opracowane przez potęgi informatyczne USA: jak Google, Apple, Microsoft, Mathematica, Matlab, Amazon i Meta, CAD, Photoshop oraz wiele innych. Koncentruje się ona na tworzeniu algorytmów które uczą się z danych, bez konieczności jawnego programowania. Jej zastosowanie w tej rozprawie jest oryginalnym pomysłem Autora,

2. Połączenia mechaniczne są kluczowymi i często krytycznymi elementami każdego podzespołu, zespołu lub konstrukcji inżynierskiej, zespołu piasty wirnika, w regulatorze kąta skręcenia łopat itp, ponieważ sztywno łączą poszczególne elementy konstrukcji zwiększając dynamiczną odporność zmontowanego systemu. Właśnie połączeniom śrubowym, a ściślej ich awarii, w kabinie wiatraka dotyczy przede wszystkim ta praca. Autor podjął się trudnego zadania ciągłego monitorowania zasadniczych i krytycznych elementów tych budowli wykorzystując wyjątkowo silne narzędzi w postaci uczenia maszynowego (Machine Learning -ML), a dokładniej monitorowania jej stanu

technicznego (Structural Health Monitoring – SHL.) Oryginalny pomysł autora zastał zastosowany, adaptowany i wykonany w tym opracowaniu, co stanowi niewątpliwie Jego osiągnięcie naukowe.

3. Jak pisze Autor celem tej pracy jest opracowanie metody uczenia maszynowego, wykorzystującego pomierzone parametry techniczne. Aby to osiągnąć opracował trzy oryginalne algorytmy postępowania wprowadzając specjalistyczne wektory H_{ij}^{dam} oraz H_{ij}^{und} zależne od częstości drgań własnych oraz wymuszonych ω . Algorytmy te opisują i podają: zbieranie danych ich klastrowanie czyli zbieranie danych podobnych w klastry, użycie algorytmu $J = \sum_{i=1}^n \min_k (\|x_i - \bar{x}_k\|^2)$ i decyzję ostateczną. Cały rozdział trzeci jest oryginalną mapą postępowania w przypadku stosowania w różnych badaniach maszynowego nauczania.

4. Niewątpliwym centrum opracowania tej rozprawy są liczne wyniki przedstawione w zasadniczym rozdziale czwartym gdzie dokonano zestawu żmudnych badań statystycznych, a ich rezultaty w postaciach na przykład licznych wykresów estymacji momentu w rzeczywistym wiatraku typu Aventa AG w Szwajcarii, pozwalają ostrzegać nadzór techniczny nad możliwością wystąpienia awarii, są zasadniczym osiągnięciem Autora.

Wniosek końcowy

W świetle ustawy z 20 lipca 2018 roku wraz z późniejszymi zmianami,, stwierdzam. Rozprawa doktorska mgr inż. Jeffersona da Silva Coelho stanowi oryginalne rozwiązanie zadania naukowego. Doktorant wykazał się z nawiązką odpowiednią wiedzą doświadczalną i teoretyczną w zakresie dyscypliny budownictwo, transport i geodezja. Opracował oryginalne algorytmy postępowania w metodzie nauczania maszynowego stosując je do oceny stanu technicznego konkretnego wiatraka. Wykazał się przy tym bardzo dobrą znajomością statyki i dynamiki konstrukcji, bardzo dobrą znajomością programowania komputerowego, bardzo dobrą znajomością opracowania statystycznego chmury wyników pomierzonych wielkości mechanicznych.

Wnoszę o dopuszczenie mgr inż. Jeffersona da Silva Coelho do publicznej obrony Jego wyróżniającej się rozprawy przed Radą Wydziału Budownictwa, Architektury i Geodezji Politechniki Bydgoskiej w Bydgoszczy. Jednocześnie stawiam wniosek o jej wyróżnienie jako jedną z nielicznych opracowań doktorskich poświęconej całkowicie komputerowemu nauczaniu maszynowemu.

