




Łukasz Jedliński, Józef Jonak

Kontrola montażu zębatach przekładni stożkowych metodą bezdemontażową



MONOGRAFIE

Kontrola montażu zębatach przekładni
stożkowych metodą bezdemontażową

Monografie – Politechnika Lubelska



Politechnika Lubelska
Wydział Mechaniczny
ul. Nadbystrzycka 36
20-618 LUBLIN

Łukasz Jedliński, Józef Jonak

Kontrola montażu zębatach przekładni stożkowych metodą bezdemontażową



Wydawnictwo Politechniki Lubelskiej
Lublin 2020

Recenzenci:

prof. dr hab. inż. Stanisław Radkowski, Politechnika Warszawska
dr hab. inż. Paweł Drożdziel, prof. Politechniki Lubelskiej

Badania zostały sfinansowane z Projektu Politechnika Lubelska – Regionalna Inicjatywa Doskonałości ze środków Ministerstwa Nauki i Szkolnictwa Wyższego na podstawie umowy nr 030/RID/2018/19

Publikacja wydana za zgodą Rektora Politechniki Lubelskiej

© Copyright by Politechnika Lubelska 2020

ISBN: 978-83-7947-427-1

Wydawca: Wydawnictwo Politechniki Lubelskiej
www.biblioteka.pollub.pl/wydawnictwa
ul. Nadbystrzycka 36C, 20-618 Lublin
tel. (81) 538-46-59

Druk: DjaF – 30-092 Kraków, ul. Kmietowicza 1/1
www.djaf.pl

Elektroniczna wersja książki dostępna w Bibliotece Cyfrowej PL www.bc.pollub.pl

Nakład: 50 egz.

SPIS TREŚCI

1. WSTĘP	7
2. DIAGNOSTYKA WIBROAKUSTYCZNA – ZAGADNIENIA TEORETYCZNE I PRAKTYCZNE	10
2.1. Klasyfikacja metod diagnostycznych	11
2.2. Generacja i propagacja drgań	14
2.3. Teoretyczne widmo drgań przekładni zębatej	16
2.4. Przegląd metod diagnostyki drganiowej przekładni zębatych.....	20
2.4.1. Selekcja użytecznego sygnału wibroakustycznego	20
2.4.1.1. Metody redukujące wymiar danych	23
2.4.2. Analiza widmowa sygnałów stacjonarnych	25
2.4.3. Analiza sygnałów niestacjonarnych	27
2.4.3.1. Transformata falkowa.....	27
2.4.4. Metody sztucznej inteligencji.....	31
2.4.4.1. Sztuczne sieci neuronowe	32
3. METODY OCENY WYKONANIA KÓŁ ZĘBATYCH I MONTAŻU PRZEKŁADNI.....	38
3.1. Kontrola kół zębatych na etapie produkcji	38
3.2. Montaż i kryteria poprawności zabudowy kół zębatych	42
3.3. Ocena wykonania przekładni zębatych w świetle wybranych norm	47
3.4. Podsumowanie badań literaturowych na temat możliwości stosowania metod wibroakustycznych do diagnostyki kontrolnej przekładni zębatych....	49
4. BADANIA STANOWISKOWE PRZEKŁADNI STOŻKOWYCH	53
4.1. Obiekt badań.....	53
4.2. Sposób prowadzenia badań.....	54
4.3. Stanowisko badawcze.....	55
5. WSTĘPNE BADANIA OCENY MONTAŻU PRZEKŁADNI ZĘBATYCH STOŻKOWYCH	57
5.1. Badania symulacyjne.....	57
5.1.1. Symulacja współpracy jednostronnej	58
5.1.2. Wyniki badań	58
5.2. Badania stanowiskowe	62
5.3. Wnioski z badań wstępnych	65

6. METODA OCENY MONTAŻU PRZEKŁADNI STOŻKOWYCH.....	67
6.1. Odszumianie sygnałów	69
6.2. Miary sygnałów	77
6.3. Wybór optymalnych miar sygnałów.....	85
6.4. Sieci neuronowe	89
6.4.1. Perceptron wielowarstwowy MLP	89
6.4.1.1. Wyniki oceny montażu przekładni zębatych stożkowych.....	97
6.4.2. Sieci o radialnych funkcjach bazowych RBF	102
6.4.2.1. Wyniki oceny montażu przekładni zębatych stożkowych.....	104
6.4.3. Metoda wektorów nośnych SVM.....	106
6.4.3.1. Wyniki oceny montażu przekładni zębatych stożkowych.....	110
7. PODSUMOWANIE I WNIOSKI KOŃCOWE	114
8. LITERATURA.....	116

1. WSTĘP

Zastosowanie przekładni zębatych ze względu na wysoką sprawność, trwałość, małe wymiary i masę jest szerokie w odniesieniu do innych rodzajów przekładni mechanicznych. Są one montowane w różnych maszynach i urządzeniach od zabawek (gdzie wykonywane są głównie z tworzywa sztucznego) po statki powietrzne. Szczególną uwagę zwraca się na te przekładnie, których awaria powoduje duże straty finansowe lub na te, które mają wpływ na bezpieczeństwo ludzi. Niewątpliwie, przekładnie używane w śmigłowcach należą do tych grup i są obiektem badań w niniejszej monografii.

W śmigłowcach jednowirnikowych w skład układu napędowego najczęściej wchodzi przekładnia główna i przekładnia końcowa [99]. Reduktor główny przekazuje napęd z poziomo położonego silnika na pionowy wirnik oraz do przekładni końcowej. Przekładnia główna jest obiektem złożonym, składa się z kilku stopni, zazwyczaj pierwszy stopień jest stożkowy. Przekładnia końcowa to najczęściej reduktor jednostopniowy stożkowy. Awaria którejkolwiek z tych przekładni może spowodować katastrofę, dlatego też przekładnie te należą do tzw. urządzeń krytycznych. Największą trudnością w ich konstruowaniu jest konieczność spełnienia przez nie sprzecznych kryteriów. Z jednej strony powinny być niezawodne, co wiąże się z większymi współczynnikami bezpieczeństwa a w rezultacie większą masą, a z drugiej strony powinny być jak najlżejsze. Masa przekładni ma wpływ nie tylko na koszty materiałów, z których jest wykonana. Każdy kilogram uniesiony przez śmigłowca wymaga spalania określonej ilości ropy lotniczej, również większa masa własna śmigłowca (przy tej samej mocy silnika) powoduje zmniejszenie maksymalnej masy ładunku. Dlatego stosuje się wyrafinowane konstrukcje, wytrzymałe a zarazem lekkie materiały, bardzo dokładną obróbkę i kontrolę wszystkich ważnych części przekładni.

Potrzeba uzyskania wysokiej niezawodności funkcjonowania przekładni spowodowała m.in. dynamiczny rozwój metod ich diagnozowania. Najczęściej są to badania produktów zużycia, diagnostyka termiczna i diagnostyka wibroakustyczna.

W pierwszej metodzie bada się produkty zużycia poprzez: ferrografie, metody magnetyczne, analizy spektralne oleju czy zliczanie cząstek. Diagnostyka termiczna najczęściej polega na punktowym pomiarze temperatury. Ostatnia z wymienionych metod – diagnostyka wibroakustyczna – oparta jest na analizie sygnału wibroakustycznego. Jest często stosowana, gdyż pozwala na ciągłe monitorowanie stanu obiektu. Wyróżnia się też wśród pozostałych metod tym, że oprócz ogólnego określenia stanu technicznego umożliwia lokalizację miejsca i typu uszkodzenia. W ostatnich latach nastąpił szybki postęp tej metody spowodowany głównie rozwojem aparatury pomiarowej i komputerów oraz nowymi metodami przetwarzania i analizy sygnałów. Dzięki temu możliwe jest

wykrycie nawet niewielkich zmian w stanie obiektu a także kilku zmian jednocześnie. Zagadnienia te są omówione szerzej w rozdziale 2.

Wiele ośrodków naukowych krajowych i zagranicznych zajmuje się diagnostyką wibroakustyczną przekładni zębatych. Istnieją również komercyjne rozwiązania oferowane przez firmy do diagnostyki przekładni, które możemy podzielić na urządzenia przenośne i do ciągłego monitorowania stanu maszyn. Publikowane prace z tego zakresu dotyczą najczęściej diagnostyki eksploatacyjnej. Często poruszonymi problemami badawczymi są: wykrywanie wykruszenia zęba i pęknięcia zęba u podstawy, uszkodzenia roboczej powierzchni zębów, wykrywanie uszkodzeń w łożyskach lub kilku różnych uszkodzeń jednocześnie. Obiektami badawczymi są najczęściej przekładnie walcowe. Mniej uwagi poświęca się przekładniom stożkowym i diagnostyce kontrolnej wytwarzania i montażu.

Przekładnie walcowe są prostsze w opisie matematycznym i jest dużo prac z tego zakresu, dotyczących różnych aspektów fazy cyklu życia obiektu. Natomiast przekładnie stożkowe, zwłaszcza o krzywoliniowej linii zęba, są trudniejsze w opisie, co przekłada się na mniejszą liczbę prac w tym temacie. Marciniak [68] zaprezentował dla przekładni stożkowej o kołowo-łukowej linii zęba system symulacji obróbki i współpracy zębów pozwalający na określenie odpowiednich parametrów procesu technologicznego obróbki kół. Wrażliwość przekładni na błędy montażowe przedstawione są w pracy Sobolaka [97]. Poprzez symulację w systemie CAD możliwa jest analiza wpływu błędów montażowych na ślad współpracy, co pozwala na określenie tolerancji wykonania i montażu kół. Również w środowisku CAD Skawiński i Siemiński [94] opracowali metodę określania śladu współpracy zębów i wykresów ruchowych odzwierciedlających sposób przekazywania ruchu. Model matematyczny pozwalający na określenie współpracy zębów i wartości nacisków powierzchniowych przedstawiła Sheveleva i in. [90]. Litvin i in. [63] zaproponowali procedurę pozwalającą na projektowanie i wytwarzanie przekładni stożkowych o niskim poziomie hałasu i drgań.

Przekładnie stożkowe, które przenoszą taką samą moc co walcowe, są kilkukrotnie droższe [73] ale w przeciwieństwie do przekładni walcowych, umożliwiają zmianę kierunku przenoszenia momentu obrotowego. W reduktorach wielostopniowych zazwyczaj pierwszy stopień jest stożkowy, gdzie moment obrotowy jest najmniejszy. Z analizy częstości uszkodzeń przekładni kąto-walcowych maszyn górniczych wynika, że najbardziej awaryjny jest pierwszy stopień stożkowy [96].

Na bezawaryjną i długotrwałą pracę przekładni ma wpływ: etap projektowania, wykonania, montażu i eksploatacji. Konstruktorzy, oprócz wykonywania tradycyjnych obliczeń wytrzymałościowych, mają do dyspozycji programy komputerowe, pozwalające na optymalizację przekładni. Jednak pomimo dokładnych obliczeń i prawidłowo zaprojektowanej konstrukcji błędy na etapie wytwarzania poszczególnych części mogą nie pozwolić na uzyskanie

wymaganych parametrów przekładni założonych przez konstruktora [76]. Również w przypadku prawidłowego zaprojektowania i wykonania przekładni, nieprawidłowo przeprowadzony proces montażu, spowoduje przedwczesne zużycie kół zębatach [14, 76].

Badanie śladu współpracy, który jest głównym wskaźnikiem poprawnego wykonania kół zębatach stożkowych [113], pozwala wnioskować o [86]:

- dokładności zazębienia,
- gładkości obrobionych powierzchni,
- dokładności kątów zarysów, kątów stożków oraz linii zęba,
- prawidłowości montażu kół w korpusie,
- udziale wielkości roboczej części zęba w całkowitej powierzchni bocznej.

Jeszcze przed nacięciem kół próbnymi możliwa jest teoretyczna analiza śladu współpracy zębów (TCA – Tooth Contact Analysis) polegająca na wygenerowaniu powierzchni zębów kół zębatach. Umożliwia to obliczenie optymalnych parametrów nastawczych dla obrabiarek i zmniejszenie do minimum bardzo kosztownych i czasochłonnych prób. Następnie ślad współpracy sprawdzany jest w procesie opanowywania obróbki na miękko, wykańczającej i po wykonaniu, aby uzyskać wytyczne dla montażu przekładni [113] oraz w trakcie montażu.

Z powyższych rozważań wynika, że etap montażu przekładni stożkowych wpływa na ich parametry użytkowe a ślad współpracy świadczy o jego prawidłowości. Ustalając zależność między wielkościami charakteryzującymi ślad współpracy a cechami sygnału drganiowego w monografii założono, że możliwa jest kontrola jakości montażu oraz wykonania. Sygnał wibroakustyczny jest bardzo pojemny informacyjnie, ale jest także skomplikowany i zawiera zakłócenia. Dlatego w pracy podjęto próbę redukcji zakłóceń a jako algorytm wnioskujący wybrano sztuczne sieci neuronowe należące do metod sztucznej inteligencji. Charakteryzują się one możliwością modelowania zagadnień nieliniowych poprzez naukę na przygotowanych przykładach i są z powodzeniem stosowane w diagnostyce. W celu ustalenia wpływu błędów montażowych na pracę przekładni, przeprowadzono badania symulacyjne.

Jeżeli założenia okażą się prawdziwe proponowana metoda będzie umożliwiać, w stosunkowo krótkim czasie i obiektywnie, bezdemontażową ocenę stanu technicznego przekładni. W szczególności metoda pozwoli na:

- kontrolę poprawności ustawienia kół zębatach,
- sprawdzenie, czy między montowane części (np. korpus i łożysko) nie dostały się zanieczyszczenia,
- wykrycie przypadkowej zamiany kół zębatach,
- porównanie pracy różnych grup monterów.

Przekładnie używane w napędach lotniczych mają bezpośredni wpływ na bezpieczeństwo ludzi, dlatego też każde ekonomicznie uzasadnione działanie mające wpływ na poprawę niezawodności i trwałości przekładni powinno być podjęte.

2. DIAGNOSTYKA WIBROAKUSTYCZNA – ZAGADNIENIA TEORETYCZNE I PRAKTYCZNE

Istnieje wiele różnych definicji diagnostyki technicznej np. [7, 22], które można znaleźć zebrane np. w pracy [74]. Według jednej z definicji [74] diagnostyka techniczna to: „zespół przedsięwzięć (metod i środków) prowadzących do stwierdzenia stanu technicznego eksploatowanych urządzeń. Określenie tego stanu dokonywane jest przez kontrolę zdolności urządzeń do działania, lokalizowanie stwierdzonych uszkodzeń, a także postawienie prognozy dotyczącej niezawodności działania tych urządzeń.” Jest to dość ogólna definicja, która nie ogranicza sposobu uzyskania informacji potrzebnej do określenia stanu technicznego obiektu. Badania przedstawione w niniejszej pracy są zgodne z definicją np. [42, 62], ograniczającą poznanie stanu technicznego do metod diagnozowania, nie wymagających demontażu maszyny.


Podstawowym celem diagnostyki technicznej jest określenie stanu technicznego. Wyodrębnić można również cele szczegółowe [19, 53]:

- diagnozę – określenie aktualnego stanu technicznego,
- prognozę – przewidywanie przyszłego stanu obiektu w określonych ramach czasowych,
- genezę – identyfikację przyczyn zaistnienia bieżącego stanu.

Diagnozowaną maszynę¹ można rozpatrywać jako system, w którym uwzględnia się przepływ energii i informacji (rys. 2.1). Na wejściu obiektu występuje energia, która zostaje przetworzona w maszynie na energię użyteczną. Jako że nie ma urządzeń o 100% sprawności, część energii zostaje rozproszona. Energia użyteczna wyjściowa może być w takiej samej formie jak wejściowa lub zostać przekształcona zgodnie z funkcją maszyny. Natomiast energia tracona, dyssypowana jest w postaci procesów reszkowych tj.: termicznych, akustycznych, wibracyjnych i innych.

W praktyce, diagnostyka techniczna sprowadza się do pomiarów dostępnych sygnałów diagnostycznych, na podstawie których, wnioskuje się o stanie obiektu. Można mierzyć parametry funkcjonalne maszyny a więc, w zależności od typu obiektu, może to być moment obrotowy, prędkość, ciśnienie itp. Inną możliwością jest pomiar procesów reszkowych, „które w sposób niezamierzony, ale i nieodłączny towarzyszą funkcjonowaniu maszyn” [19]. Ich moc jest zazwyczaj znikoma w porównaniu do mocy wejściowej i mają one działanie najczęściej degradujące. Wśród tych procesów można wymienić np. drgania i hałas. Zaletą tego sposobu pozyskania informacji o obiekcie jest fakt, iż odbywa się on bez wyłączenia z ruchu maszyny i bez jej demontażu.

¹ Zgodnie z definicją [72]: Tu maszyną będziemy nazywać urządzenie, w którym z udziałem ruchu mechanicznego zachodzi proces energetyczny polegający na wykonaniu pracy użytecznej lub przekształceniu energii.




Rys. 2.1. Możliwości diagnozowania maszyny działającej jako system z przepływem energii i informacji [19]

Istnieje też trzecia możliwość uzyskania informacji o stanie obiektu [74] poprzez zastosowanie specjalnych urządzeń zewnętrznych. Wykorzystują one procesy fizyczno-chemiczne jak promieniowanie rentgenowskie, promieniotwórczość itp., za pośrednictwem których, możliwa jest ocena stanu technicznego obiektu. Metody te zaliczane są do grupy metod nieniszczących.

2.1. Klasyfikacja metod diagnostycznych

Przedstawiony poniżej podział metod diagnostycznych (rys. 2.2) uwzględni tylko metody wykorzystujące przyrządy do oceny stanu technicznego [74, 123].



Rys. 2.2. Podział przyrządowych metod diagnozowania zgodnie z rodzajem nośnika informacji [74, 123]

Nie przedstawiono tutaj metod organoleptycznych, gdyż są to metody bardziej subiektywne, a obecnie dąży się do stosowania metod przyrządowych, zapewniających pewną i obiektywną diagnozę. Taką potrzebę zauważono już na

początku istnienia diagnostyki technicznej jako dyscypliny teoretycznej, czyli w latach 60 ubiegłego stulecia [79].

Badania nieniszczące najczęściej umożliwiają badanie pojedynczych części maszyn. Wymagany jest do nich bezpośredni dostęp i dodatkowo nie mogą być one w ruchu.

Wykorzystując procesy robocze do diagnozowania, sprawdzana jest efektywność przetwarzania dostarczonej energii do maszyny poprzez pomiar momentu, przyspieszenia itp., ponieważ zużycie lub uszkodzenie nie pozwala na uzyskanie nominalnych wartości parametrów urządzenia. Jeżeli maszyna wytwarza produkty to jej stan techniczny można określić poprzez badanie jej wyrobów. Maszyna uszkodzona, zużyta lub wymagająca regulacji nie wytworzy produktu pełnowartościowego. Oprócz ostatnio wymienionej możliwości, metody wykorzystujące procesy robocze zazwyczaj wymagają czasowego wyłączenia maszyny na czas badań diagnostycznych.

W przeciwieństwie do wcześniej wymienionych metod, metody bazujące na procesach reszkowych, nie wymagają przerwy w pracy maszyny. Procesy te zawsze występują podczas działania maszyn. Ta grupa metod zostanie krótko scharakteryzowana z dokładniejszym wyjaśnieniem procesów wibroakustycznych, wykorzystywanych w niniejszej pracy.

Pomiar temperatury stosowany jest w przypadku maszyn/mechanizmów, dla których jej nadmierny wzrost lub spadek może spowodować uszkodzenie i/lub świadczy o stanie technicznym. Informacja o temperaturze uzyskana za pomocą czujnika temperatury określana jest tylko dla miejsca zamocowania czujnika, możliwe jest również uzyskanie mapy rozkładu temperatur za pomocą kamer termowizyjnych. Pomiar czujnikiem temperatury odbywa się zazwyczaj na obudowie urządzenia, a więc otrzymuje się wartość uśrednioną z pewną zwłoką czasową. Na podstawie informacji o wartości temperatury można wnioskować tylko o ogólnym stanie obiektu, ponieważ uzyskiwany jest tylko jeden parametr diagnostyczny a stan obiektu określony jest najczęściej k parametrami (k równa się najczęściej liczbie par kinematycznych [80]). Diagnostyka termiczna wykorzystywana jest do oceny stanu łożysk, kadłubów maszyn energetycznych itp.

Przykładem wykorzystania zjawiska generowania potencjałów elektrycznych przy tarcia, są łożyska ślizgowe. Stan warstwy wierzchniej panewek i czopa, rodzaj i jakość oleju, warunki pracy (obciążenie, prędkość) mają wpływ na generowane potencjały elektryczne i mogą być użyte jako parametry diagnostyczne łożyska [42].

Jest kilka możliwości badania produktów zużycia znajdujących się w oleju smarowym, hydraulicznym lub cieczy chłodzącej np. metody magnetyczne, ferrografia, analiza spektralna oleju. Metody te umożliwiają postawienie diagnozy o ogólnym stanie obiektu (metody magnetyczne) do rozróżnienia typu uszkodzenia (analiza spektralna oleju) [19, 7, 18].

W wyniku działania maszyn wzbudzone są drgania, które mogą się rozchodzić tylko w ośrodku sprężystym. Podział podstawowych źródeł drgań mechanicznych w obiektach technicznych jest następujący [42, 74]:

- aerodynamiczne, powodowane są głównie zawirowaniami, tarciami, niejednorodnością strumienia przepływającego gazu i pulsacjami,
- hydrauliczne, wynikają z przepływu cieczy (niejednorodnego rozkładu prędkości i ciśnienia) oraz procesów kawitacyjnych,
- elektromagnetyczne, spowodowane są oddziaływaniem zmiennych pól magnetycznych np. w silnikach elektrycznych,
- mechaniczne, generowane są głównie przez zderzenia w parach kinematycznych (siły impulsowe), niewyrównoważenie części i ruch elementów ze zmiennym przyspieszeniem (siły bezwładności) oraz tarcie występujące między współpracującymi elementami (siły tarcia).

Drgania, zaliczane do mechanicznych, są podstawowym generatorem drgań w maszynach. Występuje ścisły związek między tym typem drgań a stanem technicznym par kinematycznych.

Zderzenia współpracujących części maszyn spowodowane są występowaniem luzu między nimi. Z diagnostycznego punktu widzenia istnieje zależność pomiędzy stanem technicznym pary kinematycznej a zachodzącym zderzeniem. Drgania wywołane przez zderzenia są zjawiskiem wtórnym uzależnionym od zderzeń. W zderzeniu ciał istotne są dwie cechy: czas trwania zderzenia i prędkość zderzających się elementów. Czas trwania zderzenia zależy od wielkości, kształtu i rodzaju materiału, z jakiego wykonane są części. Są to właściwości danej pary, które determinują częstotliwość drgań. Natomiast prędkość zderzenia uzależniona jest od luzów występujących w danej parze kinematycznej. Im większa prędkość zderzenia a więc luz, tym większa jest amplituda drgań. Charakterystyczne dla drgań wywołanych przez zderzenia jest to, iż mają małą amplitudę przemieszczeń, dużą przyspieszeń i wysoką częstotliwość [42]. Drgania, powstające w wyniku zderzeń części, rozchodzą się w materiale maszyny i odbierane są poprzez przetwornik drgań, umieszczony na obudowie. Taki sygnał dla rzeczywistego obiektu badań jest skomplikowany i jednym z podstawowych zadań diagnostyki jest rozdzielenie sygnału na składowe, generowane przez poszczególne pary kinematyczne. Dla stałych warunków pracy maszyny czas trwania zderzenia a więc właściwości części są w zasadzie stałe. Jest to pierwsza cecha, która pozwala na wydzielenie sygnału generowanego przez daną parę. Wiedza o okresie następowania zderzeń w parach kinematycznych w maszynie i momencie czasu uderzenia stwarza dodatkowe możliwości wydobycia z sygnału informacji o diagnozowanej parze.


Drugim źródłem drgań mechanicznych są siły bezwładności. Podstawową przyczyną powstawania sił bezwładności jest niewyrównoważenie części i ruch ze zmiennym przyspieszeniem. Możemy wyróżnić czynniki konstrukcyjne, technologiczne, produkcyjne i eksploatacyjne, powodujące niewyrównoważenie [65]. Konstruktor, projektując wał korbowy, nie wyrównoważa go całkowicie,

zakłada pewną wartość za dopuszczalną, a więc jest to przykład czynnika konstrukcyjnego. Wady materiałowe w postaci wtrąceń, rzadziwności odlewniczych zaliczamy do czynników technologicznych a niedokładności procesów wytwarzania, czyli niedotrzymanie tolerancji wymiarów i nieprawidłowy montaż, kwalifikujemy do czynników produkcyjnych. W trakcie użytkowania ubytki materiału, odkształcenia plastyczne itp. powodują niewyrównoważenie i są to czynniki eksploatacyjne. Ogólnie niewyrównoważenie części wirujących można podzielić na statyczne i dynamiczne [42]. Jeżeli główna oś bezwładności jest przesunięta i równoległa do osi obrotu, mamy do czynienia z nierównoważeniem statycznym. Natomiast jeżeli jest przesunięta i nierównoległa, mówimy o niewyrównoważeniu dynamicznym. Drgania spowodowane przez niewyrównoważenie są dość łatwo identyfikowalne w widmie sygnału drgań, ponieważ mają częstotliwość równą częstotliwości obrotowej niewyrównowanej części. Są to zazwyczaj małe częstotliwości z dużymi amplitudami przemieszczeń i małymi amplitudami przyspieszeń [42]. Dokonując pomiaru na dwóch łożyskach, poprzez porównanie faz uzyskanych sygnałów możemy określić typ niewyrównoważenia [19].

Drgania powstają również w wyniku tarcia, które występuje podczas ruchu względnego części będących w kontakcie. Dotyczy to także przypadków, gdzie pomiędzy współpracującymi powierzchniami jest smar. Siły tarcia mają charakter losowych impulsów o krótkim czasie trwania i małej amplitudzie. Zgodne jest to z jedną z teorii tarcia, według której podczas ruchu względnego elementów następuje wygładzenie i ścięcie mikronierówności. Dlatego też drgania wywołane przez tarcie mają charakter szerokopasmowy. Smarowanie zmniejsza siły tarcia a więc i intensywność drgań.

2.2. Generacja i propagacja drgań


Drgania wywoływane są przez procesy pierwotne (zdarzenia elementarne) φ_i , najczęściej powstające w parze kinematycznej (rys. 2.3). Postać i -tego zdarzenia elementarnego jest uzależniona od konstrukcji i stanu technicznego maszyny [19]. Poszczególne zdarzenia elementarne nie są takie same, co wynika m.in. ze zmiennej prędkości obrotowej źródła napędu, zakłóceń pochodzących z otaczającego środowiska, zmiennego obciążenia. Przy cyklicznej pracy urządzenia powstaje ciąg zdarzeń elementarnych, czyli proces oznaczony jako x , który odzwierciedla stan dynamiczny obiektu. Powoduje on pobudzenie do drgań wszystkich elementów maszyny. Sygnał y odbierany za pomocą przetwornika drgań z powierzchni korpusu może być określony, dla najprostszego przypadku, jako splot procesu wymuszającego drgania x i odpowiedzi dynamicznej układu o charakterystyce impulsowej h [19]. Dodatkowo postać odbieranego sygnału y uzależniona jest od miejsca odbioru.



Rys. 2.3. Transformacja procesu pierwotnego $\varphi_i(t, \Theta)$ na sygnał diagnostyczny y [14]

Powyższe rozważania dotyczyły jednego źródła generacji drgań, w rzeczywistych maszynach takich generatorów jest więcej. W przypadku drgań jednostopniowej przekładni zębatej, głównym czynnikiem drgań jest oddziaływanie dynamiczne w strefie zazębienia. Moment napędowy przenoszony jest przez zęby w sposób dyskretny – zęby, wchodząc w przypór, zderzają się. Spowodowane jest to błędami wykonawczymi poszczególnych części, błędami montażowymi, zużyciem, odkształcaniem zębów i zmienną sztywnością, wynikającą z liczby przyporu. Dodatkowo, w trakcie współpracy zębów, występuje tarcie między powierzchniami roboczymi. Drugim źródłem drgań są łożyska, zwłaszcza toczne, które charakteryzują się zmienną sztywnością, spowodowaną obracaniem się elementów tocznych w trakcie pracy łożyska, w wyniku czego przemieszczają się względem linii działania obciążenia. Upraszczając zagadnienie, dla łożyska poprzecznego, w skrajnym przypadku, obciążenie przenoszone jest przez jeden lub dwa elementy toczne. Oprócz czynników konstrukcyjnych na drgania, generowane przez łożysko, mają wpływ czynniki produkcyjne i eksploatacyjne. Dla przekładni ze smarowaniem zanurzeniowym ostatnim źródłem drgań są wały. Powodem wystąpienia drgań jest niewyrównoważenie wału wraz z osadzonym na nim kołem zębatym. Najczęściej koło zębate połączone jest z wałem za pomocą połączenia kształtowego (połączenia wpustowego), które powoduje, że wał ma zmienną sztywność giętną. Jest to kolejna przyczyna generacji drgań parametrycznych przez wał.

Rejestrując drgania na obudowie przekładni otrzymywany jest sygnał zawierający składowe ze wszystkich źródeł drgań (rys. 2.4). Ponieważ koła zębate, wały i łożyska są połączone szeregowo, występuje zjawisko modulacji. Drgania pochodzące od zazębienia zmodulowane są przez zmienną podatność łożysk [20]. Wały cechują się również właściwościami rezonansowymi, które powodują zakłócenie sygnału zazębienia. Korpus przekładni ma skomplikowaną strukturę rezonansową [110], przez co w różnych jego miejscach odbieramy inne sygnały drgań.



Rys. 2.4. Schemat propagacji drgań w przekładni zębatej

2.3. Teoretyczne widmo drgań przekładni zębatej

Dominująca składowa w widmie (rys. 2.5) pochodzi od zazębienia f_z i spowodowana jest przez współpracę zębów, czyli wchodzenie zębów w przypór. Im większe błędy produkcyjne, odkształcenia części, które są określone przez błąd przełożenia, tym większa amplituda drgań, pochodzących od zazębienia. Dodatkowo, w widmie sygnału pojawiają się składowe, mające częstotliwość równą wielokrotności częstotliwości zazębienia, nazywane harmonicznymi. Powstanie harmonicznego zazębienia spowodowane jest tym, iż w trakcie pracy przekładni zęby obciążone są zmienną siłą, której wykres nie jest idealną sinusoidą [27]. Amplituda harmonicznego zazębienia zależy od kształtu wykresu zmienności siły oraz innych impulsowych sił. Częstotliwość zazębienia (pierwszą harmoniczną zazębienia) obliczamy ze wzoru [7, 21, 20]:


$$f_z = \frac{n_1 z_1}{60} = \frac{n_2 z_2}{60} \text{ [Hz]} \quad (1)$$

gdzie:

n_1, n_2 – prędkości obrotowe kół zębatych lub wałów, na których osadzone są koła [obr/min],

z_1, z_2 – liczby zębów kół zębatych.

Kolejne harmoniczne ząbienia, których liczba istotnych energetycznie nie przekracza pięć, określone są zależnością if_z (gdzie $i = 2, 3, \dots, I$).



Rys. 2.5. Teoretyczne widmo amplitudowe drgań jednostopniowej przekładni zębatej (opracowano na podstawie [19])

Na początku widma widoczne są składowe związane z obrotami wałów f_{01} , f_{02} , które powstały poprzez mimośrodowe osadzenie kół zębatych oraz niewyrównoważenie wałów. Mogą pojawić się wyższe harmoniczne spowodowane nieosiowością wałów [92] lub wystąpieniem precesji przeciwbieżnej [65]. Częstotliwość obrotową opisuje zależność:

$$f_0 = \frac{n}{60} = \frac{\omega}{2\pi} \text{ [Hz]} \quad (2)$$

gdzie:


n – prędkość obrotowa wału [obr/min],

ω – prędkość kątowna [rad/s].

Analogicznie, tak jak w przypadku harmonicznym ząbieniu, oblicza się kolejne harmoniczne obrotowe wału if_0 (gdzie $i = 2, 3, \dots, I$).

Wokół harmonicznego ząbienia występują tzw. „wstęgi boczne”. Pojawienie się ich w widmie spowodowane jest modulacją amplitudową, częstotliwościową i fazową [93]. Rozważania, dotyczące modulacji fazowej, można też zastosować do modulacji częstotliwościowej [20]. Ogólnie modulację definiuje się jako [70]: „ciągłą zmianę przez sygnał modulujący jednego (lub więcej niż jednego) parametru okresowego sygnału nośnego”. W przypadku maszyn brak jest pełnej informacji o sygnale modulującym i nośnym a występujące zakłócenia utrudniają analizę modulacji sygnału drganiowego [1]. Modulacja amplitudowa spowodowana jest zmiennym obciążeniem (które z kolei powoduje ugięcie zębów [84]) oraz mimośrodowym osadzeniem kół

zębatach [92]. Błąd podziałki powoduje zmiany siły międzyzębnej, a w konsekwencji fluktuacje momentu napędowego i prędkości obrotowej, które wywołują modulację fazową [70]. Generalnie, wg Randala [84], błąd lokalny, który zaburza sygnał drgań w krótkim okresie czasu, implikuje powstanie pasm bocznych o małej amplitudzie i szerokim paśmie częstotliwości, natomiast błąd rozproszony – o wysokiej amplitudzie i wąskim paśmie częstotliwości (rys. 2.6).



Rys. 2.6. Wpływ uszkodzenia lokalnego i rozproszonego na charakterystykę czasową i częstotliwościową [84]

Zużycie przekładni powoduje wzrost poziomu emisji wibroakustycznej. Im procesy (różnego typu) zużycia i uszkodzenia narastają, tym bardziej skomplikowane jest widmo drgań przekładni.

W widmie może wystąpić fikcyjna częstotliwość (ang. ghost frequency) o znacznej amplitudzie, niezwiązanej z harmonicznymi zazębienia i prędkościami obrotowymi wałów, a spowodowana procesem wytwarzania. Wynika to z niedokładności wykonania napędu maszyny, odpowiedzialnego za obrót koła zębatego w trakcie wykonywania uzębienia.

Przypór tych samych zębów następuje co kilka lub kilkadziesiąt obrotów koła zębatego, dając w rezultacie podobne wymuszenie [7]. W widmie drgań może być to widoczne jako kinematyczna częstotliwość zazębienia f_k , obliczana z zależności [122]:

$$f_k = \frac{f_z}{NWW(z_1, z_2)} \quad (3)$$

gdzie:

$NWW(z_1, z_2)$ – najmniejsza wspólna wielokrotność liczby zębów zębnika i współpracującego z nim koła.

Podstawowy model matematyczny sygnału drgań dla przekładni zębatej, wykonanej bezbłędnie, z podatnymi zębami, można przybliżyć równaniem [60, 88]:

$$x(t) = \sum_{i=1}^I P_i \cos(i\omega t + \phi_i) + w(t) \quad (4)$$

gdzie:

P_i – amplituda i -tej harmonicznej,
 ω – częstotliwość zazębienia; $\omega = 2\pi f_0 z$,
 f_0 – częstotliwość obrotowa wału,
 z – liczba zębów koła zębatego,
 ϕ_i – faza i -tej harmonicznej,
 $w(t)$ – biały szum.

Z powodu niedokładności wytwarzania i montażu sygnał jest modulowany amplitudowo i fazowo. Sygnał zmodulowany amplitudowo a_i i fazowo b_i można zapisać w postaci [89]:

$$a_i(t) = \sum_{i=1}^I A_i \cos(i\omega_r t + \alpha_i) \quad (5)$$

$$b_i(t) = \sum_{i=1}^I B_i \cos(i\omega_r t + \beta_i) \quad (6)$$

gdzie:

$\omega_r = 2\pi f_r$.

Podstawiając te zależności do równania (4) otrzymamy sygnał drgań, który jest bardziej ścisły, o postaci:

$$x(t) = \sum_{i=1}^I P_i [1 + a_i(t)] \cos(i\omega t + \phi_i + b_i(t)) + w(t) \quad (7)$$

Wytwarzana przez przekładnię emisja wibroakustyczna zależy także od stopnia obciążenia i prędkości obrotowej. Dla bardzo dużych prędkości obrotowych czynnik smarujący lub powietrze może być wyrzucane z pomiędzy zazębiających się zębów, z prędkością naddźwiękową, co może być przyczyną dominującego źródła dźwięku [27].

2.4. Przegląd metod diagnostyki drganiowej przekładni zębatych

Literatura związana z diagnostyką wibroakustyczną jest bardzo bogata, a badania są nieustannie prowadzone od kilku dekad. Dodatkowo, metody badań zapożyczane są również z innych dziedzin naukowych np. telekomunikacji, dlatego liczba różnych metod, umożliwiających bądź zwiększających pewność diagnozy, jest znaczna. Niemniej jednak w pracy przedstawiono metody, które potwierdziły swoją skuteczność i mają ugruntowaną pozycję oraz nowe metody rozwijane dynamicznie, których przydatność została potwierdzona w licznych publikacjach.

Większość literatury prezentuje wyniki dla pomiarów drgań wykonanych bezpośrednio na korpusie przekładni. Podstawową wadą pomiaru mikrofonem jest rejestracja oprócz hałasu emitowanego przez badaną maszynę tła akustycznego (zakłóceń) np. hałasu emitowanego przez niebadane maszyny [14, 74]. Również przedmioty jak ściana, obok których znajduje się badany przedmiot, mogą zniekształcić hałas badanej maszyny [80]. Dlatego w niniejszej pracy drgania są podstawowym nośnikiem informacji o stanie przekładni zębatych. Należy zaznaczyć, że nie wszyscy badacze wyrażają taki pogląd np. [23].

2.4.1. Selekcja użytecznego sygnału wibroakustycznego

Sygnał wibroakustyczny posiada dużą pojemność informacyjną, co powoduje, że zawiera informacje o całej badanej maszynie. Zazwyczaj diagnozowane są wybrane części (najczęściej pary kinematyczne), wchodzące w skład badanego obiektu, a więc informacje o innych częściach stanowią zakłócenie w sygnale. Ogólny model sygnału wibroakustycznego może być zapisany w postaci [74]:

$$y(t) = k(t) \cdot y_1(t) + m(t) \quad (8)$$

gdzie:

$y_1(t)$ – użyteczna część sygnału, zawierająca informację o badanej części (częściach),

$k(t)$ – zakłócenia multiplikatywne, wynikające ze zmian warunków diagnozowania: prędkości kątowej, obciążenia, stanu cieplnego oraz właściwości toru pomiarowego,

$m(t)$ – zakłócenia addytywne, spowodowane niepełnym opisaniem stanu par kinematycznych za pomocą zbioru parametrów stanu, a także nakładaniem się na sygnał użyteczny sygnałów niebadanych par kinematycznych.

Aby zwiększyć stosunek sygnału do szumu, powinny być podjęte działania, mające na celu minimalizację zakłóceń. Można to osiągnąć poprzez

odpowiednie zaplanowanie badań oraz wstępne przetwarzanie sygnałów. Poniżej przedstawiono zalecenia i metody, umożliwiające selekcję sygnału użytecznego [19, 20, 74].

Oceniając stan techniczny maszyny za pomocą sygnału wibroakustycznego, korzystniej jest rejestrować drgania niż hałas, z przyczyn wymienionych na początku podrozdziału.

Kolejna decyzja, jaką należy podjąć, to wybór między pomiarem przemieszczenia, prędkości albo przyspieszenia drgań. Uzależnione jest to od częstotliwości generowanej przez przekładnię zębatą a dokładniej diagnozowanego elementu. Generalnie Cempel [19], Niziński i Michalski [74] zalecają pomiar przyspieszeń a Bartelmus [7], w zależności od zakresu częstotliwości, pomiar prędkości i przyspieszenia drgań. Należy pamiętać, że w wyniku pojedynczego całkowania przyspieszenia drgań otrzymujemy prędkość a dwukrotnego całkowania przemieszczenie drgań.

Wybór miejsca mocowania przetwornika drgań związany jest z zagadnieniem selekcji przestrzennej sygnału. Polska Norma PN-ISO 10816-1 [82], dotycząca oceny drgań maszyn zaleca, aby pomiar odbywał się na obudowach łożysk i innych podporach lub elementach konstrukcyjnych, które przenoszą obciążenia dynamiczne. Miejsce mocowania przetwornika powinno charakteryzować się także dużą sztywnością. Według PN-ISO 8579-2 [83], która określa drgania mechaniczne podczas odbioru przekładni zębatych, pomiar może odbywać się na korpusie lub wale przekładni. Pomiar drgań względnych wału zalecany jest dla łożysk ślizgowych i może być połączony z pomiarem drgań bezwzględnych korpusu. Drgania powinno się mierzyć w trzech wzajemnie prostopadłych kierunkach: osiowym oraz w płaszczyźnie prostopadłej do osi obrotu w kierunku poziomy i pionowy. Liczba punktów pomiarowych zależy od złożoności przekładni oraz celu badań. Odległość między badaną częścią a miejscem mocowania przetwornika powinna być jak najmniejsza. Przetworniki drgań charakteryzują się dużą selektywnością kierunkową, można to wykorzystać do eliminacji drgań niepożądanych, stosując kilka przetworników drgań. Przykładem tego dla przekładni zębatych może być pomiar drgań skrętnych koła zębatego. Stosuje się w takim przypadku dwa lub cztery przetworniki drgań odpowiednio usytuowane na kole zębatym względem siebie tzn. oś główna przetworników jest styczna do okręgu, który zataczają, a same przetworniki rozmieszczone są symetrycznie. Sumując sygnały z przetworników zwiększa się poziom sygnału pochodzący od drgań skrętnych a zmniejsza wpływ drgań giętnych wału [96]. Dla pomiarów hałasu, w celu eliminacji niepożądanych źródeł dźwięku, pochodzących np. od innych maszyn, stosuje się mikrofony o wąskiej charakterystyce jednokierunkowej.

W maszynach, w których występują drgania generowane przez pary kinematyczne w określonej kolejności, wynikającej z konstrukcji maszyny, możliwa jest selekcja czasowa. Polega ona na rejestracji sygnału tylko w momencie, kiedy badana para kinematyczna generuje drgania. Wymagany jest

do tego dodatkowy sygnał odniesienia, wyzwalający pomiar o określonym przedziale czasowym. Wykorzystał to McFadden do rejestracji drgań przekładni planetarnej [84]. Rejestrując drgania w pobliżu koła koronowego, sygnał drgań jest wyraźnie zależny od odległości między kołem satelitarnym a przetwornikiem drgań. Zastosowano więc selekcję czasową aby uzyskać sygnał dla przyporu pojedynczego zęba w momencie, kiedy współpraca zębów następowała naprzeciwko przetwornika. Następnie, w momencie kiedy to samo koło satelitarne mijalo przetwornik, uzyskiwano sygnał dla innego zęba. Informacja o kolejności przyporu zębów wynika z kinematyki przekładni. Procedurę powtarzano aż do uzyskania danych dla wszystkich zębów kół zębatych, eliminując wpływ położenia koła satelitarnego względem przetwornika drgań.

Selekcja widmowa (częstotliwościowa) realizowana jest za pomocą filtracji lub uśredniania. Filtracja wykonywana jest na sygnale w dziedzinie czasu a efekt filtracji sprawdzany jest na widmie sygnału [64]. Aby wykonać filtrację, musimy znać częstotliwości w których znajduje się informacja o badanym obiekcie (bądź częściach) lub pasmo, w którym występują zakłócenia. Zastosowane mogą być wtedy podstawowe filtry: dolnoprzepustowe, górnoprzepustowe, pasmowoprzepustowe lub pasmowozaporowe. Dla przekładni zębatych stosowane są również bardziej wyrafinowane metody filtracji, polegające na filtrowaniu sygnału zespołem filtrów. Można uzyskać w ten sposób sygnał resztkowy i różnicowy. Sygnał resztkowy definiowany jest jako sygnał z usuniętymi składowymi obrotowymi wałów i częstotliwościami zazębienia wraz z harmonicznymi, natomiast sygnał różnicowy ma dodatkowo usunięte wstęgi boczne, związane z częstotliwościami obrotowymi wałów wokół harmonicznymi zazębienia [66, 109]. Występują również inne definicje tych sygnałów np. [88]. W przypadku, kiedy zakłócenia mają charakter szumu szerokopasmowego, można zastosować odszumianie za pomocą transformaty falkowej. Metoda ta została zastosowana w niniejszej pracy i omówiono ją bardziej szczegółowo w dalszej części monografii. W przypadku zmiennych warunków eksploatacyjnych (obciążenie, prędkość obrotowa, temperatura), które powodują zmienną w czasie strukturę sygnału, Zimroz wskazuje na konieczność stosowania filtracji adaptacyjnej [121]. Filtry adaptacyjne mogą np. dostosowywać swoją częstotliwość środkową do zmiennej częstotliwości sygnału [119].

Można wyróżnić trzy rodzaje uśredniania sygnałów ze względu na dziedzinę, w której ta operacja jest wykonywana: w dziedzinie czasu, częstotliwości i współczynników falkowych. Pierwsza metoda ma ugruntowaną pozycję i nosi nazwę uśredniania synchronicznego (ang. time domain averaging lub time synchronous averaging (TSA)). Jest to jedno z podstawowych narzędzi stosowanych przy ocenie maszyn o ruchu obrotowym głównych części, takich jak przekładnie zębate [25]. Dzięki temu możliwe jest odseparowanie okresowych przebiegów z zaszumionego sygnału. Realizowane jest to poprzez uśrednianie ze sobą szeregu odcinków czasowych, odpowiadających jednemu

okresowi sygnału synchronizującego [5]. Wymagany jest więc dodatkowy sygnał synchronizujący z czujnika położenia lub enkodera. Przy małej fluktuacji prędkości obrotowej możliwe jest uśrednianie synchroniczne tylko na podstawie sygnału drgań, z którego również uzyskiwana jest informacja (przez demodulację) o położeniu kątowym wału. Źródła drgań niesynchroniczne ze stopniem, z którego pochodzi sygnał synchronizujący, jak i inne niebadane stopnie przekładni lub inne maszyny współpracujące z badaną maszyną, są tłumione. Uśrednianie synchroniczne ma głównie zastosowanie w wykrywaniu lokalnych uszkodzeń, takich jak wyłamany ząb [26]. Rozwinięciem powyższej techniki jest połączenie uśredniania synchronicznego i transformaty falkowej, zaproponowane przez Halima i jego współpracowników. W tej metodzie uśredniane są współczynniki falkowe, co ma zapewnić możliwość jednoczesnego wykrywania uszkodzeń lokalnych i rozproszonych [41]. Uśrednianie w dziedzinie częstotliwości również zapewnia zwiększenie stosunku sygnału do szumu i może być realizowane na dwa sposoby: koherentny i niekoherentny. W uśrednianiu niekoherentnym sumowane są moduły prążków widma a w koherentnym oddzielnie części rzeczywiste i urojone [64].

Idea eliminacji zakłóceń przez demodulację sygnału wibroakustycznego opiera się na założeniu, iż przebieg wysokoczęstotliwościowy (sygnał nośny) nieniosący informacji diagnostycznej zmodulowany jest niskoczęstotliwościowym sygnałem informacyjnym. Przykładem par kinematycznych, podatnych na diagnozowanie tą techniką, są łożyska toczne i koła zębate. W przekładniach zębatych sygnałem nośnym są harmoniczne zazębienia, rezonanse bieżni łożysk, wieńców kół zębatych, obudowy przekładni i innych elementów [20]. Przykładowe zastosowania demodulacji to: wykrywanie lokalnych uszkodzeń kół zębatych [6], badanie zmienności warunków przyporu reduktora walcowego [70]. Stosując transformatę Hiberta można dokonać demodulacji amplitudowej i fazowej [27].

2.4.1.1. Metody redukujące wymiar danych

Obecne systemy akwizycji danych pozwalają na gromadzenie bardzo dużych zbiorów informacji. Stosując nawet wcześniej wymienione metody, w wyniku badań można uzyskać bardzo dużą liczbę danych. Część z nich może być nieistotna z punktu widzenia postawionego celu lub niosąca tę samą informację. Również dalsze przetwarzanie danych może powodować ich wzrost (np. obliczenie współczynników falkowych ciągłej transformaty falkowej). Redukcja wymiaru danych ma w zasadzie dwa podstawowe cele: poprawę budowanych modeli poprzez wykorzystanie optymalnych danych i ich wizualizację. Zaletą optymalnych danych jest krótszy czas obliczeń. Dane nadmiarowe i nieistotne mogą prowadzić do utworzenia skomplikowanego modelu, nieoddającego natury problemu, a zbyt dopasowanego do danych. W celu wizualizacji danych cztero i więcej wymiarowych wykorzystuje się metody redukujące ich

wymiar, aby móc je zwizualizować w przestrzeni dwu lub trójwymiarowej. Taka obserwacja pozwala na jakościową ocenę danych, analizę i lepsze zrozumienie. Ze względu na sposób redukcji wymiaru danych wyróżniamy dwie metody: odkrywanie cech (ang. feature extraction) i selekcję cech (ang. feature selection).

Odkrywanie, czyli ekstrakcja cech jest techniką, w której z oryginalnych cech (zmiennych, atrybutów) tworzone są nowe cechy poprzez transformacje liniową bądź nieliniową. Nowy zbiór cech jest redukowany na podstawie kryterium zależnego od wybranej metody. Wymienione zostaną tylko niektóre metody z tej grupy:

- analiza składowych głównych (ang. principal component analysis – PCA),
- analiza czynnikowa (ang. factor analysis – FA),
- skalowanie wielowymiarowe (ang. multidimensional scaling – MDS),
- analiza składowych niezależnych (ang. independent component analysis – ICA),
- nieliniowa analiza składowych głównych (ang. nonlinear principal components analysis – NLPCA).

Selekcja cech to technika, polegająca na wyborze z istniejących cech tych najbardziej przydatnych do rozwiązywanego zadania. Metody selekcji ze względu na sposób oceny cech dzieli się na [56]:

- metody filtrów (ang. filter method),
- metody opakowane (ang. wrapper approach),
- metody hybrydowe (ang. frappers approach),
- metody wbudowane (ang. embedded methods).

W metodach filtrów, wybór optymalnego podzbioru cech, odbywa się tylko w oparciu o właściwości danych bez angażowania algorytmu wnioskującego (np. klasyfikatora). Oblicza się przyjętą miarę, która służy do oceny wybranych cech. Zaletą tych metod jest szybkość działania oraz to, że uzyskane wyniki mogą być zastosowane do dowolnego algorytmu wnioskującego. Do wad zalicza się skłonność do wyboru dużego podzbioru cech, dlatego często konieczne jest arbitralne wybieranie liczby cech.

W metodach opakowanych proces selekcji optymalnych cech składa się z dwóch głównych algorytmów: algorytmu selekcji i algorytmu wnioskującego (np. klasyfikatora). Pierwszy algorytm wybiera podzbiór cech, który jest następnie sprawdzany np. na wytrenowanym klasyfikatorze poprzez ocenę błędu odpowiedzi klasyfikatora. Jako zalety tych metod w stosunku do filtrów zalicza się uzyskiwanie lepszych wyników. Wadą jest natomiast większa złożoność obliczeniowa, a więc i dłuższy czas obliczeń, a w przypadku bardzo dużych zbiorów danych, ograniczenia w stosowaniu. Algorytm wnioskujący, który brał udział w procesie wyboru cech i jest zoptymalizowany z wybranym podzbiorem, nie podlega zmianie, w przypadku wyboru innego algorytmu wnioskującego cała procedura powtarzana jest na nowo.

Metody hybrydowe są kombinacją metod filtrów i opakowanych. Algorytm selekcji jest z pierwszej metody, ale parametry filtracji dostrajane są w zale-

żności od wyników algorytmu wnioskującego. To podejście jest kompromisem pomiędzy szybkością działania a uzyskiwanymi wynikami oraz łączy wady i zalety obu metod.

Metody wbudowane są podobne do metod opakowanych. Algorytm wybierający cechy wbudowany jest w algorytm wnioskujący, selekcja cech i trening algorytmu wnioskującego zachodzi symultanicznie, podczas gdy w metodach opakowanych są to oddzielne procesy. Porównując je do metod opakowanych, są to metody szybsze i mniej wrażliwe na przeuczenie.

Po krótkim przedstawieniu metod selekcji i odkrywania cech należy jeszcze zaznaczyć różnice między tymi metodami, które mogą warunkować o ich zastosowaniu. Metoda odkrywania cech jest bardziej ogólną metodą, tworzy nowe cechy w oparciu o cały zbiór danych, jest też ona wykorzystywana do wizualizacji danych. Nowo powstałe cechy nie mają jednak sensu fizycznego, co może powodować trudności w zrozumieniu rozwiązywanego problemu. Dobór metody w ogólnym przypadku uzależniony jest od analizowanego zagadnienia.

Literatura odnosząca się do tych metod w kontekście oceny stanu technicznego przekładni zębatych nie jest zbyt bogata, jednak uzyskiwane rezultaty wskazują, że stosowanie metod redukcji danych poprawia skuteczność diagnozy. Jedną z najczęściej wykorzystywanych metod jest PCA. W pracach Zimroza i Bartkowiak [120, 9] stosowana jest do oceny stanu technicznego przekładni planetarnej jak również analiza zmiennych kanonicznych (ang. canonical discriminant analysis – CDA) i analiza komponentów krzywoliniowych (ang. curvilinear component analysis – CCA). W artykułach [45, 29] zastosowano PCA do oceny stanu reduktorów walcowych a dokładnie do wykrywania pęknięcia zęba przy podstawie. Bartelmus [8], badając stan reduktora stożkowo-planetarnego, uzyskał rozróżnienie stanów technicznych dla analizy czynnikowej. Metoda filtrów, zaliczana do metod selekcji cech, użyta jest np. w pracy [49] do wyboru optymalnych parametrów statystycznych. Wykorzystanie parametrów tylko najbardziej powiązanych ze stanem reduktora, zwiększyło poprawność klasyfikacji stanu.

2.4.2. Analiza widmowa sygnałów stacjonarnych

Dyskretne przekształcenie Fouriera (ang. Discrete Fourier Transform – DFT) jest jedną z podstawowych procedur stosowanych w diagnostyce maszyn. Działanie maszyn jest okresowe, a więc powtarza się z określoną częstotliwością, dlatego analiza częstotliwościowa jest tak dogodnym narzędziem, dostarczającym informacje o właściwościach obiektu. Równanie opisujące DFT może być zapisane w postaci:

$$X(m) = \sum_{n=0}^{N-1} x(n) [\cos(2\pi mn / N - j \sin(2\pi mn / N))] \quad (9)$$

gdzie:

$x(n)$ – sygnał dyskretny, $n = 0, 1, 2, \dots, N - 1$,

$X(m)$ – sygnał wyjściowy DFT, $m = 0, 1, 2, \dots, N - 1$,

N – liczba próbek sygnału wejściowego.

Na podstawie równania (9) można stwierdzić, że sygnał w dziedzinie czasu rozkładany jest za pomocą funkcji harmoniczych. Część rzeczywista sygnału reprezentowana jest przez funkcje cosinusoidalne a urojona przez funkcje sinusoidalne. Informacja zawarta w dziedzinie częstotliwości jest taka sama jak w dziedzinie czasu, jest ona tylko przedstawiana w innej formie. Istnieje odwrotne przekształcenie Fouriera (ang. Inverse Discrete Fourier Transform – IDFT), umożliwiające odtworzenie sygnału oryginalnego na podstawie części rzeczywistej i urojonej sygnału w dziedzinie częstotliwości.

Wyniki uzyskane z przekształcenia sygnału do dziedziny częstotliwości są najczęściej przedstawiane w postaci widma [53, 64, 111, 11, 77]:

- amplitudowego $X_{ampl}(m) = |X(m)| = \sqrt{X_{real}^2(m) + X_{imag}^2(m)},$
- fazowego $X_{phase}(m) = \arctg(X_{imag}(m) / X_{real}(m)),$
- mocy $X_p(m) = X_{ampl}^2(m) = X_{real}^2(m) + X_{imag}^2(m),$
- gęstości mocy $P(m) = \frac{1}{K} \sum_{k=1}^K \frac{1}{N} |X(m)|^2.$

gdzie:

X_{real} – część rzeczywista DFT,

X_{imag} – część urojona DFT,

K – liczba sygnałów (lub segmentów sygnału), dla których wyznaczana jest DFT.

Widmo fazowe jest rzadko wykorzystywane w diagnostyce maszyn. Rozdzielczość częstotliwości zależna jest od ilości próbek sygnału N i częstotliwości próbkowania f_s zgodnie z zależnością f_s/N . Jeżeli w sygnale występuje częstotliwość, która nie jest wielokrotnością częstotliwości podstawowej (rozdzielczości f_s/N), to w widmie wystąpi zjawisko zwane przeciekiem widmowym. Ta pojedyncza częstotliwość zmieni wartości wszystkich prążków wyjściowych DFT. Na widmie jest to widoczne w postaci prążka (piku) z „ogonami”, które mogą być mylące w interpretacji i zmniejszają rozróżnialność prążków. Zmniejszenie przecieku widmowego uzyskuje się, stosując funkcje okien inne niż prostokątne np. Hamminga, Blackmana. Są one kompromisem pomiędzy rozdzielczością widma a wielkością „ogonów”.

W praktycznych zastosowaniach zamiast procedury DFT używa się algorytmu szybkiego przekształcenia Fouriera (ang. Fast Fourier Transform –

FFT). Został on wprowadzony przez Cooleya i Tuckeya w 1965 r. Są to równoważne algorytmy. Właściwości, które posiada DFT, są zachowane przez FFT, przy czym FFT w zależności od długości analizowanego sygnału jest setki a nawet tysiące razy szybszy.

Jeżeli występuje potrzeba uzyskania wyższej rozdzielczości częstotliwościowej, stosuje się *zoom analysis*. Są dwie możliwości realizacji *zoom analysis*, wynikające z zależności na obliczanie rozdzielczości widma. Można zwiększyć liczbę próbek w sygnale i uzyskać widmo o wyższej rozdzielczości w całym zakresie częstotliwości. Druga możliwość to redukcja częstotliwości próbkowania. Stosuje się ją wtedy, gdy interesujący jest tylko fragment widma. Wiąże się to z przesunięciem częstotliwości badanego pasma i filtracją dolnoprzepustową [84].

2.4.3. Analiza sygnałów niestacjonarnych

Badanie maszyn, pracujących w zmiennych warunkach eksploatacyjnych, w trakcie rozruchu lub wybiegu, wymaga innego podejścia niż przekształcenie Fouriera. Wykonując FFT, traci się informację o położeniu częstotliwości w czasie. Rozwijane są więc metody czasowo-częstotliwościowe, umożliwiające otrzymanie informacji o widmie sygnału w zależności od czasu. Wśród najpopularniejszych metod można wymienić krótkoczasową transformatę Fouriera (ang. Short-Time Fourier Transform – STFT), transformatę Wignera-Ville’a (WV) i transformatę falkową (ang. Wavelet Transform – WT). Podstawowym problemem w analizach czasowo-częstotliwościowych jest uzyskanie wysokiej rozdzielczości w dziedzinie czasu i częstotliwości jednocześnie.

STFT realizowana jest poprzez wykonanie FFT na odcinku sygnału wyciętego przez przesuwające się okno [119]. Rozdzielczość czasowo-częstotliwościowa jest stała i zależy od długości okna. Krótkie okno powoduje, że rozdzielczość w dziedzinie czasu jest duża, a w dziedzinie częstotliwości mała, dla długiego okna jest odwrotnie.

Transformata WV ma najlepszą rozdzielczość czasowo-częstotliwościową. Jej głównym mankamentem są pasożytnicze interferencje wzajemne, utrudniające interpretację otrzymanego widma.

Ponieważ w niniejszej pracy nie są analizowane sygnały niestacjonarne, dokładniej omówiona zostanie tylko WT, wykorzystana do odsumiania i wizualizacji sygnałów.

2.4.3.1. Transformata falkowa

Rozwój WT w ciągu ostatnich dwudziestu kilku lat jest bardzo dynamiczny. Powstała bardzo duża liczba publikacji dotyczących matematycznych podstaw tego przekształcenia oraz jego zastosowań w różnych dziedzinach, takich jak technika, medycyna, chemia. Spowodowane jest to przede wszystkim

korzystnymi właściwościami tej metody oraz dostępnością programów komputerowych [10]. W diagnostyce WT służy głównie do wizualizacji struktury sygnału, odszumiania, kompresji i dekompozycji sygnału.

W odróżnieniu od DFT sygnał nie jest rozkładany przy pomocy funkcji trygonometrycznych, a za pomocą falek (ang. wavelets). Są to funkcje o skończonym nośniku, czyli ich wartości w sposób istotny różnią się od zera dla niedużej liczby argumentów. Jest wiele typów falek jak np. Haara, Daubechies, Coiflets, Biorthogonal. Falkę podstawową, matkę (ang. mother wavelet) wybiera się w zależności od badanego sygnału. Kształt falki powinien być jak najbardziej podobny do kształtu analizowanego sygnału, co skutkuje uzyskaniem niedużej liczby istotnych współczynników, odwzorowujących badany przebieg [4]. Z falki podstawowej ψ powstaje rodzina falek poprzez skalowanie i przesunięcie wg zależności:

$$\psi_{a,b} = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (10)$$

gdzie:

a – parametr skalujący,

b – parametr przesunięcia,

$1/\sqrt{|a|}$ – stała,

t – czas.

Częstotliwość falki a więc stopień rozciągnięcia uzależniony jest od parametru skalującego a , wyższy numer skali oznacza niższą częstotliwość [52]. Parametr przesunięcia b określa położenie falki względem sygnału dla określonego parametru skalującego, natomiast stała zapewnia normalizację energii dla każdej wartości skali.

Transformatę falkową dzielimy na ciągłą (ang. Continuous Wavelet Transform – CWT) i dyskretną (ang. Discrete Wavelet Transform – DWT). *Ciągła transformata falkowa* określona jest następująco [37]:

$$CWT(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \cdot \psi^*\left(\frac{t-b}{a}\right) dt \quad (11)$$

gdzie:


$x(t)$ – badany sygnał,

ψ^* – sprzężenie zespolone falki podstawowej ψ .

W wyniku tego przekształcenia otrzymujemy współczynniki falkowe, które są miarą korelacji sygnału i falki. Im większa wartość współczynnika, tym

większe podobieństwo kształtu sygnału i falki [106]. Idea obliczania CWT, poprzez skalowanie i przesuwanie falki podstawowej, pokazana jest na rysunku 2.7.

CWT oblicza współczynniki falkowe dla każdej skali. Powoduje to bardzo dokładne odwzorowanie sygnału. Jest to korzystne, ponieważ ułatwia interpretację otrzymanych wyników. Generowana jest jednak bardzo duża liczba danych, co jest związane także z dłuższym czasem obliczeń. Nie zawsze potrzebne jest tak precyzyjne przekształcenie sygnału, w takich przypadkach obliczana jest dyskretna transformata falkowa.



Rys. 2.7. Zasada obliczania CWT [114]

Dyskretna transformata falkowa uzyskiwana jest poprzez próbkowanie parametrów a i b , które mają wtedy postać:

$$\begin{aligned} a &= 2^{-m} \\ b &= n2^{-m} \end{aligned} \tag{12}$$

gdzie:

m, n – odpowiednio dobrane liczby całkowite.


Zbiór falek generuje się z zależności:

$$\psi_{m,n}(t) = 2^{m/2} \psi(2^m t - n) \tag{13}$$

natomiast współczynniki falkowe obliczane są z wzoru:

$$DWT_{m,n} = \int_{-\infty}^{\infty} x(t) \psi^*(t) dt \tag{14}$$

Do obliczeń DWT w praktyce, stosuje się algorytm wprowadzony przez Mallata [67] zwany multi-resolution analysis – MRA. Wykorzystuje on filtry związane z falkami, zwane filtrami kwadraturowymi. Sygnał jest filtrowany zespołem filtrów w sposób iteracyjny. W jednym kroku poddawany jest filtracji dolno i górnoprzepustowej. Uzyskiwana jest więc składowa zawierająca niskie częstotliwości, nazywana aproksymacją A_j , oraz wysokie częstotliwości, nazywana detalem D_j . Aby liczba próbek w sygnale i w uzyskanej aproksymacji a także detalu nie różniła się, następuje zmniejszenie częstotliwości próbkowania aproksymacji i detalu poprzez usunięcie co drugiej próbki. Następnie w kolejnym kroku procedura jest powtarzana dla aproksymacji, co powoduje powstanie wielopoziomowej dekompozycji sygnału. Idea DWT pokazana jest na rysunku 2.8.



Rys. 2.8. Zasada obliczania DWT [114]

Poziom rozkładu najczęściej nie przekracza 8. Sygnał zdekomponowany na dwa poziomy może być zrekonstruowany jako: $x = A_2 + D_2 + D_1 = A_1 + D_1$.

2.4.4. Metody sztucznej inteligencji

Z inspiracji naturą powstała grupa metod obliczeniowych nazywanych sztuczną inteligencją (ang. artificial intelligence lub natural computing). Badacze, obserwując np. działanie mózgu czy genów, stworzyli algorytmy o możliwościach wcześniej niedostępnych, pozwalających na uczenie się czy odkrywanie wiedzy w zgromadzonych danych. Wśród najbardziej popularnych metod wyróżnia się:

- sztuczne sieci neuronowe (ang. artificial neural networks),
- logikę rozmytą (ang. fuzzy logic),
- systemy ekspertowe (ang. expert systems),
- algorytmy ewolucyjne (ang. evolutionary algorithms),
- sztuczne systemy immunologiczne (ang. immune system metaphors),
- inteligentny rój (ang. swarm intelligence).

Metody te stosowane są coraz częściej w diagnostyce maszyn, ponieważ są bardzo przydatne w rozwiązywaniu złożonych rzeczywistych problemów. Sztuczne systemy immunologiczne, inteligentny rój i algorytmy ewolucyjne powstały stosunkowo niedawno i wykorzystywane są do zadań optymalizacyjnych [112]. Systemy ekspertowe i logika rozmyta bazują na regułach, przy czym w systemach ekspertowych reguły muszą być wprowadzone do bazy

wiedzy w ściśle określonej formie [99]. Logika rozmyta ma zastosowanie przede wszystkim w układach sterowania. Jedną z pierwszych i zarazem najczęściej stosowanych technik spośród metod sztucznej inteligencji są sztuczne sieci neuronowe wykorzystane w niniejszej pracy.

2.4.4.1. Sztuczne sieci neuronowe

Charakterystyka ogólna

Naukowcy zainspirowani funkcjonowaniem układu nerwowego a w szczególności mózgu rozwijają sztuczne sieci neuronowe, które swoim działaniem w mniejszym lub większym stopniu imitują naturę. Pierwszy matematyczny model neuronu, który jest podstawą większości współczesnych modeli, został przedstawiony w 1943 r. przez McCullocha i Pittsa.

Sieci neuronowe okazały się przydatne w rozwiązywaniu problemów takich jak:

- aproksymacji i interpolacji,
- klasyfikacji i rozpoznawania wzorców,
- predykcji, czyli przewidywania na podstawie bieżących danych przyszłych odpowiedzi,
- sterowania procesami,
- kompresji danych,
- filtracji danych,
- optymalizacji.

Ciągły rozwój i coraz większa popularność tej metody wynika z jej zalet. Są to [78, 100]:

- szybkość działania dzięki równoległemu przetwarzaniu danych,
- odporność na błędy występujące w strukturze sieci,
- zdolność do uczenia się, adaptacji i samoorganizacji,
- zdolność do generalizacji nabytej wiedzy.

Tylko poprawnie skonstruowana sieć posiada wymienione zalety. Występuje kilka problemów w opracowywaniu modelu neuronowego, które mają istotny wpływ na jego prawidłowe działanie (rozważania ograniczają się do sieci uczonych z nauczycielem stosowanych w niniejszej pracy).

Pierwszym z nich jest wybór danych do nauki sieci. Dane powinny być reprezentatywne tzn. odzwierciedlać modelowany proces w całym zakresie. Jeżeli sieć po zakończonej nauce otrzyma dane znacznie odbiegające zakresem od tych wykorzystanych w procesie uczenia, nie należy spodziewać się jej prawidłowego działania. Zbiór uczący prezentowany jest sieci w postaci zmiennych o określonej liczbie przypadków. Liczba zmiennych dobierana jest najczęściej na podstawie doświadczenia użytkownika. Mała liczba zmiennych może nie w pełni odwzorować badany proces, w wyniku czego wartości, uzyskiwane z modelu, mogą być niezadowalające. Zbyt duża liczba zmiennych natomiast może skutkować tym, że dane będą redundantne, co także powoduje

zwiększenie błędu sieci. Większa liczba zmiennych wymaga znacznie większej liczby przypadków, zależność ta nie jest liniowa i rośnie gwałtownie a często zbiór danych nie jest zbyt liczny (zwiększenie go jest kosztowne lub nawet niemożliwe). Nauka sieci dużym zbiorem uczącym jest też czasochłonna.

Kolejna kwestia dotyczy wyboru typu sieci i jej parametrów. W zależności od rozwiązywanego problemu należy wybrać odpowiednią sieć, nie każda architektura sieci nadaje się do wszystkich zagadnień. Również wyniki, uzyskane przez sieci dedykowane do danego zadania, nie będą takie same. Sieci neuronowe można podzielić na:

- jednokierunkowe sieci wielowarstwowe (ang. multi-layer perceptron – MLP),
- o radialnych funkcjach bazowych (ang. radial basic function – RBF),
- metodę wektorów nośnych (ang. support vector machine – SVM),
- rekurencyjne, np. Hopfielda (ang. recurrent neural network – RNN),
- samoorganizujące się – Kohonena (ang. self-organizing map – SOM),
- neuronowe rozmyte (ang. neuro fuzzy – NF),
- realizujące regresję ogólną (ang. general regression neural networks – GRNN),
- sieci probabilistyczne (ang. probabilistic neural networks – PNN),
- sieci z kontrpropagacją (ang. counter propagation – CP).

Po wyborze odpowiedniej sieci należy wybrać jej parametry. Duży wpływ na poprawność jej działania ma liczba neuronów w warstwie ukrytej (w zależności od typu sieci liczba warstw ukrytych może być większa niż jeden). Mniejsza liczba korzystniejsza jest dla problemów prostszych a większa dla bardziej złożonych. Jeżeli wybranych zostanie zbyt mało neuronów, to sieć nie nauczy się w dostatecznym stopniu rozwiązywanego zagadnienia, natomiast za duża ich ilość powoduje zbytne dopasowanie się do danych uczących a w konsekwencji słabe właściwości generalizacyjne. Należy wybrać także funkcję aktywacji neuronów, gdzie do dyspozycji jest dość duża liczba funkcji oraz algorytm uczenia. Nie wszystkie algorytmy wymienione poniżej nadają się do każdego typu sieci. Klasycznym już algorytmem jest algorytm wstecznej propagacji błędów (ang. back propagation), a z obecnie stosowanych można wymienić także: algorytm gradientów sprzężonych (ang. conjugate gradients), algorytm Levenberga-Marquardta, algorytm największego spadku (ang. steepest descent), algorytm zmiennej metryki (np. Broydena-Fletcher-Goldfarba-Shanno quasi-newton – BFGS). Od wyboru algorytmu uczącego zależy czas nauki sieci oraz to, czy sieć osiągnie mały błąd działania. Problemy, jakie towarzyszą nauce sieci, związane są z niestabilnością algorytmów, małą zbieżnością oraz lokalnymi minimami, i mogą wystąpić lub nie z różną intensywnością w zależności od wybranej metody. Na właściwości generalizacyjne sieci ma także wpływ czas uczenia.

Przedstawione problemy pozostają otwarte do dziś. Oczywiście są różne metody rozwiązywania ich od matematycznych zależności po zalecenia,

wynikające z doświadczenia i intuicji badaczy oraz użytkowników sieci neuronowych, stosowanych w określonych zagadnieniach. Nie ma jednak jednoznacznych i uniwersalnych zasad postępowania, które zapewnią sukces przy stosowaniu sieci neuronowych.

Przegląd zastosowań sieci neuronowych w obszarze diagnostyki maszyn i przekładni zębatych


W pracy przeglądowej Sicka [91], dotyczącej diagnostyki narzędzi skrawających z wykorzystaniem sztucznych sieci neuronowych, dokonano analizy publikacji z okresu 1987-2001 o łącznej liczbie 138. Najczęściej wybieraną siecią była sieć MLP (96 publikacji) i jest to prawie pięć razy więcej niż drugiej w kolejności RNN. Nie jest to najnowszy artykuł, ale uwzględnia on długi okres czasu i dużą liczbę prac. Nowszą pracą przeglądową jest artykuł [112], w którym dokonano przeglądu metod sztucznej inteligencji w odniesieniu do systemów mechanicznych. Obejmował on lata 2008-2010 i dotyczy artykułów z czasopisma Mechanical Systems and Signal Processing. Na pierwszym miejscu jest sieć MLP (18 artykułów), na drugim SVM (13 artykułów) i trzecim RBF (4 artykuły). Jako oddzielną kategorię w tym artykule stanowią sieci SVM. Należy wyjaśnić, że dla niektórych autorów sieci SVM są rozwiązaniem konkurencyjnym, odrębnym względem sieci neuronowych. W niniejszej monografii zgodnie z Osowskim [78] przyjęto, że SVM jest pewnym rodzajem sieci neuronowych. Również polska nomenklatura nie jest jednorodna w odniesieniu do nazwy metody wektorów nośnych, występują inne określenia jak np. technika wektorów podtrzymujących, maszyna wektorów nośnych.

Poniżej przedstawiono także statystyki z własnych badań z wykorzystaniem bazy bibliograficzno-abstraktowej polskich czasopism technicznych BazTech i jednej z największych baz publikacji pełnotekstowych na świecie ScienceDirect. Wykonana analiza dotyczy zastosowań sieci neuronowych, gdzie obiektem badań są przekładnie zębate. Statystyki mają na celu uwidocznienie, jakie typy sieci neuronowych są wykorzystywane do diagnostyki przekładni zębatych, jakie zagadnienia są rozwiązywane oraz jakie typy przekładni są badane. Użyto terminu w wyszukiwaniu „neural network gear” w lipcu 2013 r.

W BazTech, po wybraniu opcji szukaj w dowolnym polu, wyszukiwarka odnalazła 51 wyników a dla terminu „sieć neuronowa przekładnia” 19, dlatego wykorzystano termin anglojęzyczny, okres czasu nie był zawężany. Wyniki opracowane są w oparciu o tytuł, słowa kluczowe i streszczenie. Po odrzuceniu prac, które jednocześnie nie były związane z diagnostyką stanu przekładni zębatych i sieciami neuronowymi z 51 pozycji pozostało 19. Pochodzą one z lat 2003-2012.


Rezultaty uzyskane z tej bazy są podobne do tych prezentowanych z publikacji [91, 112]. Najczęściej wybieraną siecią neuronową jest sieć MLP, następnie sieci RBF i SVM (rys. 2.9). Zdecydowanie najczęściej poruszonym

zagadnieniem jest wykrywanie pęknięcia zęba przy podstawie a badanym typem przekładni zębatej jest przekładnia walcowa.



Rys. 2.9. Wyniki uzyskane z BazTech

Wyszukiwanie w bazie ScienceDirect zostało ograniczone do szukania w tytule, słowach kluczowych i streszczeniu. Aby wyniki można było porównać do polskiej bazy okres wyszukiwania został ograniczony do artykułów wydanych po 2002 r. Wyszukiwarka ScienceDirect znalazła 26 artykułów, z czego, po zapoznaniu się z treścią publikacji i po odrzuceniu niezwiązanych z diagnozowaniem przekładni zębatych z wykorzystaniem sieci neuronowych, pozostało 18.



Rys. 2.10. Wyniki uzyskane z ScienceDirect

Wyniki potwierdziły, że najczęściej w tego typu zagadnieniach wykorzystywana jest sieć typu MLP (rys. 2.10). Na drugim miejscu znalazła się sieć SVM a trzecim RBF wraz z trzema innymi typami sieci. Najpopularniejszymi tematami są: wykrywanie zużycia, wykruszenia, pęknięcia, wyłamania i pittingu zęba(ów) w przekładniach walcowych.

Dokonując oceny prezentowanych wyników, należy dodać, że autorzy mają świadomość, iż nie wszystkie artykuły zostały uwzględnione przy założonym terminie wyszukiwania. Aby ująć wszystkie lub niemal wszystkie prace należałoby zastosować zestaw różnych terminów. Niemniej jednak główny trend w rozpatrywanej tematyce został pokazany.

Do uzyskania pełniejszego obrazu zastosowań sieci neuronowych, stosowanych w diagnostyce przekładni zębatych, należy przedstawić przykłady i rezultaty badań.

W Polsce ośrodkiem naukowym, który opublikował największą liczbę prac z tego zakresu, jest zespół prof. A. Wilka a obecnie prof. B. Łazarza z Katedry Budowy Pojazdów Samochodowych Politechniki Śląskiej. Jednostka ta posiada stanowisko badawcze z mocą krążącą, gdzie badane są różne czynniki, wpływające na wibroaktywność przekładni walcowej o zębach śrubowych. W monografii poświęconej wykrywaniu lokalnych uszkodzeń kół zębatych [28] wykorzystano sieci neuronowe i algorytmy genetyczne. Lokalne uszkodzenia były w postaci pęknięcia zęba u podstawy i wykruszenia wierzchołka zęba. Algorytmy genetyczne służyły do wyboru najlepszych wariantów danych wejściowych do sieci neuronowych. Testowano również zaawansowane metody przetwarzania sygnałów. Wybrano cztery typy sieci neuronowych MLP, RBF, PNN i SVM. Sieć SVM ze względu na krótki czas nauki służyła do wyboru, po kolejnych analizach, najlepszych zestawów wzorców do pozostałych sieci. Ostatecznie po badaniach wstępnych i uzyskanych wynikach, jak również faktu, iż jest to najczęściej stosowana sieć, co może ułatwić implementację w układach diagnostycznych, wybrano sieć MLP do klasyfikacji stanu przekładni. We wnioskach stwierdzono, że możliwe jest rozróżnianie stopnia i rodzaju uszkodzeń zębów przy użyciu sieci neuronowej.

W zespole prof. S. Radkowskiego z Politechniki Warszawskiej prowadzono badania m.in. nad wykrywaniem błędów wykonawczych i montażowych przekładni walcowej o zębach śrubowych z wykorzystaniem sieci neuronowych [34]. Badana przekładnia została wyposażona w mimośrodowe osadzenie łożysk wału, co umożliwiło symulację odchyłek. Jako klasyfikator neuronowy zastosowano sieć CP, której jakość klasyfikacji wyniosła dla danych testowych od 95,12% do 100%. Zastosowano także dodatkowe przetwarzanie sygnałów, aby wyselekcjonować istotne cechy stanu z sygnału przyspieszeń drgań.

Trzecim zespołem, który również zaznaczył swoją działalność w tym zakresie w postaci publikacji są pracownicy z Katedry Podstaw Konstrukcji Maszyn Politechniki Lubelskiej pod kierownictwem prof. J. Jonaka. W pracy [47] diagnozowano zatarcie w przekładni zębatej stożkowej jednostopniowej. Po

odpowiednim przygotowaniu danych wejściowych do sieci typu MLP uzyskano jakość klasyfikacji dla danych walidacyjnych na poziomie od 98% do 100%. Dla tego samego obiektu badań, ale wykorzystując inne algorytmy przetwarzania informacji diagnostycznej dla klasyfikatora neuronowego typu RBF, uzyskano skuteczność diagnozy na poziomie 95% [51].

Należy w tym miejscu krótko scharakteryzować i podać przykłady zastosowania coraz bardziej popularnej sieci SVM. Jest to stosunkowo nowy rodzaj sieci opracowany we współczesnej formie w latach dziewięćdziesiątych XX wieku głównie przez Vladimira Vapnika. W pracy [108] dokonano ankiety czasopism anglojęzycznych, dotyczącej zastosowań sieci SVM do oceny stanu i uszkodzeń maszyn w latach 1996–2006. Tylko jedna praca w tym okresie dotyczy kół zębatych. Stosunkowo niewiele jest publikacji, w których można znaleźć porównanie skuteczności różnych sieci neuronowych zwłaszcza w konkretnym zastosowaniu. W pracy [107] diagnozowano reduktor stosowany w turbinach wiatrowych z pękniętym zębem u podstawy. Dla sieci SVM uzyskano skuteczność klasyfikacji na poziomie 96% a RBF 90,6%. Porównanie skuteczności klasyfikacji sieci neuronowych dla reduktora dwustopniowego z kołami zębatymi w stanie dobrym i z pittingiem jest przedstawione w artykule Samanty [87]. Wyniki przedstawiane są dla różnego przetwarzania wstępnego, zwiększającego skuteczność diagnozy. Generalnie osiągnięto lepsze wyniki dla sieci SVM niż MLP.

3. METODY OCENY WYKONANIA KÓŁ ZĘBATYCH I MONTAŻU PRZEKŁADNI

Ze względu na skomplikowany kształt, koła zębate są swego rodzaju wyzwaniem dla metrologii. Pomiaru wymagają przygotowania teoretycznego w zakresie geometrii uzębienia i kinematyki zazębienia, konieczne było też skonstruowanie specjalnych przyrządów do pomiaru wielkości charakteryzujących koła zębate, takich jak linia zęba czy zarys zęba.

Rozważania w tym rozdziale zostają ograniczone do dwóch typów przekładni zębatych: walcowych i stożkowych. Różnią się one od siebie w pewnych aspektach pomiarowych, co związane jest z technologią ich wytwarzania. Produkcja kół walcowych w porównaniu ze stożkowymi jest dużo prostsza i bardziej opanowana. Różnice widoczne są w zarysie boku zęba – w przekładniach walcowych jest on najczęściej ewolwentowy, natomiast w stożkowych powiązany i uzależniony od metody obróbki koła. Dodatkowo geometria uzębienia w przekładniach stożkowych jest bardziej skomplikowana, co również ma wpływ na sposób i dokładność pomiaru.

3.1. Kontrola kół zębatych na etapie produkcji

Sposoby sprawdzania kół zębatych uzależnione są od kilku czynników, takich jak m.in. wyposażenia zakładu, klasy i przeznaczenia kół zębatych czy metody wytwarzania. Pierwszym głównym celem pomiarów jest sprawdzenie, czy produkowane koła są zgodne ze specyfikacją i spełniają określone normy. Kontrola części wpływa na obniżanie kosztów wytwarzania poprzez nadzór nad procesem produkcji i redukcję ilości wyrobów wybrakowanych. Drugim zasadniczym powodem jest diagnostyka procesu nacinania kół zębatych na etapie wprowadzania do produkcji nowej przekładni. Informacje z pomiarów pomagają w określeniu poprawek ustawczych na obrabiarki, potrzebnych do uzyskania prawidłowej geometrii uzębienia.

Sprawdzanie kół w trakcie procesu produkcji następuje na różnych jego etapach a rozpoczyna się od pomiarów półfabrykatu przed nacięciem uzębienia. Gotowy wyrób najpierw podlega oględzinom wzrokowym, a następnie za pomocą przyrządów sprawdza się m.in:

- grubość zęba,
- bicie uzębienia,
- podziałki,
- zarys boku zęba,
- linię zęba,
- topografię boku zęba,
- chropowatość zęba,
- ślad współpracy (przylegania),
- cichobieżność,

- luz międzyzębny,
- błędy zazębienia (z kołem kontrolnym),
- naprężenia resztkowe i ściskające zębów utwardzanych,
- odpuszczenia powierzchni po szlifowaniu.

Występują różne podziały metod pomiarowych. Tutaj zostaną przedstawione dwie klasyfikacje, które zdaniem autorów w sposób całościowy oddają istotę zagadnienia: w zależności od rodzaju użytych elementów pomiarowych i mierzonych wielkości.

Podział w zależności od użytych przyrządów jest następujący [75]:

- metody dotykowe,
- metody optyczne,
- metody optyczno-dotykowe.

W metodach dotykowych, w trakcie pomiaru, między badanym przedmiotem a przyrządem pomiarowym występuje styk powierzchni. Są to najbardziej rozpowszechnione metody pomiarowe ze względu na dokładność, powtarzalność i stosunkowo dużą szybkość pomiaru. Klasycznymi już przyrządami pomiarowymi w tej kategorii są narzędzia ręczne, takie jak suwmiarki, mikrometry i przyrządy oparte na czujnikach. Współczesne maszyny pomiarowe, oferowane przez czołowych producentów, możemy podzielić na trzy grupy [40]: maszyny współrzędnościowe (ang. coordinate measuring machines – CMM), uniwersalne maszyny do pomiaru kół zębatych (ang. universal gear measuring instruments – GMI) oraz przyrządy specjalne. Tradycyjne narzędzia pomiarowe, takie jak mikrometr talerzykowy czy suwmiarka modułowa są nadal oferowane, ale przez coraz mniejszą liczbę producentów. Jednak przy produkcji kół zębatych o wysokiej jakości nie znajdują już one zastosowania, podobnie jak i przy produkcji seryjnej oraz masowej. Dokładny pomiar ilościowy kół stożkowych, pozwalający na sprawdzenie zgodności z dokumentacją techniczną, możliwy jest od lat 80-ych XX wieku, kiedy to wprowadzono maszyny CMM i GMI do pomiaru kół zębatych [36].

Maszyny współrzędnościowe zostały stworzone do badania przedmiotów o dowolnym kształcie. Aby możliwy był pomiar kół zębatych, do standardowego urządzenia należy dokupić specjalne oprogramowanie i ewentualnie stół obrotowy lub trzpienie pomiarowe. Obecnie za pomocą CMM możliwe jest sprawdzenie w zasadzie każdego typu kół zębatych i pomiar takich wielkości, jak m.in. grubość zęba, linia zęba, zarys boku zęba, a także i topografia boku zęba [38, 43].

Uniwersalne maszyny pomiarowe są urządzeniami dedykowanymi do sprawdzania kół zębatych, których zastosowanie ogranicza się do przedmiotów o kształcie obrotowo-symetrycznym. Obecnie produkowane GMI są sterowane komputerowo. Urządzenia firmy Gleason z serii GMS [39], oprócz pomiarów geometrii uzębienia, mogą sprawdzić w kołach walcowych chropowatość powierzchni roboczych zębów, naprężenia resztkowe i ściskające zębów

utwardzanych, przegrzanie powierzchni szlifowanych. Do zalet GMI zalicza się większą szybkość, dokładność i powtarzalność pomiarów dzięki prostszej, sztywniejszej i bardziej niezawodnej konstrukcji [36]. Natomiast mocnymi stronami CMM jest możliwość pomiaru przedmiotów w zasadzie o dowolnym kształcie oraz niższa cena [38].

Istnieje jeszcze szereg specjalnych maszyn i przyrządów pomiarowych, służących głównie do badania współpracy jednostronnej, obustronnej, śladu współpracy i cichobieżności.

Za pomocą przyrządów optycznych wykonywane są głównie pomiary geometrii zębów. Można wyróżnić trzy typy urządzeń: mikroskopy, urządzenia oparte na kamerach cyfrowych i laserach. Mikroskopy służą do pomiaru z dużą dokładnością wielkości geometrycznych. Systemy, bazujące na kamerach i laserach, w przypadku inspekcji kół zębatych nie są jeszcze powszechnie stosowane, gdyż w dużym stopniu są ciągle w fazie badań i rozwoju. Ich zaletą może być bardzo duża szybkość pomiarów. Przykładowym urządzeniem jest laserowy skaner profili scanCONTROL 2800-25 firmy Micro-Epsilon [71], który umożliwia pomiar bicia i tworzenie przestrzennych dyskretnych odwzorowań zębów kół zębatych. Istnieją jeszcze inne przyrządy optyczne, takie jak projektory, lupy itp.

W metodach optyczno-dotykowych pomiar wielkości geometrycznych wykonywany jest przyrządem optycznym a położenie przedmiotu określone jest przez dotyk [75].

W literaturze angielskiej (np. [35, 36, 39]) metody pomiarowe dzielone są, zgodnie z otrzymywanymi wynikami, na metody analityczne (ang. analytical inspection) i funkcjonalne (ang. functional inspection). W metodach analitycznych w wyniku pomiaru uzyskujemy wartości pojedynczych wielkości geometrycznych np. grubość, zarys zęba. Używane są do tego przyrządy ręczne, maszyny GMI, CMM, mikroskopy itp. Natomiast w metodach funkcjonalnych sprawdza się łączny wpływ błędów wykonania na maszynach umożliwiających współpracę z kołem kontrolnym. Wyodrębnia się tutaj badanie współpracy jednostronnej, obustronnej, śladu współpracy i cichobieżności. Obecnie na jednym urządzeniu możliwe jest wykonanie kilku wymienionych testów.

Sprawdzanie współpracy jednostronnej odbywa w warunkach zbliżonych do takich, w jakich będą pracowały koła zębate. Podczas badań zachowana jest stała odległość osi kół i w tej samej chwili kontakt występuje tylko na jednej stronie zębów. Badania mogą się odbywać (najczęściej) bez lub z obciążeniem. W trakcie kontroli rejestrowane są położenia katowe kół, na podstawie których wyznaczany jest błąd przełożenia (odchyłka kinematyczna). Metodę tę najczęściej stosuje się, gdy geometria uzębienia jest bardzo skomplikowana i zbyt złożona dla metod analitycznych lub gdy wysoka dokładność kinematyczna jest głównym kryterium oceny przekładni. Możliwa jest również prognoza hałasu przekładni i detekcja przyczyn, pochodzących z procesu wytwarzania, które powodującą nadmierną wibroaktywność [36]. Ponadto na

podstawie wyników można wnioskować o [73]: uszkodzeniach powierzchni zębów, biciu uzębienia, błędach podziałek, odchyłkach zarysu.

W pomiarze współpracy obustronnej, koła zębate dosuwane są do siebie tak, by stykały się obydwoma bokami zębów. Rejestrowane są zmiany odległości osi kół spowodowane niedokładnością wykonania. W porównaniu do poprzedniej metody warunki próby znacznie odbiegają od rzeczywistej pracy kół, dlatego też wyniki są trudniejsze w interpretacji. Koszt zakupu przyrządu jest jednak znacznie tańszy.

Zaletami metody współpracy jednostronnej i obustronnej w porównaniu do metod analitycznych są [36]:

- sprawdzanie wszystkich zębów,
- szybkość pomiaru,
- wykrywanie uszkodzeń powierzchni roboczych,
- możliwość sprawdzania kół o małym module i kompletnych przekładni (metoda współpracy jednostronnej),
- nie jest wymagana szczegółowa wiedza o geometrii uzębienia.

Do wad natomiast należy zaliczyć:

- trudności w interpretacji przyczyn powstania błędów, ponieważ niektóre odchylenia powodują taki sam skutek na wykresie lub się znoszą,
- modyfikacje powierzchni roboczej zęba, takie jak zmiana zarysu głowy zęba, również powodują trudności w interpretacji wyników. Nie wiadomo czy błąd jest spowodowany celową modyfikacją czy błędami w produkcji.

Ślad współpracy powstaje w wyniku kontaktu (tarcia) bocznych powierzchni zębów i jest obrazem chwilowych miejsc styku zębów. Analizując jego wielkość, kształt i położenie, uzyskuje się informacje o poprawności wykonania kół zębatych. Ze względu na skomplikowaną geometrię uzębienia kół stożkowych, ograniczającą użycie metod analitycznych, ślad współpracy jest niezastąpiony przy produkcji i montażu tego typu kół. Ze względu na obiekt badań niniejszej pracy dalsze rozważania dotyczące śladu współpracy zostają ograniczone do przekładni stożkowych. Ślad współpracy sprawdzany jest kilkakrotnie w trakcie wdrażania do produkcji nowej przekładni [113]. Ostateczna kontrola przeprowadzana jest dla gotowego wyrobu i ma na celu ustalenie najkorzystniejszego położenia wzajemnego kół zębatych, ponieważ położenie teoretyczne najczęściej nie jest położeniem optymalnym. Koła przesuwane są w dwóch kierunkach: H – kierunek zgodny z osią zębownika i J – zgodnym z osią koła. Badanie to przeprowadzane jest na urządzeniach kontrolnych. Pod uwagę brany jest ślad współpracy oraz w maszynach firmy Gleason również drgania. W pracy [113] Wójcik wskazuje, że z analizowanych pasm 200 Hz, 400 Hz i 600 Hz decydujące jest pierwsze pasmo. W wyniku przeprowadzonej kontroli uzyskiwane są optymalne odległości montażowe, które utrwalane są bezpośrednio na kołach lub w ich metrykach wraz z wartością luzu międzyzębnego, gdzie również mogą być archiwizowane uzyskane ślady współpracy.

Koła zębate w trakcie pracy emitują hałas spowodowany przez niedoskonałości konstrukcji i/lub procesu produkcji oraz zależy od prędkości obrotowej i obciążenia. Poszczególne błędy powodują powstanie określonego typu hałasu. Doświadczony pracownik jest w stanie na tej podstawie stwierdzić przyczynę hałasu lub proces diagnozy może być w pełni automatyczny. Innym powodem takiej kontroli jest sprawdzenie, czy koła nie wytwarzają nadmiernego hałasu w przypadku, gdy jest to jedno z głównych kryteriów oceny.

3.2. Montaż i kryteria poprawności zabudowy kół zębatach

W montażu przekładni walcowych i stożkowych występuje zasadnicza różnica. W pierwszym przypadku, jeżeli części są pełnowartościowe, to po złożeniu również otrzymamy przekładnię o gwarantowanej jakości. To twierdzenie nie jest prawdziwe dla przekładni stożkowych, w których należy indywidualnie dokonywać ustawienia kół zębatach. Odpowiedzialni za wysoką jakość przekładni są wykonawca kół zębatach, konstruktor przekładni i monter. Ze wszystkich części wchodzących w skład przekładni, koła zębate są najtrudniejsze w konstrukcji i produkcji, stanowiąc ciągłe wyzwanie, dlatego produkowane są przez wysokospecjalizowane zakłady. Łatwość pomiarów, sztywność łożyskowania, możliwość obserwacji kół bez ich demontażu itp. uzależniona jest od konstrukcji przekładni a więc od konstruktora. Ma to wpływ na proces montażu i trwałość przekładni. Kompetencje i umiejętności montera wpływają w znacznym stopniu na właściwości użytkowe przekładni. W praktyce spotykane są dwie sytuacje, gdy firma zleca produkcję kompletnej przekładni przedsiębiorstwu, które ma możliwość wytwarzania kół zębatach i innych komponentów lub zamawia części, których nie jest w stanie produkować i samodzielnie montuje przekładnię. To drugie rozwiązanie jest mniej korzystne, ponieważ w przypadku problemów eksploatacyjnych odpowiedzialność będzie trudna do ustalenia. Zakład kupujący koła zębate nie zawsze ma możliwości techniczne do kompleksowego sprawdzenia kół zębatach z powodu znacznych cen maszyn pomiarowych.

Najważniejszym wskaźnikami, które muszą być zachowane w trakcie montażu kół zębatach są:

- odległości montażowe,
- ślad współpracy,
- luz międzyzębny.

Opisane poniżej czynności montażowe odnoszą się do obiektu badań, czyli przekładni stożkowej z zębami kołowo-łukowymi o przełożeniu większym niż dwa i kącie osi dziewięćdziesiąt stopni.


Odległości montażowe

Odległości montażowe określają wzdlużne położenie zębniaka i koła, przy których zachodzi prawidłowa współpraca zębów. Definiowane są one jako wymiar liniowy między punktem przecięcia się osi kół a powierzchnią oporową (rys. 3.1). Przesunięcie zębniaka ma przede wszystkim wpływ na ślad współpracy a koła na luz międzyzębny (im większe przełożenie tym wyraźniejsza jest ta zależność; przy przełożeniu równym jeden taki sam wpływ na ślad współpracy i luz międzyzębny ma przesunięcie zębniaka i koła). Sposób regulacji położenia osiowego kół zapewnia konstruktor poprzez odpowiednie zaprojektowanie przekładni, a najczęstszym rozwiązaniem jest zastosowanie podkładek dystansowych. W praktyce ustawienie kół zębatych w obudowie zgodnie z wymaganymi odległościami montażowymi odbywa się poprzez [46, 69]:

- użycie specjalnego przyrządu,
- pomiar narzędziami uniwersalnymi,
- obliczenia,
- wyrównanie stożków czołowych.

Najczęściej przy produkcji seryjnej używa się specjalnego przyrządu do określenia położenia zębniaka w obudowie, co znacznie przyspiesza montaż. Jeżeli nie jest dostępny taki przyrząd, to odległość montażowa może być osiągnięta również przy użyciu uniwersalnych narzędzi pomiarowych. Sprawdza się bowiem odległość od powierzchni oporowej koła do osi drugiego koła.

Kolejnym rozwiązaniem, pozwalającym na zachowanie odległości montażowej, jest ustalenie grubości podkładek dystansowych z łańcucha wymiarowego. Konieczna jest znajomość wszystkich wymiarów składowych, wchodzących w skład tego łańcucha. Nie jest to metoda zbyt dokładna, ponieważ jest ona uzależniona od dokładności pomiaru elementów, dodatkowo precyzja uzyskanego wyniku maleje wraz z ilością wymiarów składowych. Ostatnia z metod stosowana jest przy kołach o dużych rozmiarach [46]. Polega ona na ustaleniu położenia kół poprzez wyrównanie stożków czołowych, co widoczne jest na rysunku 3.1. Nie jest to metoda dokładna i zalecana. „Licowanie się” stożków świadczy o prawidłowym montażu tylko wtedy, gdy optymalne odległości montażowe ustalone na maszynie kontrolnej są równe odległościom teoretycznym.



Rys. 3.1. Odległości montażowe w przekładni stożkowej

Ślad współpracy

Sprawdzanie śladu współpracy jest stosunkowo szybką metodą oceny poprawności montażu i wykonania elementów przekładni. Do jej zalet należy zaliczyć dużą czułość na warunki zabudowy (np. błędne położenie otworów w obudowie, nieprawidłowe odległości montażowe), zdolność do wykrywania nawet niewielkich odchyłeń w topografii powierzchni bocznej zęba i powtarzalność wyników. Ślad współpracy może być sprawdzany metodą statyczną i dynamiczną.


Badanie metodą statyczną odbywa się pod małym obciążeniem i przy małej prędkości obrotowej. Napęd zębnika i moment hamujący koło uzyskiwany jest zazwyczaj w sposób ręczny. Zęby jednego z kół lub obu pokrywane są substancją barwiącą, uwidaczniającą ślad współpracy. Zęby należy starannie pokryć środkiem barwiącym. Dlatego do tego celu najczęściej używa się pędzla o twardym włosiu, aby uzyskać równomierną warstwę o małej grubości (w granicach od 6 μm do 12 μm [57]). Uzyskanie wiarygodnych i powtarzalnych wyników wymaga kontroli i konsekwentnego stosowania przyjętej grubości znacznika [40]. Pod uwagę brane są ślady dla co najmniej trzech zębów, równo rozmieszczonych na obwodzie koła, dla strony wklęsłej i wypukłej.

Interpretacja uzyskanych wyników nie jest zadaniem prostym, ponieważ kształt, położenie i wielkość śladu współpracy zależy od wielu czynników, takich jak: klasy dokładności wykonania kół, wielkości kół, przeznaczenia itd. Jednakże w trakcie montażu ma to drugorzędne znaczenie, albowiem konstruktor określa w warunkach zabudowy właściwy ślad współpracy. Dodatkowo w metryce załączony jest ślad uzyskany na maszynie kontrolnej dla danej pary kół. Różnice między śladami z metryki a tymi z montażu, wynikają z niedokładności wykonania obudowy i/lub nieprawidłowego montażu. Można jednak podać ogólne zalecenia odnośnie uzyskiwanych śladów współpracy, pochodzące z praktyki. Generalnie ślad współpracy powinien znajdować się

bliżej wewnętrznego końca zęba, ponieważ pod wpływem obciążenia, powodującego odkształcenia w przekładni, ślad przesuwu się w kierunku zewnętrznego końca zęba. Biorąc pod uwagę położenie względem wysokości, to na stronie wklęsłej powinien być nieco niżej a wypukłej nieco wyżej stożka podziałowego [46]. Na rysunku 3.2a przedstawiony jest prawidłowy ślad współpracy a na rysunku 3.2b, c nieprawidłowe ślady, spowodowane niezachowaniem odległości montażowej zębniaka. Poprawa błędnych śladów z rysunku 3.2d÷g wymaga korekty obudowy lub kół zębatych z powodu braku możliwości regulacji położenia kół, umożliwiających zniwelowanie odchylek.

Dla konstrukcji nowych i tych o najwyższej jakości ślad sprawdzany jest również w warunkach eksploatacyjnych, czyli metodą dynamiczną. Zęby koła mogą być pokryte np. tuszem, wtedy ślad uwidacznia się w postaci błyszczącej (jasnej) powierzchni. Kontrola powinna być przeprowadzona dla kilku obciążeń w kolejności rosnącej do obciążenia maksymalnego. Ważne jest, tak jak i przy sprawdzaniu metodą statyczną, aby ślad współpracy nie skupiał się przy głowie lub stopie oraz na końcach zęba. Zanikanie śladu powinno być wyraźne widoczne.

Uzyskane ślady stanowią dowód prawidłowego montażu i dlatego powinny być utrwalone. Stosuje się do tego dwie metody: fotografię lub zachowanie śladu przy użyciu specjalnej taśmy. W drugiej metodzie w pierwszej kolejności transparentna taśma przyklejana jest do zęba i w tym momencie pasta barwiąca naniesiona na ząb przyczepia się do taśmy. Następnie taśmę odrywa się od zęba i przykleja na biały papier.




Rys. 3.2. Prawidłowy ślad współpracy a) i nieprawidłowe ślady b÷g) dla przekładni stożkowej o kołowo-lukowej linii zęba [3]


Luz międzyzębny

Niewłaściwy luz międzyzębny, czyli spoza zakresu ustalonego przez konstruktora, uniemożliwia prawidłową współpracę zębów. Skutkować to może przedwczesnym zużyciem, hałaśliwą pracą a nawet może doprowadzić do awarii. Przedział wartości luzu, jaki podaje producent kół, odnosi się najczęściej do luzu normalnego. Pomiar odbywa się przy pomocy czujnika na końcu zewnętrznym zęba koła, trzpień pomiarowy jest prostopadły do powierzchni bocznej zęba (rys. 3.3). W tym celu zębnik zostaje unieruchomiony, obrót kołem w obu kierunkach powoduje otrzymanie na czujniku skrajnych wartości, których

różnica jest wartością luzu normalnego. Pomiar wykonuje się dla co najmniej trzech zębów równo rozmieszczonych na obwodzie. W przypadku braku odpowiedniego dostępu do koła możliwy jest tylko pomiar luzu obwodowego. Wykonuje się go w płaszczyźnie obrotu koła z wykorzystaniem dodatkowego oprzyrządowania (rys. 3.4). Należy jednak pamiętać, iż uzyskana w ten sposób wartość jest około 30% większa [3] i należy ją przeliczyć, uwzględniając kąt przyporu, średni kąt pochylenia linii zęba, oraz promień, na którym odbywał się pomiar [46].



Rys. 3.3. Pomiar luzu normalnego [24]



Rys. 3.4. Pomiar luzu obwodowego

Montaż kół zębanych

W pierwszej kolejności zabudowuje się zębnik a następnie koło zgodnie z odległościami montażowymi. Zespoły, które były docierane w określonym położeniu (liczby zębów kół mają wspólny dzielnik), muszą być również w takim położeniu zamontowane. Pozycja ta określona jest poprzez wykonanie znaków na dwóch zębach koła i jednym zębie zębnika w postaci „x” lub punktu. Luz międzyzębny powinien osiągnąć zalecaną wartość, a jeśli od niej odbiega, należy zmienić położenia koła. Po sprawdzeniu odległości montażowych i luzu międzyzębnego sprawdzany jest ślad współpracy. Jeśli ślad nie jest zadowalający, powinno się zmienić położenie zębnika. Zabudowa kół z uwzględnieniem tylko odległości montażowych i luzu międzyzębnego może nie dać zadowalających wyników np. z powodu odchyłek wykonania otworów w obudowie. Decydujący jest ślad współpracy, który uwzględnia czynniki wykonawcze i montażowe.

3.3. Ocena wykonania przekładni zębanych w świetle wybranych norm

Do oceny wykonania przekładni stożkowych mają zastosowanie w zasadzie dwie normy spośród Polskich Norm: PN-80/M-88522/03 „Przekładnie zębate

stożkowe i hipoidalne. Dokładność wykonania. Nazwy, określenia i wartości odchyłek” oraz PN-ISO 8579-2: 1996 „Przepisy odbioru przekładni zębatych. Określanie drgań mechanicznych przekładni zębatych podczas badań odbiorczych”.

Pierwsza norma precyzuje dokładność wykonania otoczki koła zębatego, pojedynczego koła, pary kół i przekładni oraz wyznacza dwanaście klas dokładności wykonania kół zębatych i przekładni zębatych od 1 do 12, przy czym niższa klasa oznacza większą dokładność wykonania [81]. Przekładnie i koła mogą być sklasyfikowane jednocześnie w trzech różnych klasach, dotyczących dokładności kinematycznej, płynności pracy i przylegania zębów. Aby określić klasę w jednej z trzech grup dokładnościowych, wyznacza się określone wskaźniki poprzez pomiary i porównuje z wartościami dopuszczalnymi, zawartymi w normie. W wymaganiach, dotyczących przylegania zębów, podane są minimalne długości i wysokości względne śladów współpracy. Generalnie im wyższa klasa dokładności, tym większa jest wymagana długość i wysokość śladu.

W normie PN-ISO 8579-2: 1996, która jest tłumaczeniem międzynarodowej normy ISO 8579-2, określono warunki odbioru przekładni zębatych, gdzie za kryterium obrano drgania mechaniczne [83]. Sposób pomiaru drgań przekładni został podzielony ze względu na rodzaj łożysk. W przekładniach z łożyskami tocznymi drgania mierzy się na korpusie. Pomiar powinien być wykonany w trzech wzajemnie prostopadłych kierunkach, we wszystkich dostępnych fragmentach korpusu, podpierających łożyska. Jeśli zastosowano łożyska ślizgowe, można dokonać pomiaru zarówno przemieszczeń drgań względnych wału, jak i drgań korpusu. Zakres pomiarowy dla drgań względnych wału zalecany jest w zakresie od 0 Hz do 500 Hz a dla pomiarów drgań korpusu od 10 Hz do 10 kHz lub więcej. Pomiary powinny odbywać się podczas pracy przekładni w warunkach eksploatacyjnych (prędkość, temperatura, smarowanie i kierunek obrotów) z wyjątkiem obciążenia, które zaleca się, aby nie występowało lub było małe. Aparatura pomiarowa na wyjściu dla drgań wału powinna zapewnić uzyskanie wartości międzyszczytowej przemieszczenia w μm a dla korpusu wartości skutecznej prędkości drgań w mm/s. Dodatkowo możliwa powinna być analiza wąskopasmowa. Otrzymane wyniki drgań należy porównać z odpowiednim rysunkiem w postaci wykresu i dokonać ich klasyfikacji. W załączniku normy przedstawiona jest subiektywna klasyfikacja drgań, z uwzględnieniem przenoszonych mocy, definiująca cztery kategorie od A do D.

Norma API Standard 677, Second Edition, July 1997, „General Purpose Gear Units for Petroleum, Chemical, and Gas Industry Services” Amerykańskiego Instytutu Naftowego (ang. American Petroleum Institute – API) określa szereg aspektów dotyczących projektowania, rozwiązań konstrukcyjnych, obowiązków producenta i badań odbiorczych przekładni walcowych o zębach śrubowych i stożkowych o zębach krzywoliniowych o kącie prostym między osiami, ogólnego przeznaczenia dla przemysłu naftowego [3]. Założenia projektowe

wymagają przyjęcia minimum dwudziestoletniego okresu użytkowania i trzy-letniego okresu ciągłej, nieprzerwanej pracy. Zalecenia, dotyczące montażu przekładni stożkowych, są zgodne z tymi podanymi w podrozdziale 3.2. Preferowaną metodą utrwalania śladów współpracy jest zastosowanie do tego celu przezroczystej celofanowej taśmy. Próba mechaniczna przekładni na stanowisku powinna trwać nie mniej niż godzinę od czasu ustabilizowania się temperatury oleju smarowego i łożysk, przy maksymalnej prędkości obrotowej bez obciążenia. Jeśli określono inaczej, może być przeprowadzony test rozszerzony (bez obciążenia) lub testy opcjonalne (max. prędkość/obciążenie max. lub częściowe; max. moment/prędkość zredukowana; max. moment/próba statyczna; test poziomu głośności). Po zakończonej próbie sprawdzane są powierzchnie zębów pod kątem uszkodzeń oraz ślad współpracy. Producent zobowiązany jest do przechowywania danych z próby zawierających informacje o:

- temperaturze i ciśnieniu oleju,
- amplitudzie drgań z sygnału filtrowanego i niefiltrowanego,
- temperaturze łożysk, jeśli taki pomiar jest możliwy.

Norma określa wartości drgań, które nie powinny zostać przekroczone podczas próby standardowej lub rozszerzonej. Dla drgań korpusu, mierzonych na podporach łożyskowych, prędkość drgań w zakresie od 10 Hz do 2,5 kHz dla sygnału niefiltrowanego nie powinna przekroczyć 5 mm/s, a dla filtrowanego 4 mm/s. W przypadku pomiaru przyspieszenia drgań w zakresie od 2,5 kHz do 10 kHz dla sygnału niefiltrowanego, poziom drgań nie powinien przekroczyć 8 g. Jeżeli sprawdzane są drgania wałów w postaci przemieszczeń, to wartość międzyszczytowa dla sygnału niefiltrowanego nie powinna przekroczyć określonej dopuszczalnej wartości w μm .

3.4. Podsumowanie badań literaturowych na temat możliwości stosowania metod wibroakustycznych do diagnostyki kontrolnej przekładni zębatych

Z dokonanego przeglądu metod diagnostycznych i ich krótkiej charakterystyki w podrozdziale 2.1 wynika, że do bezdemontażowej oceny stanu technicznego zastosowanie może mieć głównie metoda wibroakustyczna, której sygnał charakteryzuje się dużą pojemnością informacyjną. Potwierdzają to publikacje związane z wartościowaniem wykonania i montażu przekładni zębatych. W omówionej normie PN-ISO 8579-2: 1996, dla badań odbiorczych przekładni z łożyskami tocznymi, określono poziomy wartości skutecznej prędkości drgań, pozwalające na ich klasyfikację do jednego z pięciu poziomów. Zalecenia dotyczą wszystkich typów przekładni zębatych o dowolnej liczbie stopni i bez ograniczeń ze względu na przenoszoną moc co sprawia, że są one dość ogólne. Dlatego wybór dopuszczalnego poziomu ustalany jest między producentem a kupującym. Należy zwrócić uwagę, że zakres częstotliwości, dla którego

określono poziomy drgań, wynosi do 10 kHz, a możliwości przetworników prędkości średnio osiągają wartości do 2,5 kHz. Dla wyższych częstotliwości należy dokonać pomiarów przyspieszeń drgań i wykonać całkowanie wyników, aby móc porównać je z ustalonymi poziomami. Zapewne dlatego w normie API Standard 677, w zależności od częstotliwości, dokonuje się pomiaru prędkości lub przyspieszenia drgań. Podane w tej normie wartości maksymalne drgań dotyczą dwóch typów przekładni z ograniczeniem co do przenoszonej mocy i prędkości obwodowej, i są to wymagania minimalne. Uwzględnienie badania drgań w normach przy próbach odbiorczych świadczy o ich potwierdzonej przydatności. Jednak określenie tylko wymagań minimalnych lub pozostawienie dowolności przy wyborze dopuszczalnego poziomu drgań tylko dla prób bez znaczącego obciążenia, wskazuje na złożoność i niedostateczne poznanie metod wibroakustycznych pomimo licznych i długoletnich badań, prowadzonych na całym świecie.

Boczkowski w swoich pracach [13, 14, 15, 16] z powodzeniem badał możliwość oceny jakości wykonania i montażu samochodowych skrzyń przekładniowych za pomocą sygnału wibroakustycznego. Są to przekładnie o kołach walcowych (z wyjątkiem mechanizmu różnicowego). Jak sam autor stwierdził [14], użyte metody i środki są bardzo podobne do tych używanych w diagnostyce eksploatacyjnej. Również wykrywane niesprawności w dużej części przypadków odpowiadają uszkodzeniom, występującym podczas użytkowania przekładni np. uszkodzony ząb, skrzywiony wałek, uszkodzone łożysko.

Problem wykrywania błędów montażowych w reduktorze jednostopniowym walcowym o zębach śrubowych badał Mączak [70]. Błędy montażowe zadawane były poprzez mimośrodowe osadzenie łożysk koła. Wykorzystano sygnał drgań, a poprzez procedurę demodulacji możliwe było określenie rodzaju i wielkości powstałego błędu. Inne prace powstałe w zespole naukowym prof. Radkowskiego, rozwiązujące powyższe zagadnienie, związane są z zastosowaniem filtracji tercjowej [44] i sieci neuronowej [34].


W pracy [30] analizowano m.in. możliwość odwzorowywania wartości luzu międzyzębnego poprzez miary obliczone z sygnału drganiowego. Pod uwagę wzięto ponad sto miar i stwierdzono, że nie ma takiej miary, która określiłaby tę wartość monotoniczną zależnością. Wyciągnięto jednak ogólny wniosek, że intensywność drgań i hałasu osiąga minimum zawsze powyżej luzu nominalnego, i jest tym bliżej wartości nominalnej luzu, im dokładniej jest wykonana przekładnia.

Z przedstawionych publikacji wynika, że dla przekładni walcowych możliwe jest ustalenie nie tylko ogólnego poziomu wykonania i montażu, ale też określenie rodzaju powstałego błędu. Jednak użycie prostych metod, takich jak np. zastosowanie tylko typowych miar, może nie dać zadowalających wyników.

Z rozważań, dotyczących montażu w podrozdziale 3.2, wynika, że parametrem kompleksowym, który uwzględni wszystkie czynniki zabudowy kół zębatych, jest ślad współpracy. Luz międzyzębny nie może pełnić takiej roli,


ponieważ koła mają kształt stożków i dlatego możliwe jest zmontowanie kół w bardzo dużej liczbie pozycji z prawidłowym luzem i błędnymi odległościami montażowymi. Natomiast ustawienie kół tylko zgodnie z zalecanymi odległościami montażowymi, na skutek odchyłek wykonania np. obudowy, wału, również może doprowadzić do nieprawidłowego montażu. W pracy Skawińskiego [95], dotyczącej integracji procesu projektowania i wytwarzania przekładni stożkowych, podkreślono znaczenie śladu współpracy jako jednego z najważniejszych czynników, określających jakość kół zębatach. Zaproponowano w niej system oceny kół stożkowych na etapie produkcji. Idea metody polega na rejestracji śladu współpracy podczas sprawdzania kół na maszynie kontrolnej poprzez kamery cyfrowe. Następnie sieci neuronowe klasyfikują otrzymany obraz do jednej z trzynastu klas. W przypadku nieprawidłowego śladu system pomaga w jego uzyskaniu poprzez wybór odpowiedniej procedury korekcyjnej. Zrealizowane badania dotyczą pomyślniej klasyfikacji sztucznie przygotowanych śladów współpracy do trzynastu klas, za pomocą zestawu sieci SVM. Podobne rozwiązanie zastosowano w fabryce Forda [105]. Opracowano system optyczny, który służy do analizy części mostu napędowego. Za pomocą kamer rejestrowany jest ślad współpracy zębów, w trakcie obrotu kół, dla obu stron zębów, i porównywany jest ze specyfikacją. Jeśli ślad nie spełnia wymagań, części są brakowane. Zastosowanie takiego rozwiązania przy montażu jest ograniczone, ponieważ nie każda obudowa umożliwia obserwację wewnątrz przekładni po zabudowie kół.

Obszerne badania dotyczące prognozowania właściwości dynamicznych przekładni stożkowych przeprowadził Skoć [96]. Analiza dotyczyła przekładni stożkowej o zębach kołowo-lukowych z kołami zębatymi wykonanymi metodą Gleason, Klingelnberg i Oerlikon. Badano na stanowisku laboratoryjnym o mocy krążącej m.in. wpływ odchyłek montażowych na nadwyżkę dynamiczną N_{vp} , zdefiniowaną jako stosunek momentu statycznego do momentu dynamicznego. Obliczenia momentu dynamicznego były wykonane na podstawie informacji o przyspieszeniu drgań skrętnych koła, pochodzących z dwóch czujników piezoelektrycznych, umieszczonych bezpośrednio na kole zębatym. Wprowadzono odchyłki montażowe przedstawione na rysunku 3.5 w taki sposób, aby w jak najmniejszym stopniu wpływać na wartość luzu międzyzębnego.



Rys. 3.5. Zadawane odchyłki montażowe [96]

Badania przeprowadzono dla różnych prędkości obrotowych i obciążeń, dla kół zębatych, wykonanych w siódmej klasie dokładności. Zauważono, że różne typy odchyłek o dowolnych wartościach liczbowych mają taki sam wpływ na nadwyżkę dynamiczną, jeżeli powodują zbliżone zmiany w śladzie współpracy. Jest to ważne stwierdzenie, ponieważ wynika z niego, iż w tym przypadku kompleksowym parametrem, świadczącym o obciążeniu dynamicznym kół, jest ślad współpracy, a nie typ i wartość odchyłki. Miara, która reprezentowała ślad współpracy, była względna długość L_w , czyli stosunek długości śladu przylegania, mierzonej względem linii zęba do całkowitej długości linii zęba. Przykładowe wyniki przedstawione są na rysunku 3.6. Z wykresów widać wyraźną zależność, świadczącą o tym, iż im krótszy jest ślad współpracy, tym nadwyżka dynamiczna jest większa.



Rys. 3.6. Związek między względną długością śladu współpracy L_w a nadwyżką dynamiczną N_{vp} [96]

Wartość nadwyżki dynamicznej zależy od drgań skrętnych koła – jest ona tym większa, im większe są wartości przyspieszeń drgań. Można stąd wyciągnąć wniosek, że intensywność drgań przekładni powinna wzrastać wraz ze zmniejszaniem się długości śladu współpracy. Niestety pomiar drgań skrętnych kół poza stanowiskami laboratoryjnymi jest bardzo utrudniony, i w praktyce w zasadzie się go nie stosuje. Prezentowane w niniejszej pracy normy, w których określono poziomy czy wartości dopuszczalne drgań, nie obejmują swoim zakresem drgań skrętnych.

4. BADANIA STANOWISKOWE PRZEKŁADNI STOŻKOWYCH

Dla inżynierów i naukowców głównym źródłem informacji, w przypadku zgłębiania nowych zagadnień, są badania eksperymentalne [32]. Takie rozwiązanie stosuje się zwłaszcza wtedy, gdy analizowany problem jest złożony. Również wyniki i tezy, bazujące na takich badaniach, budzą mniej kontrowersji [96]. Metody symulacyjne opierają się lub są weryfikowane w oparciu o wyniki z badań empirycznych, dlatego w niniejszej pracy za podstawowe źródło poznania przyjęto badania stanowiskowe.

W ramach współpracy między Politechniką Lubelską a PZL Świdnik przeprowadzono badania, w trakcie których zgromadzono dane wykorzystane w niniejszej monografii. Próby stanowiskowe odbywały się na terenie i z wykorzystaniem wyposażenia zakładu.


4.1. Obiekt badań

Badaniu został poddany montaż przekładni końcowej śmigłowca PZL SW-4 (rys. 4.1). Jest to przekładnia zębata jednostopniowa stożkowa o zębach kołowo-łukowych i kącie między osiami 90° . Koła zębate wykonane są w 7 klasie dokładności, liczba zębów zębnika wynosi 19 a koła 42.



Rys. 4.1. Widok przekładni końcowej zabudowanej na śmigłowcu

Zębnik i wał koła podparte są w łożyskach tocznych. Możliwa jest zmiana odległości montażowej kół poprzez dobór podkładek regulacyjnych o innej grubości. Nominalna prędkość kątowna wynosi 629.99 rad/s (6016 obr/min) a moc $87,5 \text{ kW}$. Na rysunku 4.2 przedstawiona jest budowa przekładni. Obecnie zmienione jest rozwiązanie łożyskowania zębnika.



Rys. 4.2. Przekrój przekładni śmigła ogonowego. 1 – podzespół zębniaka z obudową, 2 – wał śmigła ogonowego, 3 – pokrywa z łożyskiem oporowym wału śmigła ogonowego, 4 – obudowa przekładni, 5 – wspornik do mocowania dźwigni sterowania śmigła ogonowego [102]

4.2. Sposób prowadzenia badań


Przed montażem wszystkie części wchodzące w skład przekładni podlegają sprawdzeniu, a czynności montażowe i kontrolne są zgodne z odpowiednimi dokumentami zakładu. Uzyskanie wymaganych odległości montażowych kół (dobór grubości podkładek regulacyjnych) odbywa się poprzez obliczenia z łańcucha wymiarowego. Po zabudowaniu kół nie ma dostępu do wnętrza przekładni, dlatego wykonuje się pomiar luzu międzyzębnego obwodowego z użyciem specjalnego przyrządu w trzech miejscach na obwodzie zębniaka. Jeżeli wszystko jest zgodne z wymaganiami, następuje kontrola śladu współpracy. W tym celu zęby każdego z kół pokrywane są substancją barwiącą o innym kolorze. Uzyskany ślad powinien być zgodny z wytycznymi podanymi przez producenta i możliwie jak najbardziej zbliżony do uzyskanego na maszynie kontrolnej dla danego kompletu kół. Utrwalenie śladu z trzech zębów rozmieszczonych co 120° wykonywane jest przy użyciu specjalnej transparentnej taśmy. W metryce montażowej zawarte są dane o przebiegu montażu i innych czynnościach wykonywanych przy przekładni. Dokument ten umożliwia analizę procesu montażu, obsługi oraz kontroli części i przekładni.

Przekładnia docierana i sprawdzana jest na stanowisku. Parametry próby, takie jak prędkość, obciążenie i czas trwania poszczególnych etapów, są zgodne z wymaganiami technicznymi i zadawane są w sposób automatyczny. Próba


odbywa się dla dwóch prędkości obrotowych, wynoszących 50% i 103% prędkości nominalnej i czterech obciążeniach: bez obciążenia (opór własny przekładni i hamulca) oraz 34,3%, 86,8% i 118,8% momentu nominalnego.

4.3. Stanowisko badawcze

Napęd stanowił silnik elektryczny. Ze względu na dużą prędkość kątową badanej przekładni konieczne było zastosowanie multiplikatora o kołach zębatych walcowych. Moment hamujący zadawany był za pomocą hamulca wodnego i sprawdzany z wykorzystaniem momentomierza (rys. 4.3).



Rys. 4.3. Schemat budowy stanowiska badawczego i toru pomiarowego. 1 – silnik elektryczny, 2 – multiplikator, 3 – badana przekładnia, 4 – hamulec wodny, 5 – momentomierz i obrotomierz, 6 – sprzęgło, 7 – czujnik przyspieszeń drgań, 8 – kondycjoner sygnału, 9 – komputer NI [124]



Rys. 4.4. Położenie czujników przyspieszeń drgań na przekładni. 1, 2 – numer czujnika drgań [51]

Na stanowisku kontrolowane i mierzone były drgania i temperatura przekładni, moment obciążający oraz prędkość kątowna. Do pomiaru drgań użyto dwa trójosiowe czujniki przyspieszeń Brüel&Kjaer typu 4321 z kondycjonerami sygnału B&K Nexus a także komputer pomiarowy National Instruments PXI-1044 z kartą pomiarową NI PXI-4472B i oprogramowaniem LabView. Rozmieszczenie czujników drgań na przekładni widoczne jest na rysunku 4.4. Częstotliwość próbkowania sygnału drgań wynosiła 40 kHz.

5. WSTĘPNE BADANIA OCENY MONTAŻU PRZEKŁADNI ZĘBATYCH STOŻKOWYCH

5.1. Badania symulacyjne

Ze względu na krótki czas realizacji i stosunkowo niskie koszty badania symulacyjne są chętnie stosowane zwłaszcza wtedy, gdy liczba rozpatrywanych wariantów jest duża. W niniejszej pracy posłużono się tym narzędziem, aby ustalić, jaki wpływ na pracę przekładni ma nieprawidłowe położenie kół zębatych, spowodowane błędami montażowymi. Błędy w usytuowaniu kół powodują zmianę warunków przyporu, co z kolei implikuje błąd przełożenia. W pracy doktorskiej Mączaka [70] przytaczane są wyniki badań, dotyczące relacji między błędem przełożenia a emitowanym przez przekładnie walcowe hałasem. Wynika z nich jednoznacznie, że moc akustyczna hałasu rośnie wraz ze wzrostem błędu przełożenia (hałas przekładni jest następstwem jej drgań, dlatego należy stwierdzić, iż poziom drgań przekładni również musiał wzrosnąć). Ta prawidłowość jest zgodna z intuicją i wynika w pewnym stopniu z definicji błędu przełożenia TE , który określony jest jako różnica między rzeczywistym położeniem kątowym koła napędzanego a teoretycznym:

$$TE = \theta_2 - \frac{z_1}{z_2} \theta_1 \quad (15)$$

gdzie:

θ_1 – położenie katowe zębownika,

θ_2 – położenie katowe koła,

z_1 – liczba zębów zębownika,

z_2 – liczba zębów koła.

Całkowity błąd przełożenia wyraża wzór:

$$TTE = TE_{\max} - TE_{\min} \quad (16)$$

gdzie:

$TE_{\max}$ – maksymalna wartość błędu przełożenia,

$TE_{\min}$ – minimalna wartość błędu przełożenia.

Dla wartości błędu przełożenia równej zero, niemożliwej w praktyce do osiągnięcia (i przy stałej wartości prędkości silnika), koła mają stałą prędkość kątową i w zasadzie nie generują drgań. Wartość błędu przełożenia większa od zera powoduje drgania kół zębatych i wałów, które pobudzają przekładnię do drgań. Zatem informacja o błędzie przełożenia, zależnego od położenia kół, pokazuje wpływ błędów montażowych na wibroaktywność przekładni.

5.1.1. Symulacja współpracy jednostronnej


Do pomiaru błędu przełożenia dla obiektów rzeczywistych stosuje się metodę współpracy jednostronnej. W badaniach symulacyjnych odwzorowano warunki, panujące podczas tych badań. W programie NX 7.5 wygenerowano modele bryłowe kół zębatach o parametrach uzębienia, odpowiadających obiektowi badań. Koła wykonane są ze stali. W programie przyjęto stal o właściwościach: gęstość $\rho = 7829 \text{ kg/m}^3$, moduł Younga $E = 20694 \times 10^7 \text{ Pa}$, współczynnik Poissona $\nu = 0.288$. Badania przeprowadzono dla małej prędkości kątowej i małego obciążenia, dlatego nie uwzględniono odkształcalności zębów i wpływu tarcia. Prędkość kątowa zębownika była stała i wynosiła $1,5708 \text{ rad/s}$ (15 obr/min). Aby zapewnić ciągły kontakt zębów, przyłożono do koła moment hamujący o wartości 10 Nm . Wyniki przedstawione są dla pełnego obrotu zębownika z krokiem co $0,5^\circ$. Symulacja współpracy kół również odbyła się w programie NX 7.5.

5.1.2. Wyniki badań

Modele kół zębatach przemieszczane były z prawidłowej pozycji zgodnie z prostokątnym układem współrzędnych widocznym na rysunku 5.1. Oś H pokrywa się z osią zębownika a oś J z osią koła. Konwencja oznaczenia na poniższych rysunkach jest następująca:


- H – przemieszczenie zębownika wzdłuż własnej osi,
- J – przemieszczenie koła wzdłuż własnej osi,
- wartość dodatnia oznacza, że przemieszczenie było zgodnie ze zwrotem osi,
- wartość 0 oznacza, że nie było zmiany pozycji, czyli brak jest odchyłki montażowej; np. $H = -0,3 \text{ mm}$ oznacza zwiększenie odległości montażowej zębownika, która różni się od prawidłowej o tę wartość.

Błędy położenia kół, powstające w trakcie montażu wynikają z konstrukcji obudowy. W badanej przekładni, jak i innych typowych rozwiązaniach, możliwe są tylko przemieszczenia obu kół wzdłuż ich własnej osi.




Rys. 5.1. Modele bryłowe kół zębatach wraz z układem współrzędnych

Błąd przełożenia i całkowity błąd przełożenia dla różnych odległości montażowych zębniaka przedstawiony jest na rysunkach 5.2 i 5.3.




Rys. 5.2. Błąd przełożenia dla różnych odległości montażowych zębniaka




Rys. 5.3. Całkowity błąd przełożenia dla różnych odległości montażowych zębniaka

Błąd przełożenia i całkowity błąd przełożenia dla różnych odległości montażowych koła przedstawiony jest na rysunkach 5.4 i 5.5.




Rys. 5.4. Całkowity błąd przełożenia dla różnych odległości montażowych koła




Rys. 5.5. Błąd przełożenia dla różnych odległości montażowych koła


Błąd przełożenia i całkowity błąd przełożenia dla różnych kombinacji odległości montażowych zębniaka i koła przedstawiony jest na rysunkach 5.6, 5.7, 5.8 i 5.9.




Rys. 5.6. Błąd przełożenia dla różnych odległości montażowych koła i zębika jednocześnie mniejszych lub większych niż prawidłowe



Rys. 5.7. Całkowity błąd przełożenia dla różnych odległości montażowych koła i zębika jednocześnie mniejszych lub większych niż prawidłowe



Rys. 5.8. Błąd przełożenia dla różnych odległości montażowych koła i zębika na przemian mniejszych lub większych niż prawidłowe



Rys. 5.9. Błąd przełożenia dla różnych odległości montażowych koła i zębniaka na przemian mniejszych lub większych niż prawidłowe

Podsumowanie wyników

Analizując uzyskane wyniki należy stwierdzić, iż w żadnym z rozważanych przypadków nie uzyskano monotonicznej zależności świadczącej o tym, że wraz ze wzrostem błędu montażu wzrasta całkowity błąd przełożenia. Dla zębniaka największe wartości całkowitego błędu przełożenia występują dla zbyt dużej odległości montażowej, w przypadku koła dla zbyt małej. Natomiast przy jednoczesnym nieprawidłowym ustawieniu kół zębatych największy błąd występuje dla zbyt małej odległości montażowej koła i zębniaka a także dla zbyt małej odległości montażowej koła i zbyt dużej zębniaka. Występują również takie położenia kół, dla których całkowity błąd przełożenia jest mniejszy niż w pozycji optymalnej. Oznacza to brak prostej zależności między położeniem kół zębatych a błędem przełożenia, a więc także trudności w określeniu relacji symptom (wartość symptomu) – stan.

5.2. Badania stanowiskowe

Przeprowadzenie badań wstępnych podczas prób stanowiskowych ma na celu sprawdzenie, czy do realizacji postawionego zadania wystarczą proste metody analizy sygnałów i wnioskowania. Należy także wybrać parametr, który w pełni i jednoznacznie określa jakość montażu. Z podrozdziału 3.3 i 3.4 wynika, że takim parametrem jest ślad współpracy. W pracy Skocia [96] ślad współpracy reprezentowany jest przez względną długość śladu a w Polskiej Normie PN-80/M-88522/03 przez względną długość i szerokość śladu. W badaniach wstępnych przyjęto, że wielkościami charakteryzującymi ślad współpracy jest względna długość i względne pole powierzchni śladu. Względna długość śladu L_w określona jest zależnością:

$$L_w = L_s / L_c \quad (17)$$

gdzie:

L_s – długość śladu współpracy,

L_c – całkowita długość linii zęba.

Natomiast względne pole powierzchni śladu P_w :


$$P_w = P_s / P_c \quad (18)$$

gdzie:

P_s – pole powierzchni śladu współpracy,

P_c – pole powierzchni bocznej zęba.


Pod uwagę wzięto 6 przekładni. Ślad współpracy utrwalony został dla trzech zębów równo rozmieszczonych na obwodzie dla każdego z kół. Przykładowe zwymiarowane ślady współpracy widoczne są na rysunku 5.10.




Rys. 5.10. Ślady współpracy koła zębatego [48]

Dla zarejestrowanych sygnałów przyspieszeń drgań wykonano dwie analizy. W pierwszej z nich policzono wartość średnią i skuteczną dla sygnału niepoddanego przetwarzaniu. W drugiej metodzie obliczono te same miary dla sygnału z trzema harmonicznymi zazębienia. Do wyodrębnienia z sygnału harmonicznymi zazębienia, o częstotliwościach 1962 Hz, 3924 Hz i 5886 Hz, zastosowano filtry tercjowe, charakteryzujące się stałą względną szerokością pasma. Częstotliwość dolna, środkowa i górna dla trzech filtrów wynosi odpowiednio: dla pierwszego – 1782 Hz, 2000 Hz, 2245 Hz, dla drugiego – 3564 Hz, 4000 Hz, 4490 Hz i dla trzeciego – 5613 Hz, 6300 Hz, 7071 Hz.


Z pracy [96] wynika, że im dłuższy jest ślad współpracy, tym nadwyżka dynamiczna, obliczana na podstawie drgań skrętnych koła, jest mniejsza. Głównie na tej podstawie poczyniono założenie, że im większy jest ślad współpracy, tym poziom drgań mierzonych na obudowie powinien być mniejszy. Wymiary śladu współpracy dla kolejnych numerów przekładni przedstawione są na rysunku 5.11.



Rys. 5.11. Względne długości i względne pola powierzchni śladu współpracy [48]



Rys. 5.12. Wartości skuteczne i średnie obliczone dla sygnałów bez przetwarzania [48]



Rys. 5.13. Wartości skuteczne i średnie obliczone dla sygnałów po filtracji [48]

Porównując wartości skuteczne i średnie na rysunkach 5.12 oraz 5.13, można zauważyć, że proporcje pomiędzy wartościami dla poszczególnych przekładni są niemal takie same, dlatego wystarczy rozpatrywać jedną miarę, np. wartość skuteczną. Kolejne spostrzeżenie dotyczy wyników dla sygnału bez przetwarzania. Wszystkie wartości, oprócz tej dla przekładni 2, w nieznacznym stopniu różnią się między sobą, co praktycznie uniemożliwia ocenę montażu. W przypadku sygnału poddanego filtracji różnice są większe i do tych rezultatów będą porównywane wielkości śladu współpracy. Największą długość śladu współpracy uzyskano dla przekładni 2 i 3, dla których poziom drgań jest najmniejszy. Zgodne z założeniem są też wyniki dla przekładni 1 i 5, które mają zbliżoną długość śladu i wartości skuteczne. To, co się nie zgadza to rezultaty dla numeru 4 i 6. Dla przekładni numer 4, o drugim co do długości śladzie, uzyskano największą wartość skuteczną, a przekładnia numer 6, o najmniejszym śladzie, nie generowała drgań o największej wartości skutecznej. W przypadku względnego pola powierzchni można uznać za zgodne z założeniem tylko wyniki uzyskane dla przekładni 5 i 6.

5.3. Wnioski z badań wstępnych

Badania symulacyjne pokazują, że nie każde błędne położenie kół zębatych powoduje zwiększanie się błędu przełożenia. Wynika z tego, że nieoptymalna pozycja kół w obudowie może skutkować nie tylko zwiększeniem się, ale także


i zmniejszeniem się poziomu drgań. Utrudnia to określenie reguł diagnostycznych.

W badaniach doświadczalnych nie udało się potwierdzić założenia, dotyczącego zależności pomiędzy wielkością śladu a intensywnością generowanych drgań. Teza, że większej długości śladu powinien towarzyszyć mniejszy poziom drgań, powstała na bazie prezentowanych wcześniej wyników z pracy [96]. Powodów takiego stanu rzeczy może być kilka i wynikają one z różnic pomiędzy badaniami. W wykonanym eksperymencie rejestrowano drgania osiowe na korpusie dla 6 przekładni i obliczono miary z sygnału drgań. W cytowanych badaniach mierzono drgania skrętne dla jednej przekładni montowanej tak, aby uzyskać różne położenie kół i wyznaczono nadwyżkę dynamiczną. Wyniki dla kilku obiektów badań, nawet tego samego typu i w tym samym stanie dla takich samych warunków badań, zazwyczaj różnią się od siebie, co jest spowodowane odchyłkami wykonawczymi i montażowymi. Sygnał drgań rejestrowany na korpusie charakteryzuje się większymi zakłóceniami, co także wpływa na uzyskiwane wyniki.

Z dwóch wielkości, określających ślad współpracy, bardziej przydatna okazała się względna długość śladu i ona będzie stosowana w dalszych badaniach.

6. METODA OCENY MONTAŻU PRZEKŁADNI STOŻKOWYCH

Przyjęty w badaniach wstępnych algorytm diagnozowania okazał się niewystarczający. Sygnał drgań charakteryzuje się dużą zawartością informacji, ale struktura widmowa sygnału jest złożona, ponadto sygnał również zawiera zakłócenia (kwestie te opisane są w podrozdziale 2.2 i 2.3).



Rys. 6.1. Schemat metody oceny montażu przekładni stożkowych

Opracowano więc metodę oceny montażu przekładni, opartą na sztucznych sieciach neuronowych w trzech odmianach. Schemat metody widoczny jest na rysunku 6.1. Strzałki o jednakowym kolorze wskazują etapy poszczególnych wariantów metody. W pierwszym wariancie (strzałki koloru pomarańczowego) obliczane są miary dla sygnałów drgań zarejestrowanych z korpusu przekładni. Następnie z dwudziestu miar wybrane zostają tylko te najbardziej skorelowane ze stanem przekładni. Posłużą one jako dane wejściowe do sieci neuronowych. Zadaniem sieci będzie klasyfikacja przekładni z uwagi na względną długość śladu współpracy oraz predykcja względnej długości śladu. W drugim i trzecim wariancie metody sygnały przed obliczeniem miar poddawane są odszumianiu z wykorzystaniem WT, a w przypadku trzeciego wariantu (strzałki czerwone) dodatkowo stosowana jest PCA. Spośród różnych sieci neuronowych wybrano trzy typy: MLP, RBF i SVM. Jak wynika z podrozdziału 2.4.4.1 są to sieci najczęściej wykorzystywane w diagnostyce przekładni zębatych, a ich skuteczność działania została potwierdzona.

Tabela 6.1. Charakterystyka badanych przekładni [124]

Przekładnie wykorzystane do budowy algorytmu diagnozującego			
Oznaczenie przekładni	Względna długość śladu współpracy	Oznaczenie przekładni	Względna długość śladu współpracy
1	0,381	7	0,488
2	0,427	8	0,490
3	0,438	9	0,495
4	0,451	10	0,497
5	0,454	11	0,501
6	0,461		
Przekładnie kontrolne			
12	0,467		
13	0,481		

W badaniach zasadniczych posłużono się trzynastoma przekładniami. W tabeli 6.1 podano oznaczenia przekładni oraz ich względne długości śladów współpracy. Nauka sieci neuronowych została przeprowadzona dla danych z pierwszych jedenastu przekładni, a ostatnie dwie służyły wyłącznie do dodatkowej kontroli zbudowanych modeli neuronowych. Należy podkreślić, że wyniki uzyskane dla przekładni kontrolnych, zostały uzyskane w trybie wdrożenia sieci, czyli dla modeli neuronowych zapisanych i wczytanych. Równie dobrze mogłoby się to odbywać w zakładzie przemysłowym. Analizowane sygnały były zarejestrowane przy obciążeniu wynoszącym 34,3%, 86,8% i 118,8% momentu nominalnego i prędkości obrotowej równej 103%

prędkości nominalnej. Kolejność zadawania obciążenia na stanowisku w trakcie kontroli i docierania przekładni jest zgodna z wymienioną.

W pierwszym przypadku sieci neuronowe mają za zadanie przyporządkować przekładnie do jednej z trzech klas, które nazwano: I – nieprawidłowy montaż, II – montaż prawidłowy i III – montaż bardzo dobry. W tabeli 6.1 przynależność do określonej klasy oznaczona jest odpowiednim kolorem. Do klasy pierwszej należy tylko pierwsza przekładnia, dla której uzyskano zbyt krótki ślad współpracy. Do drugiej grupy zaliczanych jest pięć przekładni (od 2 do 6), tyle samo do grupy trzeciej (od 7 do 11). Jeżeli takie same proporcje byłyby wśród danych wykorzystywanych do treningu sieci neuronowych, miałyby one tendencje do wybierania drugiej i trzeciej klasy. Spowodowane jest to tym, że wybierając przynależność do tych klas sieci minimalizują popełniany błąd. Aby tego uniknąć utworzono zbiory danych, w których są równe liczby przypadków zmiennych (miar) dla każdej klasy.

W drugim przypadku sieci neuronowe będą przewidywały wartość względnej długości śladu przekładni. Tak jak i w zadaniu klasyfikacji, trening sieci przeprowadzony został z wykorzystaniem danych z jedenastu przekładni.

Prezentowane w tym rozdziale wyniki zostały opracowane w oparciu o oprogramowanie Matlab, Statistica i Microsoft Excel.

6.1. Odszumianie sygnałów

Jako metodę wstępnego przetwarzania sygnałów często stosuje się filtrację, która umożliwia zmniejszenie wpływu zakłóceń, czyli zwiększenie stosunku sygnału użytecznego do szumu (ang. signal to noise ratio – SNR). Wynikiem działania tradycyjnych filtrów jest usunięcie z widma pasma o określonej częstotliwości. Aby stosowanie tych filtrów było skuteczne, należy przyjąć lub określić innymi metodami (np. z wykorzystaniem kurtozy [121]), które częstotliwości w sygnale niosą informację, a które są szumem dla rozpatrywanego zadania. W przypadku sygnału wibroakustycznego nie jest to zadanie proste z powodu jego złożoności, i problem nadal pozostaje otwarty.

WT przyniosła nowe możliwości w zakresie filtracji. Okazało się bowiem, że większość sygnałów reprezentowana jest zadowalająco przez niedużą liczbę współczynników falkowych o dużych wartościach. Szum natomiast w dziedzinie współczynników falkowych odzwierciedlany jest przez współczynniki falkowe o małych wartościach. Aby zlikwidować zakłócenia z minimalną stratą informacji, należy zmienić wartości małych współczynników na zero. Stosowane są często dwie metody odszumiania – *thresholding* i *shrinkage methods* [89]. W *thresholding methods* zerowane są współczynniki falkowe poniżej określonego progu a pozostałe nie są zmieniane. Metoda ta określana jest także jako *hard thresholding*. W drugim przypadku dla *shrinkage methods* modyfikacji podlegają także współczynniki falkowe (za pomocą funkcji *shrinkage*), których wartość jest większa od wartości progowej. Można wyróżnić

kilka odmian tej metody w zależności od zastosowanej funkcji, przy czym najczęściej stosowaną jest metoda (funkcja) *soft*. Procedurę odsumiania dla bardziej popularnej DWT (użytej w niniejszej pracy) można przedstawić w trzech krokach:

1. Oblicz współczynniki falkowe dla analizowanego sygnału do założonego poziomu rozkładu J .
2. Zmodyfikuj wartości współczynników falkowych detali zgodnie z obliczoną wartością progową.
3. Zrekonstruuuj sygnał wykonując odwrotną transformatę falkową.

Wpływ na uzyskiwane wyniki ma: dobór falki bazowej, poziom rozkładu, wybrana metoda – *thresholding* lub *shrinkage*, wybór metody obliczania wartości progowej.

Częstym przypadkiem spotykanym w praktyce jest sytuacja, w której wykorzystywany jest więcej niż jeden czujnik do rejestrowania tej samej wielkości. W pracy [2] zmodyfikowano podstawową metodę i przedstawiono procedurę, umożliwiającą odsumianie danych rejestrowanych wielokanałowo z użyciem DWT, którą zastosowano w niniejszej monografii. Bierze ona pod uwagę strukturę korelacyjną szumu. Zakładany jest następujący p -wymiarowy model sygnału [2]:

$$X(t) = f(t) + \varepsilon(t), t = 1, \dots, n \quad (19)$$

gdzie:

$X(t)$, $f(t)$, $\varepsilon(t)$ są wymiaru $1 \times p$,

$f(t)$ – sygnał, który chcemy odsumić,

$\varepsilon(t)$ – szum Gaussowski z nieznaną macierzą kowariancji $E(\varepsilon(t)^T \varepsilon(t)) = \Sigma_\varepsilon$.

Każda składowa $X(t)$ jest postaci, dla $1 \leq i \leq p$ [2]:

$$X^i(t) = f^i(t) + \varepsilon^i(t), t = 1, \dots, n \quad (20)$$

gdzie:


f^i – należy do pewnej przestrzeni funkcyjnej (najczęściej przestrzeni L^2 lub Besova).

Macierz kowariancji Σ_ε , która powinna być dodatnio określona, trafnie oddaje stochastyczną zależność pomiędzy składowymi $X(t)$ i modelami przestrzennej korelacji.


Procedura odsumiania może być wyrażona za pomocą trzech kroków dla macierzy X , która jest wymiaru $n \times p$, i składa się z p sygnałów (kolumn macierzy X) tak, że $n \gg p$ [2]:

1. Dla każdej kolumny macierzy X wykonaj dekompozycję falkową stopnia J . W tym kroku uzyskuje się $J+1$ macierzy $D_1, \dots, D_J$, zawierających współczynniki detali stopnia od 1 do J z p sygnałów i współczynniki

- aproksymacji A_j z p sygnałów. Macierze D_j i A_j są wymiaru $n2^j \times p$ oraz $n2^j \times p$;
- Wyznacz estymator $\hat{\Sigma}_\varepsilon$ macierzy kowariancji szumu a następnie dokonaj dekompozycji SVD (ang. singular value decomposition) macierzy $\hat{\Sigma}_\varepsilon$ za pomocą macierzy ortogonalnej V takiej, że $\hat{\Sigma}_\varepsilon = VAV^T$, gdzie $A = \text{diag}(A = \text{diag}(\lambda_i, 1 \leq i \leq p))$. Zastosuj dla każdego detalu po zmianie bazy przestrzeni za pomocą macierzy przejścia V (mianowicie $D_j V$, $1 \leq i \leq p$) i wykonaj filtrowanie za pomocą progu $t_i = \sqrt{2\lambda \log(n)}$ dla i -tej kolumny macierzy $D_j V$;
 - Dokonaj rekonstrukcji odszumionej macierzy $\check{X}$ za pomocą uproszczonych macierzy detali i aproksymacji, poprzez zmianę bazy przestrzeni, za pomocą macierzy V^T i odwrotnego przekształcenia falkowego.



Rys. 6.2. Sygnały drgań przed i po odszumianiu dla kanału 1 i 2



Rys. 6.3. Sygnały drgań przed i po odszumianiu dla kanału 3÷6

W procedurze zastosowano metodę odszumiania *soft*, zmieniającą także wartości współczynników, których wartość bezwzględna jest większa od wartości progu, dzięki czemu przebieg sygnału jest bardziej gładki (w porównaniu do metody *hard*):

$$D(i) = \begin{cases} \text{sign}(D(i))(|D(i)| - t) & \text{jeśli } |D(i)| > t \\ 0 & \text{jeśli } |D(i)| \leq t \end{cases} \quad (21)$$

gdzie:

$\text{sign}()$ jest funkcją signum.


Na rysunku 6.2 i 6.3 przedstawione są przykładowe wyniki działania procedury odszumiania dla sześciu osi czujników przyspieszeń drgań, zamontowanych na jednej przekładni.

Rozszerzeniem przedstawionej procedury odszumiania jest zastosowanie dodatkowo PCA w algorytmie. Daje to możliwość usunięcia nieistotnych składowych głównych, a więc dodatkowy efekt odszumiania. Procedura jest następująca [2]:


1. Dla każdej kolumny macierzy X wykonaj dekompozycję falkową stopnia J .
2. Wyznacz estymator $\hat{\Sigma}_\varepsilon$ macierzy kowariancji szumu jako $\hat{\Sigma}_\varepsilon = \text{MCD}(D_1)$, a następnie oblicz V z zależności $\hat{\Sigma}_\varepsilon = VAV^T$, gdzie $A = \text{diag}(A = \text{diag}(\lambda_i, 1 \leq i \leq p))$. Zastosuj dla każdego detalu po zmianie bazy przestrzeni za pomocą macierzy przejścia V (mianowicie $D_j V$, $1 \leq j \leq p$) i wykonaj filtrowanie za pomocą progu $t_i = \sqrt{2\lambda \log(n)}$ dla i -tej kolumny macierzy $D_j V$;
3. Oblicz PCA dla macierzy aproksymacji A_j i wybierz odpowiednią liczbę p_{J+1} użytecznych składowych głównych.
4. Dokonaj rekonstrukcji odszumionej macierzy $\check{X}$ za pomocą uproszczonych macierzy detali i aproksymacji poprzez zmianę bazy przestrzeni za pomocą macierzy V^T i odwrotnego przekształcenia falkowego.
5. Wykonaj ostatnią PCA dla macierzy $\check{X}$ otrzymaną w 4 kroku i wybierz $\check{p}$ składowych głównych.

W kroku 2, MCD oznacza estymator minimum covariance determinant, wprowadzony przez Rousseeuw w pracy [85].

W celu wyraźniejszego pokazania różnic pomiędzy dwoma procedurami odszumiania zostaną przedstawione wyniki dla obu metod bez sygnałów niepoddanych przetwarzaniu (rys. 6.4 i 6.5).




Rys. 6.4. Sygnał drgań dla 1÷3 kanału odsumiony procedurą pierwszą i drugą z PCA




Rys. 6.5. Sygnały drgań dla kanału 4÷6 odszumione procedurą pierwszą i drugą z PCA

Z przedstawionych wykresów (rys. 6.2 i 6.3) wynika, że najwięcej zakłóceń występuje na kanałach 3 i 6. Natomiast pomiędzy sygnałami odszumionymi procedurą pierwszą i drugą nie ma znacznych różnic, z wyjątkiem drugiego kanału. Aby pokazać strukturę usuniętych zakłóceń wykonano CWT dla różnicy sygnałów przed i po odszumianiu pierwszą metodą. Z wykresów czas – skala (rys. 6.6 i 6.7) wynika, że szum ma największą amplitudę dla małych wartości skali, a więc dla wysokich częstotliwości.



Rys. 6.6. Usunięte zakłócenia metodą pierwszą przedstawione przy użyciu CWT dla kanału 1÷5



Rys. 6.7. Usunięte zakłócenia metodą pierwszą przedstawione przy użyciu CWT dla kanału 6

6.2. Miary sygnałów

W diagnostyce przekładni zębatych wykorzystywana jest duża liczba miar (parametrów) sygnału drgań zwanych wskaźnikami stanu (ang. condition indices). Część z nich została opracowana specjalnie na potrzeby określania stanu technicznego przekładni zębatych. Według pracy [104] Stewart w 1977 r. wprowadził parametry oznaczone jako *FM0* i *FM4*. W ramach badań w NASA Lewis Research Center [117] opracowano parametry *NA4* i *NB4* a według [88] Martin w 1989 r. opracował *M6A* i *M8A*. Badania prowadzone w NASA, np. [31, 116, 103], dotyczące detekcji uszkodzeń przekładni stożkowych, stosowanych w śmigłowcach z wykorzystaniem m.in. wyżej wymienionych parametrów, miały na celu określenie przydatności tych wskaźników.

Sygnał drgań przed obliczeniem niektórych miar powinien zostać wstępnie przetworzony poprzez odpowiednią filtrację, uśrednianie synchroniczne czy wykonanie obwiedni sygnału. Poniżej zostaną przedstawione parametry dla sygnałów dyskretnych, które zostały użyte w niniejszej pracy zgodnie z [20, 31, 58, 59, 61, 33, 50, 29, 119, 54, 55].

1. Wartość średnia wyprostowana

Średnia arytmetyczna jest powszechnie stosowana w statystyce, zwłaszcza dla danych o rozkładzie jednomodalnym, symetrycznym. Jednak dla sygnałów oscylacyjnych, jakimi są drgania, nie jest to dobra miara, ponieważ przyjmuje wartości bliskie zeru. Dlatego stosuje się wartość średnią z wartości bezwzględnej określoną zależnością:

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (22)$$

gdzie:

x_n – wartość sygnału dyskretnego w n -tym punkcie, $n = 1, \dots, N$,

N – liczba próbek w sygnale.

2. Mediana bezwzględna

Dla danych o rozkładzie niesymetrycznym lepszym wskaźnikiem położenia jest mediana. Cechuje się ona niewrażliwością na wartości odstające. Z tych samych powodów, co dla średniej arytmetycznej, obliczenia wykonywane są dla sygnałów o wartości bezwzględnej.

$$\tilde{x} = \begin{cases} x_{((N+1)/2)}, & \text{dla } |x_n| \text{ gdy } n \text{ jest nieparzyste} \\ \frac{1}{2}(x_{(N/2)} + x_{(N/2+1)}), & \text{dla } |x_n| \text{ gdy } n \text{ jest parzyste} \end{cases} \quad (23)$$

3. Wartość skuteczna

Wartość skuteczna (ang. root mean square – RMS) jest bardzo często występującą miarą w diagnostyce wibroakustycznej maszyn, w tym także przekładni zębatych. Jej pomiar zalecany jest do oceny stanu w Polskich Normach PN [83] i międzynarodowych ISO [82]. Dla sygnału nieprzetworzonego („surowego”) jest to bardzo dobra miara ogólnego stanu przekładni. Natomiast nie jest ona czuła na zmiany, objawiające się jako pojedyncze impulsy (maksima) w sygnale np. początkowe stadia uszkodzeń uzębienia.

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (24)$$

4. Moc sygnału

Energia sygnału obliczona dla skończonego czasu trwania (liczby próbek sygnału) nazywana jest mocą sygnału. Zdefiniowana jest ona podobnie jak wartość skuteczna, lecz bez wyciągania pierwiastka. Oznacza to, że może się cechować większą czułością na zmiany sygnału drgań.

$$P = \frac{1}{N} \sum_{n=1}^N x_n^2 \quad (25)$$

5. Wartość szczytowa

Cempel w swoich monografiach [19, 20] preferuje stosowanie wartości szczytowej nad wartość skuteczną, podając przykład większej wrażliwości tego parametru na zmianę stanu obiektu oraz podkreślając jego powszechne stosowanie w krajach anglosaskich.

$$\hat{x} = \max |x_n| \quad (26)$$

6. Wartość międzyszczytowa

Wartość międzyszczytowa różni się od wartości szczytowej tym, iż bierze pod uwagę dwie skrajne wartości – najmniejszą i największą. Jest to również najprostsza miara rozproszenia, nazywana w statystyce rozstępem. Uzupełnia ona informacje o rozkładzie wartości w próbie, pozyskane poprzez obliczenie wskaźników położenia. Wartość międzyszczytowa zalecana jest do stosowania podczas odbioru przekładni zębatych przy sprawdzaniu łożysk poprzecznych ślizgowych, gdzie drgania mierzone są bezpośrednio na wałach [3, 83].

$$X_{pp} = X_{\max} - X_{\min} \quad (27)$$

7. Kurtoza

Kurtoza jest momentem centralnym czwartego rzędu i jest miarą spłaszczenia rozkładu. Dla rozkładu normalnego przyjmuje wartość równą 3. Jeżeli rozkład jest bardziej smukły, wartość kurtozy jest większa od 3, a jeżeli jest bardziej spłaszczony wartość jest mniejsza niż 3. Według pracy [104] pojawienie się impulsów w sygnale drgań przekładni spowoduje wzrost wartości kurtozy. Można wyciągnąć wniosek, że dla przekładni uszkodzonej wartość kurtozy powinna być większa niż w dobrym stanie technicznym.

$$k = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^4}{\left[\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2 \right]^2} \quad (28)$$

Przedstawione powyżej parametry amplitudowe sygnałów, z wyjątkiem kurtozy, są wrażliwe na zmiany drgań, spowodowane zmianami obciążenia i prędkości obrotowej. Poniżej zostaną przedstawione trzy bezwymiarowe parametry amplitudowe sygnałów, które nie powinny być wrażliwe na zmienne warunki pracy. Nie rozważano w niniejszej pracy współczynnika kształtu, ponieważ wg Cempela ma on minimalną wrażliwość na zmiany stanu technicznego [20, 21].

8. Współczynnik szczytu

W początkowym stadium uszkodzenia lokalnego uzębienia wzrasta wartość szczytowa, ponieważ w sygnale drgań występują impulsy o większej amplitudzie, związane z uszkodzeniem. Ich intensywność nie jest na tyle duża, aby zmienić wartość skuteczną. Zwiększy się zatem wartość współczynnika szczytu. Wraz z rozwojem uszkodzenia wzrośnie również wartość skuteczna a więc wartość współczynnika szczytu zmaleje. Z przedstawionych rozważań wynika, że współczynnik szczytu jest dobrym parametrem do wykrywania lokalnych uszkodzeń w początkowych stadiach.

$$C = \frac{\hat{x}}{x_{RMS}} \quad (29)$$

9. Współczynnik impulsowości

Definiowany jest podobnie jak współczynnik szczytu z tą różnicą, że w mianowniku jest wartość średnia wyprostowana. Ma on więc zbliżone właściwości diagnostyczne i cechuje się większą wrażliwością.

$$I = \frac{\hat{x}}{\bar{x}} \quad (30)$$

10. Współczynnik luzu

Według badań Cempela nad przydatnością diagnostyczną bezwymiarowych parametrów amplitudowych [20] współczynnik luzu jest bardziej wrażliwy niż współczynnik szczytu i impulsowości.

$$L = \frac{\hat{x}}{\tilde{x}} \quad (31)$$

11. Wariancja

Wariancja jest wskaźnikiem (miarą) rozproszenia wyników w próbie wokół wskaźnika położenia. W przeciwieństwie do rozstępu nie jest ona uzależniona tylko od dwóch skrajnych wartości w próbie a zawiera także informację o skupieniu wartości wokół środka rozkładu. Wartości, które znacznie odbiegają od wartości średniej (wskaźnika położenia), mają większy wpływ na wartość wariancji. Wyniki są więc skupione wokół wartości średniej dla niewielkiej wartości wariancji a rozproszone dla wysokiej.

$$s^2 = \frac{1}{N-1} \sum_{n=1}^N (x_n - \bar{x})^2 \quad (32)$$

12. Odchylenie standardowe

Pierwiastek kwadratowy z wariancji s^2 nazywany jest odchyleniem standardowym. Dzięki tej operacji matematycznej jednostka odchylenia standardowego jest taka sama jak jednostka pomiarowa.

$$s = \sqrt{s^2} = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_n - \bar{x})^2} \quad (33)$$

13. Energy ratio

Stosunek wartości skutecznej sygnału różnicowego do wartości skutecznej sygnału ze składowymi okresowymi definiuje wskaźnik proporcji energii *energy*

ratio (ER). Nie ma jednej definicji sygnału różnicowego (por. [109, 88, 59]). W niniejszej pracy sygnał różnicowy definiowany jest jako sygnał bez podstawowych częstotliwości obrotowych wałów i harmonicznym ząbienia wraz ze wstęgami bocznymi, pochodzącymi od wału niskoobrotowego. Sygnał okresowy $d'(n)$ określony jest jako różnica między sygnałem drgań $x(n)$ a sygnałem różnicowym $d(n)$. Występuje również inna definicja parametru *ER*, w której wartość skuteczna zastąpiona jest odchyleniem standardowym [104].

Idea, która towarzyszyła powstaniu tego parametru, to wykrywanie zaawansowanego zużycia kół zębatych.

$$ER = \sqrt{\frac{\frac{1}{N} \sum_{n=1}^N (d_n)^2}{\frac{1}{N} \sum_{n=1}^N (d'_n)^2}} \quad (34)$$

14.FM0

Parametr ten określony jest jako stosunek wartości międzyszczytowej x_{pp} do sumy amplitud harmonicznym ząbienia A_h , gdzie H oznacza liczbę rozważanych harmonicznym. Dedykowany jest do wykrywania głównym uszkodzeń kół zębatych, takich jak wyłamany ząb czy intensywne rozproszone zużycie zębów.

$$FM0 = \frac{x_{pp}}{\sum_{h=1}^H A_h} \quad (35)$$

15.FM4

Miara *FM 4* zdefiniowana jest jako kurtoza z sygnału różnicowego. Została opracowana jako uzupełnienie miary *FM0* do wykrywania uszkodzeń ograniczonych do kilku zębów. Do czasu, kiedy uszkodzenie jest lokalne, wartość tej miary powinna wzrastać, gdy uszkodzenie stanie się rozproszone, wartość powinna się zmniejszyć. Jeżeli sygnał różnicowy ma rozkład normalny wartość, *FM4* wynosi 3.

$$FM4 = \frac{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^4}{\left[\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2 \right]^2} \quad (36)$$

gdzie:

$\bar{d}$ – wartość średnia sygnału różnicowego.

16.NA4

Podawanych jest kilka definicji tej miary, jak również i sygnału resztkowego (por. 33, 89, 31, 58]). W niniejszej pracy sygnał resztkowy $r(n)$ określony jest jako sygnał z usuniętymi podstawowymi częstotliwościami wałów oraz harmonicznymi zazębienia. W przeciwieństwie do miary $FM4$ i sygnału różnicowego nie są usuwane wstęgi boczne wokół harmonicznymi zazębienia. Drugą zmianą jest uwzględnienie poprzednich pomiarów w mianowniku ułamka.

NA4 jest udoskonaleniem miary $FM4$. Jest ona wrażliwa nie tylko wtedy, kiedy uszkodzenie jest w początkowym stadium rozwoju. Jej wartość wzrasta również wraz z rozwojem uszkodzenia co do intensywności, jak i ze zmianą z uszkodzenia lokalnego na rozproszone. Oznacza to, iż można obserwować trend rozwoju uszkodzenia. Kilka godzin przed awarią przekładni miara zmienia swoją wartość w sposób gwałtowny. Dla rozkładu normalnego sygnału resztkowego wartość NA4 wynosi 3.

$$NA4 = \frac{\frac{1}{N} \sum_{n=1}^N (r_n - \bar{r})^4}{\frac{1}{M} \sum_{m=1}^M \left[\frac{1}{N} \sum_{n=1}^N (r_{n,m} - \bar{r}_m)^2 \right]^2} \quad (37)$$

gdzie:

r_n – wartość sygnału resztkowego w n -tym punkcie dla bieżącego pomiaru,

$n = 1, \dots, N$,

N – liczba próbek w sygnale,

$\bar{r}$ – wartość średnia sygnału resztkowego z bieżącego pomiaru,

$\bar{r}_m$ – wartość średnia sygnału resztkowego dla m -tego pomiaru, $m = 1, \dots, M$,

M – liczba sygnałów w zbiorze pomiarowym,

$r_{n,m}$ – wartość sygnału resztkowego w n -tym punkcie dla m -tego pomiaru.

17.M6A

Parametr $M6A$ został zaproponowany jako wskaźnik uszkodzenia powierzchni zębów. Podstawy jego działania są takie same jak parametru $FM4$ z tą różnicą, iż jest to szósty moment centralny normalizowany przez wariancję do potęgi trzeciej, dlatego jest bardziej czuły na impulsy w sygnale.

$$M6A = \frac{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^6}{\left[\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2 \right]^3} \quad (38)$$

18.M8A

Jeszcze bardziej czułym parametrem niż $M6A$ jest parametr $M8A$, określony jako moment centralny ósmego rzędu, normalizowany przez wariancję do potęgi czwartej. Należy jednak podkreślić, że wysoka czułość na impulsy w sygnale nie zawsze jest pożądana, ponieważ może prowadzić do fałszywych alarmów.

$$M8A = \frac{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^8}{\left[\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2 \right]^4} \quad (39)$$

19.NB4

Parametr $NB4$ wywodzi się z parametru $NA4$, jednak obliczany jest na podstawie obwiedni sygnału a nie sygnału resztkowego.

W pierwszym kroku sygnał filtrowany jest filtrem pasmowoprzepustowym wokół harmonicznego zazębienia, przy czym szerokość pasma przepustowego nie jest jednoznacznie określona w literaturze. Niektórzy autorzy sugerują filtrację, zapewniającą jak najszersze pasmo, zawierające wstęgi boczne. Inni ograniczają je do zawartości tylko pierwszej harmonicznego, występującej wokół częstotliwości zazębienia. Następnie sygnał poddawany jest transformacji Hilberta, w wyniku której otrzymywany jest sygnał zespolony w postaci:

$$s(n) = E(n) + i * E(n) \quad (40)$$

gdzie:

$E(n)$ – część rzeczywista sygnału, tożsama z sygnałem oryginalnym $s(n)$,

$i * E(n)$ – część urojona sygnału, która jest transformatą Hilberta, różniącą się od sygnału oryginalnego przesunięciem fazowym o 90° .

W celu otrzymania obwiedni sygnału należy wyznaczyć wartość bezwzględną z równania:

$$e(n) = |E(n) + i * E(n)| \quad (41)$$

Koncepcja, przyświecająca powstaniu parametru $NB4$ jest taka, że uszkodzenia kilku zębów wywołają fluktuację obciążenia różną od tej, którą powodują nieuszkodzone zęby, co uwidoczni się w obwiedni sygnału. Parametr wykazuje także skuteczność w wykrywaniu pittingu. Jest to jednak mało skuteczny sposób w przypadku wyłamania pojedynczego zęba.

$$NB4 = \frac{\frac{1}{N} \sum_{n=1}^N (e_n - \bar{e})^4}{\frac{1}{M} \sum_{m=1}^M \left[\frac{1}{N} \sum_{n=1}^N (e_{n,m} - \bar{e}_m)^2 \right]^2} \quad (42)$$

20. Energy operator

Parametr energy operator określony jest jako kurtoza z sygnału $re(n)$. Sygnał ten obliczany jest z następującej zależności:


$$re_n = x_n^2 - x_{n-1}x_{n+1} \quad (43)$$

Kiedy obliczany jest pierwszy punkt (dla $n = 1$), do obliczeń brany jest ostatni punkt z sygnału i odwrotnie.

Pojawienie się w sygnale drgań impulsów, związanych z uszkodzeniem, jest wzmocnione przez miarę energy operator, co umożliwia ich łatwiejsze wykrycie. Stosowany jest on do wczesnego wykrywania pęknięć zmęczeniowych zębów. Dla sygnału o rozkładzie normalnym wartość tego parametru wynosi 3.

$$EOP = \frac{\frac{1}{N} \sum_{n=1}^N (re_n - \overline{re})^4}{\left[\frac{1}{N} \sum_{n=1}^N (re_n - \overline{re})^2 \right]^2} \quad (44)$$

Przykładowe wartości miar obliczone dla jednej przekładni przedstawione są na rysunku 6.8. Wartości na tym rysunku zostały znormalizowane tak, aby maksymalna wartość każdej miary wynosiła 1.



Rys. 6.8. Przykładowe wartości miar obliczone dla jednej przekładni

6.3. Wybór optymalnych miar sygnałów

Duża liczba miar, w tym miar niosących małą ilość informacji o stanie przekładni, może powodować, że zbudowane na ich podstawie modele neuronowe będą miały słabe właściwości generalizacyjne, a więc nie będą funkcjonowały prawidłowo dla nowych przypadków. Użycie liczego zbioru zmiennych powoduje również konieczność posiadania bardzo dużej liczby przypadków, co często jest problematyczne, a powstałe modele są bardziej złożone, przez co wzrasta czas obliczeń. Zastosowano więc algorytm zaliczany

do metod filtrów, który dokonuje rankingu miar. Metoda ta przedstawiona jest w pracy [59], w której wykrywano uszkodzenie zębów kół walcowych z wykorzystaniem sygnału drgań. Opisaną poniżej metodę autorzy niniejszej monografii prezentowali już w pracy [47].

Danymi wejściowymi do algorytmu jest tablica trójwymiarowa o wymiarach M_c na C na J , gdzie:

J oznacza liczbę miar sygnałów, M_c liczbę wartości dla każdej z miar a C ilość rozpatrywanych stanów obiektu.

Zapis $p_{m,c,j}$ oznacza m -tą wartość j -tej miary dla c -go stanu obiektu, gdzie:
 $m=1,2,...,M_c$; $c=1,2,...,C$; $j=1,2,...,J$.

W niniejszej pracy rozpatrywane są trzy stany w zadaniu klasyfikacji ($C=3$), dla których obliczono dwadzieścia miar ($J=20$). Metoda obliczeń składa się z następujących kroków:

Etap (1)

Oblicz średnią odległość między poszczególnymi wartościami miar w tym samym stanie:

$$D_{c,j} = \sqrt{\frac{1}{M_c \times (M_c - 1)} \sum_{l,m=1}^{M_c} (p_{m,c,j} - p_{l,c,j})^2}, \quad l, m = 1, 2, \dots, M_c, l \neq m \quad (45)$$

a następnie oblicz średnią odległość dla C stanów obiektu:

$$D_j^{(w)} = \frac{1}{C} \sum_{c=1}^C D_{c,j} \quad (46)$$

Etap (2)

Określ i oblicz współczynnik wariancji $V_j^{(w)}$ w następujący sposób:

$$V_j^{(w)} = \frac{\max(D_{c,j})}{\min(D_{c,j})} \quad (47)$$

Etap (3)

Oblicz średnią odległość dla wszystkich wartości miar dla tego samego stanu:

$$a_{c,j} = \frac{1}{M_c} \sum_{m=1}^{M_c} p_{m,c,j} \quad (48)$$

a następnie uzyskaj średnią odległość pomiędzy wartościami miar dla różnych stanów:

$$D_j^{(b)} = \sqrt{\frac{1}{C \times (C-1)} \sum_{c,e=1}^C (a_{e,j} - a_{c,j})^2}, c,e = 1, 2, \dots, C \quad (49)$$

Etap (4)

Określ i oblicz współczynnik wariancji $V_j^{(b)}$ dla obiektu w różnym stanie:

$$V_j^{(b)} = \frac{\max(|a_{e,j} - a_{c,j}|)}{\min(|a_{e,j} - a_{c,j}|)}, c,e = 1, 2, \dots, C \quad (50)$$

Etap (5)

Określ i oblicz λ_j jak poniżej:

$$\lambda_j = \left(\frac{V_j^{(w)}}{\max(V_j^{(w)})} + \frac{V_j^{(b)}}{\max(V_j^{(b)})} \right)^{-1} \quad (51)$$

Etap (6)




Oblicz stosunek dla $D_j^{(b)}$ i $D_j^{(w)}$ oraz wyznacz E_j :

$$E_j = \lambda_j \frac{D_j^{(b)}}{D_j^{(w)}} \quad (52)$$

a następnie normalizuj E_j przez maksymalną wartość i otrzymaj kryterium wartościowania:

$$\bar{E}_j = \frac{E_j}{\max(E_j)} \quad (53)$$

Podzielenie E_j przez wartość maksymalną powoduje, że otrzymane wyniki będą z zakresu od 0 do 1. Im wartość bliższa jeden, tym dana miara lepiej odzwierciedla stan obiektu. Wybór może być dokonany za pomocą kryterium $\bar{E}_j \geq P$, gdzie P jest wybraną wartością progu dla cech.



Rys. 6.9. Klasyfikacja miar

Rysunek 6.9 przedstawia wyniki działania algorytmu dla dwudziestu miar. Wartość progu, powyżej którego dana miara uznawana jest za przydatną, zaznaczona jest poziomą linią. Wybór wartości progowej jest decyzją subiektywną, podyktowaną m.in. wyborem odpowiedniej liczby miar. Według Yanga [115] zazwyczaj liczba od pięć do dziesięciu miar jest poprawna z punktu widzenia czasu obliczeń i dokładności rezultatów.

Wartości progów ustalono tak, aby uzyskać sześć najlepszych miar. Są nimi:

- 1 – wartość średnia wyprostowana,
- 3 – wartość skuteczna RMS,
- 5 – wartość szczytowa,
- 6 – wartość międzyszczytowa,
- 12 – odchylenie standardowe,
- 14 – $FM0$.

Ponieważ miara 1 i 3 obliczana jest w podobny sposób, przebieg miar na wykresach jest również bardzo zbliżony (rys. 6.8). Oznacza to także, że informacja niesiona przez te miary w dużym stopniu jest taka sama. Wybrano więc RMS dlatego, że jest ona stosowana w normach polskich i międzynarodowych oraz w literaturze przy diagnostyce wibroakustycznej przekładni zębatych. Podobny przypadek zachodzi dla miary 5 i 6. Z tych dwóch miar wybrano wartość międzyszczytową, która bazuje na dwóch wartościach. Ostatecznie więc budowa modeli neuronowych przeprowadzona będzie w oparciu o miare 3, 6, 12 i 14.

6.4. Sieci neuronowe

6.4.1. Perceptron wielowarstwowy MLP


Budowa sieci i sposób działania

Sieć neuronowa to zbiór odpowiednio połączonych neuronów. Spośród różnych typów sieci najbardziej popularny jest perceptron wielowarstwowy. Charakteryzuje się on neuronami ułożonymi warstwowo, w których sygnały przepływają tylko w jednym kierunku.

Każdy neuron odznacza się przynajmniej jednym wejściem i pojedynczym wyjściem (rys. 6.10). Sygnały wejściowe x_i mnożone są przez współczynniki zwane wagami synaptycznymi w_i a następnie sumowane. Wartości wag mogą być zmieniane, co umożliwia naukę sieci i dostosowanie do rozpatrywanego zadania.

Do sygnałów wejściowych dodawany jest parametr w_0 (ang. bias) o stałej wartości a przy zapisie $-w_0$ nazywany jest on wartością progową (ang. threshold), przy czym $x_0 = 1$ [12]. Przekształcenie sygnałów x_i jest zgodne z zależnością:

$$u = w_0 + \sum_{i=1}^N w_i x_i \quad (54)$$



Rys. 6.10. Schemat sztucznego neuronu McCullocha i Pittsa

Następnie sygnał określający łączne pobudzenie neuronu u jest przekształcany przez funkcję aktywacji $f(u)$ i uzyskiwany jest sygnał wyjściowy z neuronu o postaci:

$$y = f(u) \quad (55)$$

W trakcie poszukiwania optymalnej sieci MLP sprawdzono przydatność liniowych i nieliniowych funkcji aktywacji dla warstwy ukrytej i wyjściowej, a dokładnie: liniowej, logistycznej, tangens hiperboliczny, wykładniczej i softmax (tylko dla warstwy wyjściowej).

Liniowa funkcja aktywacji (rys. 6.11) przekazuje na wyjście neuronu sygnał o wartości równej łącznemu pobudzeniu neuronu wg zależności:

$$f(u) = u \quad (56)$$

Do funkcji sigmoidalnych (esowatych) zaliczane są dwie nieliniowe funkcje: logistyczna (rys. 6.12) i tangens hiperboliczny (rys. 6.13). Są to najczęściej stosowane funkcje aktywacji dla sieci MLP. Funkcja logistyczna przyjmuje wartości wyjściowe z przedziału od 0 do 1 i wyraża się wzorem:


$$f(u) = \frac{1}{1 + e^{-u}} \quad (57)$$

Natomiast funkcja tangens hiperboliczny, która jest symetryczna względem osi odciętych, przyjmuje wartości z zakresu od -1 do 1 i może mieć postać:

$$f(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}} \quad (58)$$


Wykładnicza funkcja aktywacji stosowana jest głównie do neuronów w sieciach o radialnych funkcjach bazowych, jednakże zastosowano ją tutaj do sieci MLP. Postać jej widoczna jest na rysunku 6.14 a opisuje ją wzór:

$$f(u) = e^{-u} \quad (59)$$




Zakres wartości wyjściowych:
 $(-\infty, +\infty)$

Rys. 6.11. Liniowa funkcja aktywacji




Zakres wartości wyjściowych:
 $(0, 1)$

Rys. 6.12. Logistyczna funkcja aktywacji



Zakres wartości wyjściowych:
 $(-1, +1)$

Rys. 6.13. Funkcja aktywacji tangens hiperboliczny



Zakres wartości wyjściowych:

$$(0, +\infty)$$

Rys. 6.14. Wykładnicza funkcja aktywacji


Funkcja softmax (rys. 6.15) jest uogólnieniem funkcji logistycznej. Znajduje ona zastosowanie w zadaniach klasyfikacyjnych a stosowana jest do neuronów z warstwy wyjściowej. Na wyjściach neuronów uzyskuje się sygnały, których suma równa się jeden, co pozwala interpretować ich wartości jako prawdopodobieństwo przynależności do klasy. Zakres wartości wyjściowych dla poszczególnych neuronów jest od 0 do 1 a oblicza się go z zależności:

$$y_k = \frac{e^{u_k}}{\sum_{k=1}^C e^{u_k}} \quad (60)$$

gdzie:

y_k – sygnał wyjściowy dla k -tego neuronu,

$k = 1, \dots, C$ – liczba neuronów w warstwie wyjściowej.



Zakres
wartości
wyjściowych
: (0,1)

Rys. 6.15. Wartości wyjściowe neuronów y_k uzyskane dla przykładowych sygnałów sumarycznych u_k

W niniejszej pracy budowano struktury sieci MLP widoczne na rysunku 6.16. Sieci składają się z warstwy wejściowej, wyjściowej i znajdującej się w środku warstwy ukrytej (w praktyce liczba warstw ukrytych wynosi 1 lub 2). Najczęściej określa się taką sieć jako dwuwarstwową. Niektórzy autorzy wliczają także warstwę wejściową, wprowadzającą zmienne wejściowe.

Decydujący wpływ na właściwości sieci mają warstwy z adaptacyjnymi wagami, a więc warstwa ukryta i wyjściowa, co uzasadnia przyjętą nomenklaturę.

Wartość sygnału wyjściowego dla j -tego neuronu w warstwie ukrytej określa zależność:

$$z_j = f\left(w_{j0} + \sum_{i=1}^N w_{ji}x_i\right) \quad (61)$$

gdzie:

$f(\cdot)$ – funkcja aktywacji,

x_i – wektor zmiennych wejściowych, $i = 1, \dots, N$,

w_{ji} – wektor wag dla i -tej zmiennej j -tego neuronu,

w_{j0} – wartość zwana bias dla j -tego neuronu, przy czym $x_0 = 1$,

z_j – sygnał wyjściowy dla j -tego neuronu, $j = 1, \dots, M$.

Natomiast sygnał wyjściowy dla k -tego neuronu z warstwy wyjściowej może być określony wzorem:

$$y_k = w_{k0} + g\left(\sum_{j=1}^M w_{kj}f\left(w_{j0} + \sum_{i=1}^N w_{ji}x_i\right)\right) \quad (62)$$

gdzie:


$g(\cdot)$ – funkcja aktywacji,

w_{kj} – wektor wag dla j -tego wyjścia neuronu z warstwy ukrytej i k -tego neuronu z warstwy wyjściowej,

w_{k0} – wartość zwana bias dla k -tego neuronu, przy czym $z_0 = 1$,

y_k – sygnał wyjściowy dla k -tego neuronu, $k = 1, \dots, C$.

Dla podkreślenia, że funkcja aktywacji w warstwie wyjściowej może być inna niż w warstwie ukrytej, użyto oznaczenia $g(\cdot)$.



Rys. 6.16. Schemat zastosowanej sieci MLP [124]

Algorytmy uczenia sieci neuronowej

Obecnie dostępnych jest wiele algorytmów, służących do nauki sieci MLP. Ich rozwój spowodowany jest dwoma podstawowymi czynnikami, a mianowicie zmniejszeniem czasu treningu i osiągnięciem jak najmniejszego błędu nauki przez sieć. Szybsze metody mogą być podatne na zatrzymanie się w minimach lokalnych, a w szczególnych zastosowaniach wzrost szybkości może być nieznaczny [98], dlatego nie należy sugerować się tylko tą właściwością. Nauka sieci odbywała się za pomocą dwóch algorytmów: największego spadku i zmiennej metryki, zaliczanymi do kategorii metod gradientowych.

W algorytmach gradientowych nauka sieci neuronowych polega na minimalizacji funkcji celu $E(W)$. Rozwinięcie tej funkcji w szereg Taylora, w pewnym otoczeniu punktu początkowego W i wzdłuż wyznaczonego wcześniej kierunku p , ma postać:

$$E(W + p) = E(W) + [g(W)]^T p + \frac{1}{2} p^T H(w) p + \dots \quad (63)$$

W równaniu tym występuje wektor gradientu $g(W)$ określony zależnością:

$$g(W) = \nabla E = \left[\frac{\partial E}{\partial W_1}, \frac{\partial E}{\partial W_2}, \dots, \frac{\partial E}{\partial W_n} \right] \quad (64)$$

i macierz drugich pochodnych (hesjan):

$$H(W) = \begin{bmatrix} \frac{\partial^2 E}{\partial W_1 \partial W_1}, \dots, \frac{\partial^2 E}{\partial W_1 \partial W_n} \\ \vdots \\ \frac{\partial^2 E}{\partial W_n \partial W_1}, \dots, \frac{\partial^2 E}{\partial W_n \partial W_n} \end{bmatrix} \quad (65)$$

Zgodnie z Osowskim [78] algorytm nauki sieci może być przedstawiony w czterech krokach (przy założeniu, iż dana jest wartość początkowa wektora optymalizowanego $W_k = W_0$, wskaźnik dolny k oznacza k – ty cykl):

1. Dla punktu W_k wykonywany jest test na zbieżność i optymalność rozwiązania. Jeżeli spełnia on warunki zatrzymania ze względu na gradient, to obliczenia są zatrzymywane, jeśli nie, wykonywany jest punkt 2.
2. Wyznaczanie wektora kierunku poszukiwań p_k w punkcie W_k .
3. Określenie kroku η_k na kierunku p_k , aby była spełniona nierówność $E(W_k + \eta_k p_k) < E(W_k)$.
4. Wyznaczanie nowego rozwiązania $W_{k+1} = W_k + \eta_k p_k$ oraz odpowiadającej mu wartości $E(W_k)$, $g(W_k)$ i ewentualnie $H(W_k)$, a następnie powrót do punktu 1.

W algorytmie największego spadku wykorzystywane są tylko dwa pierwsze elementy z szeregu Taylora (63), funkcja celu $E(W)$ przybliżana jest w sposób liniowy. Spełnienie zależności $E(W_{k+1}) < E(W_k)$ oznacza, że wartość funkcji błędu w kolejnych krokach będzie maleć. Zachodzi to przy warunku:

$$[g(W_k)]^T p_k < 0 \quad (66)$$

Wektor kierunkowy ma postać:

$$p_k = -g(W_k) \quad (67)$$

Wadą metody największego spadku jest jej wolnozbieżność, spowodowana nieuwzględnieniem informacji o krzywiznie funkcji zawartej w hesjanie. Również w pobliżu punktu optymalnego, kiedy wartości gradientu przyjmują małe wartości, brak jest postępów optymalizacyjnych. Do zalet należy zaliczyć małe wymagania sprzętowe dzięki prostocie obliczeniowej. Stosowana jest ona ciągle do nauki sieci wielowarstwowych.

W metodzie zmiennej metryki stosuje się kwadratowe przybliżenie funkcji (trzy pierwsze składniki szeregu Taylora) $E(W)$. Osiągnięcie minimum funkcji (63) wymaga, aby był spełniony warunek:

$$\frac{dE(W_k + p_k)}{dp_k} = 0 \quad (68)$$

dla kierunku wyznaczonego z równania:

$$p_k = [H(W_k)]^{-1} g(W_k) \quad (69)$$

Należy więc dla każdego cyklu wyznaczyć wartość gradientu g i hesjanu H , aby określić kierunek w punkcie W_k . Wyznaczenie hesjanu dodatnio określonego jest trudne, dlatego rezygnuje się z obliczania dokładnej wartości $H(W_k)$ i wyznacza się jego wartość przybliżoną $G(W_k)$. Wykonywane jest to poprzez modyfikację odwrotności przybliżonej macierzy hesjanu $V_k = [G(W_k)]^{-1}$ z poprzedniego kroku o pewną poprawkę. W metodzie zmiennej metryki obliczanie uaktualnienia macierzy V może być wykonane zgodnie z formułą Broydena-Fletcher-Goldfarba-Shanno (BFGS), która została użyta w niniejszej pracy:

$$V_k = V_{k+1} + \left[1 + \frac{r_k^T V_{k-1} r_k}{s_k^T r_k} \right] \frac{s_k s_k^T}{s_k^T r_k} - \frac{s_k r_k^T V_{k-1} + V_{k-1} r_k s_k^T}{s_k^T r_k} \quad (70)$$

gdzie:

s_k – przyrost wektora wag W , $s_k = W_k - W_{k-1}$,

r_k – przyrost wektora gradientu g , $r_k = g(W_k) - g(W_{k-1})$.

W pierwszym kroku przyjmuje się V jako macierz jednostkową a obliczenia następują zgodnie z algorytmem największego spadku. W kolejnych krokach stosowana jest zależność (70). Do zalet algorytmu należy zaliczyć szybkość zbieżność. Uważany jest on także za jedną z najlepszych metod optymalizacyjnych wielu zmiennych [78]. Do wad natomiast przypisuje się znaczną złożoność obliczeniową i duże wymagania, dotyczące pamięci operacyjnej.

Algorytmy uczące uzyskują informacje o postępie w nauce sieci za pomocą funkcji błędu. Sprawdzany jest bieżący błąd sieci na podstawie odpowiedzi sieci i wartości kontrolnych. Jako funkcje błędu wybrano sumę kwadratów (ang. sum of squares error) i entropię wzajemną (ang. cross entropy).

Suma kwadratów stosowana jest głównie dla problemów predykcyjnych. Obliczana jest ona jako suma kwadratów różnic pomiędzy wartościami wyjściowymi z sieci y_i a zadanymi t_i , z zależności [101]:

$$E_{SK} = \sum_{n=1}^N (y_i - t_i)^2 \quad (71)$$

gdzie $n = 1, \dots, N$ oznacza liczbę przypadków.

Entropia wzajemna wykorzystywana jest tylko do zagadnień klasyfikacji i ma postać [101]:

$$E_{EW} = - \sum_{i=1}^N t_i \ln \left(\frac{y_i}{t_i} \right) \quad (72)$$

6.4.1.1. Wyniki oceny montażu przekładni zębatych stożkowych

Klasyfikacja

Długości śladów współpracy przekładni kontrolnych nie zawierają się w zakresie żadnej z klas (patrz tab. 6.1). Jednakże długość śladu przylegania przekładni 12 jest najbliższej górnego zakresu klasy II, a dla przekładni 13 jest to dolny zakres klasy III. Sieci neuronowe muszą w takim przypadku dokonać klasyfikacji obiektów, które wykraczają poza zakres danych, co nie jest zadaniem prostym.

Przed analizą wyników należy wyjaśnić pojęcie zbioru testowego i walidacyjnego oraz poprawności klasyfikacji. Zbiór walidacyjny bierze udział w sposób pośredni w uczeniu sieci neuronowej. Pomaga on w określeniu momentu zatrzymania nauki w taki sposób, aby sieć nadmiernie nie dopasowała się do danych ze zbioru uczącego i potrafiła prawidłowo działać również dla nowych przypadków. Zbiór walidacyjny w ogóle nie uczestniczy w procesie uczenia. Został on wyodrębniony dla jedenastu przekładni w celu oceny powstałych sieci neuronowych. Poprawność klasyfikacji określa w procentach stosunek przypadków prawidłowo sklasyfikowanych do wszystkich przypadków.

Tabela 6.2. Wyniki klasyfikacji dla obciążenia wynoszącego 34,3% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	7	12	3
Funkcja aktywacji: ➤ warstwa ukryta ➤ warstwa wyjściowa	Logistyczna Tangens hiperboliczny	Liniowa Wykładnicza	Tangens hiperboliczny Tangens hiperboliczny
Poprawność klasyfikacji dla: ➤ zbioru testowego ➤ zbioru walidacyjnego	100% 100%	100% 100%	100% 100%
Poprawność klasyfikacji dla przekładni kontrolnych: ➤ numer 12 ➤ numer 13	100% 100%	100% 100%	100% 100%

Sieci, dla których osiągnięto najlepsze wyniki dla drgań zapisywanych przy pierwszym obciążeniu, przedstawione są w tabeli 6.2. Niezależnie od wariantu metody poprawność klasyfikacji wynosi 100% dla zbioru walidacyjnego, jak i dla przekładni kontrolnych.

Gorsze wyniki osiągnięto dla obciążenia drugiego (tab. 6.3). W wariancie I metody żadna z przekładni kontrolnych nie została prawidłowo przypisana do swojej klasy, pomimo poprawności klasyfikacji dla zbioru walidacyjnego na poziomie 99,67%. Lepszy rezultat osiągnięto dla pozostałych wariantów metody z odszumianiem sygnałów. Przekładnia kontrolna 12 została poprawnie przydzielona do swojej grupy.

Przy największym obciążeniu wszystkie warianty metody osiągnęły taki sam rezultat (tab. 6.4). Poprawność klasyfikacji dla zbioru walidacyjnego i przekładni 13 wyniosła 100%, natomiast nieprawidłowo została sklasyfikowana przekładnia 12.

Dla sieci MLP w problemie klasyfikacji śladu współpracy najkorzystniejszym momentem badań jest etap, w trakcie którego przekładnia jest najmniej obciążona.

Tabela 6.3. Wyniki klasyfikacji dla obciążenia wynoszącego 86,8% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	3	3	6
Funkcja aktywacji: ➤ warstwa ukryta ➤ warstwa wyjściowa	Logistyczna Liniowa	Tangens hiperboliczny Liniowa	Tangens hiperboliczny Liniowa
Poprawność klasyfikacji dla: ➤ zbioru testowego ➤ zbioru walidacyjnego	100% 99,67%	100% 100%	100% 100%
Poprawność klasyfikacji dla przekładni kontrolnych: ➤ numer 12 ➤ numer 13	0% 0%	100% 0%	100% 0%

Tabela 6.4. Wyniki klasyfikacji dla obciążenia wynoszącego 118,8% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	10	8	3
Funkcja aktywacji: ➤ warstwa ukryta ➤ warstwa wyjściowa	Wykładnicza Tangens hiperboliczny	Liniowa Softmax	Tangens hiperboliczny Softmax
Poprawność klasyfikacji dla: ➤ zbioru testowego ➤ zbioru walidacyjnego	100% 100%	100% 100%	100% 100%
Poprawność klasyfikacji dla przekładni kontrolnych: ➤ numer 12 ➤ numer 13	0% 100%	0% 100%	0% 100%

Przewidywanie

Drugim zadaniem, stawianym sieciom neuronowym w niniejszej pracy, jest prognoza względnej długości śladu współpracy. Jest to inny problem niż klasyfikacja, dlatego używa się innych wskaźników oceniających utworzone modele neuronowe.

Do oceny sieci neuronowych, w odniesieniu do zbiorów testowych i walidacyjnych, użyto współczynnika korelacji liniowej Pearsona. Wskaźnik ten dla N przypadków oblicza się z zależności:

$$r = \frac{\sum_{n=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{n=1}^N (x_i - \bar{x})^2 \sum_{n=1}^N (y_i - \bar{y})^2}} \quad (73)$$

Określa on zależność między wartościami obserwowanymi a przewidywanymi. Wartość wskaźnika 1 oznacza bardzo silną korelację dodatnią między danymi, -1 – ujemną a 0 oznacza brak korelacji. Dla przekładni kontrolnych wyznaczono natomiast wartość średnią arytmetyczną przewidywanej względnej długości śladu współpracy, odchylenie standardowe oraz błąd prognozy. Ten ostatni wskaźnik został utworzony, aby można było w prosty sposób porównać skuteczność prognozy sieci opracowanych dla różnych wariantów metody i obciążeń. Obliczany jest on z wzoru:

$$\text{Błąd prognozy} = \frac{|x_{rzecz} - \bar{x}_{prog}|}{x_{rzecz}} \cdot 100 \quad (74)$$

gdzie:

x_{rzecz} – rzeczywista względna długość śladu współpracy,

$\bar{x}_{prog}$ – prognozowana wartość średnia względnej długości śladu współpracy.

W przypadku wyników uzyskanych przy pierwszym obciążeniu (tab. 6.5) widoczna jest bardzo wysoka, bliska jedności, korelacja między wartościami rzeczywistymi a przewidywanymi. Dla wariantu I uzyskano nieznacznie lepsze wyniki. Natomiast dla przekładni kontrolnych wariant III metody okazał się najlepszy ze względu na błąd prognozy. Wartość odchylenia standardowego, a więc rozrzut wyników wokół wartości średniej, jest podobny w każdym z wariantów. Podobnie jak i przy klasyfikacji przekładni, dla obciążenia drugiego osiągnięto gorsze wyniki (tab. 6.6). Pomimo wysokiej wartości

współczynnika korelacji średni błąd poprawności prognozy jest znaczny, zwłaszcza dla wariantu I metody.

Tabela 6.5. Wyniki prognozy dla obciążenia wynoszącego 34,3% obciążenia nominalnego (część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	8	10	14
Funkcja aktywacji:			
➤ warstwa ukryta	Tangens hiperb.	Tangens hiperb.	Wykładnicza
➤ warstwa wyjściowa	Wykładnicza	Wykładnicza	Liniowa
Współczynnik korelacji dla:			
➤ zbioru testowego	0,984	0,978	0,978
➤ zbioru walidacyjnego	0,985	0,979	0,979
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna	0,451	0,461	0,468
odchylenie standardowe	0,0053	0,0026	0,0044
błąd prognozy	3,46%	1,11%	0,30%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,502	0,497	0,488
odchylenie standardowe	0,0018	0,0040	0,0027
błąd prognozy	4,33%	3,36%	1,53%
Średni błąd prognozy dla przekł. kontr.	3,89%	2,24%	0,92%

Tabela 6.6. Wyniki prognozy dla obciążenia wynoszącego 86,8% obciążenia nominalnego (część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	9	15	4
Funkcja aktywacji:			
➤ warstwa ukryta	Tangens hiperb.	Logistyczna	Tangens hiperb.
➤ warstwa wyjściowa	Logistyczna	Tangens hiperb.	Liniowa
Współczynnik korelacji dla:			
➤ zbioru testowego	0,979	0,978	0,979
➤ zbioru walidacyjnego	0,978	0,979	0,980
Prognoza względnej długości śladu współpracy dla przykładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna	0,492	0,487	0,477
odchylenie standardowe	0,0023	0,0012	0,0031
błąd prognozy	5,41%	4,39%	2,20%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,381	0,447	0,496
odchylenie standardowe	0,00002	0,0116	0,0112
błąd prognozy	20,75%	7,11%	3,21%
Średni błąd prognozy dla przekł. kontr.	13,08%	5,75%	2,70%

Nadal na wysokim poziomie, niemniej jednak wyraźnie mniejszy, jest współczynnik korelacji dla trzeciego obciążenia (tab. 6.7), dla wszystkich wariantów metody. Natomiast średni błąd prognozy jest poniżej 3% i jest najmniejszy dla III wariantu metody.

Tabela 6.7. Wyniki prognozy dla obciążenia wynoszącego 118,8% obciążenia nominalnego (część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	10	3	4
Funkcja aktywacji:			
➤ warstwa ukryta	Logistyczna	Wykładnicza	Logistyczna
➤ warstwa wyjściowa	Wykładnicza	Liniowa	Wykładnicza
Współczynnik korelacji dla:			
➤ zbioru testowego	0,847	0,858	0,858
➤ zbioru walidacyjnego	0,849	0,859	0,859
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna	0,477	0,463	0,483
odchylenie standardowe	0,0034	0,0065	0,0088
błąd prognozy	2,30%	0,74%	3,49%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,498	0,460	0,478
odchylenie standardowe	0,0033	0,0045	0,0072
błąd prognozy	3,63%	4,43%	0,68%
Średni błąd prognozy dla przekł. kontr.	2,96%	2,59%	2,09%

6.4.2. Sieci o radialnych funkcjach bazowych RBF

Sieci radialne są sieciami jednokierunkowymi, dwuwarstwowymi, składającymi się z warstwy wejściowej, ukrytej i wyjściowej. Neurony wejściowe przekazują dane do neuronów ukrytych, tak jak w przypadku sieci MLP. W warstwie ukrytej występują radialne funkcje bazowe, które są odpowiednikami neuronów ukrytych, i tak też często są określane. W warstwie wyjściowej natomiast występują neurony najczęściej z liniową funkcją aktywacji.

Radialne funkcje bazowe są to funkcje symetryczne, których wartości argumentów x zależą wyłącznie od odległości od centrum c , i opisane są ogólną zależnością $f(x) = (\|x - c\|)$. Najczęściej stosowaną funkcją radialną jest funkcja Gaussa (rys. 6.17), zastosowana również w niniejszej pracy o postaci [101]:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (75)$$

gdzie σ jest parametrem szerokości.

Neurony wyjściowe sumują sygnały pochodzące z neuronów ukrytych z uwzględnieniem wag i wartości bias. Sygnał wyjściowy dla k -tego neuronu może być opisany zależnością:

$$y_k = w_{k0} + \sum_{j=1}^M w_{kj} f_j(\|x - c\|) \quad (76)$$


gdzie:

$f_j(\|x - c\|)$ – radialna j -ta funkcja bazowa,

w_{kj} – wektor wag dla j -tego wyjścia neuronu z warstwy ukrytej i k -tego neuronu z warstwy wyjściowej,

w_{k0} – wartość zwana bias dla k -tego neuronu.

Trening sieci RBF przeprowadzony został w dwóch etapach. W pierwszej kolejności określone zostały parametry funkcji radialnych, a więc środki c i szerokości σ na podstawie danych wejściowych. Następnie zostały określone wagi liniowych neuronów z warstwy wyjściowej. Do kontroli nauki sieci użyto funkcję błędu w postaci sumy kwadratów.



Zakres wartości wyjściowych:

$(0, +\infty)$

Rys. 6.17. Przykładowa funkcja Gaussa

Sieci RBF odznaczają się pewnymi zaletami w stosunku do sieci MLP. Przy wyborze topologii sieci nie ma konieczności wyboru liczby warstw ukrytych, ponieważ jedna warstwa jest wystarczająca do rozwiązania dowolnego problemu. Również proces nauki jest znacznie szybszy. Można też spotkać opinie, że sieci radialne osiągają lepsze rezultaty w problemach klasyfikacyjnych i predykcyjnych [78].

Do negatywnych cech natomiast zalicza się konieczność użycia większej liczby neuronów w warstwie ukrytej w porównaniu z siecią MLP. Dla danych odbiegających od danych uczących, czyli przy zadaniu ekstrapolacji sieci MLP, są bardziej zdecydowane w swojej odpowiedzi [101].

6.4.2.1. Wyniki oceny montażu przekładni zębatych stożkowych

Klasyfikacja

Dla pierwszego obciążenia wyniki dla zbioru walidacyjnego wszystkich wariantów metody są podobne (tab. 6.8). Większe różnice występują dla przekładni kontrolnych. Najlepsze rezultaty osiągnięto dla wariantu III metody. W przypadku drugiego obciążenia (tab. 6.9) wyniki dla zbioru walidacyjnego są na poziomie od ok. 95% dla wariantu I do ok. 99% dla wariantu II. Dla przekładni kontrolnych natomiast uzyskano bardzo słabe rezultaty na poziomie 35%–40%, przy czym najlepsze wyniki osiągnięto dla II wariantu metody. W ostatnim przypadku (tab. 6. 10) najlepsze wyniki dla zbioru walidacyjnego otrzymano dla wariantu I a dla przekładni kontrolnych dla wariantu II na poziomie 40,23%, co jest wynikiem niezadowalającym.

Tabela 6.8. Wyniki klasyfikacji dla obciążenia wynoszącego 34,3% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	12	13	10
Poprawność klasyfikacji dla:			
➤ zbioru testowego	97,32%	97,66%	99,67%
➤ zbioru walidacyjnego	98,33%	97,66%	99,33%
Poprawność klasyfikacji dla przekładni kontrolnych:			
➤ numer 12	99,25%	96,99%	100%
➤ numer 13	96,24%	94,74%	100%
Średnia popraw. klasyfikacji dla przek. kontr.	97,74%	95,86%	100%

Tabela 6.9. Wyniki klasyfikacji dla obciążenia wynoszącego 86,8% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	30	10	15
Poprawność klasyfikacji dla:			
➤ zbioru testowego	94,98%	98,66%	98,33%
➤ zbioru walidacyjnego	95,32%	99,33%	96,99%
Poprawność klasyfikacji dla przekładni kontrolnych:			
➤ numer 12	21,80%	80,45%	66,92%
➤ numer 13	48,87%	0%	0%
Średnia popraw. klasyfikacji dla przek. kontr.	35,34%	40,23%	33,46%

Tabela 6.10. Wyniki klasyfikacji dla obciążenia wynoszącego 118,8% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	30	15	30
Poprawność klasyfikacji dla:			
➤ zbioru testowego	99,33%	99,33%	89,97%
➤ zbioru walidacyjnego	98,66%	97,99%	91,30%
Poprawność klasyfikacji dla przekładni kontrolnych:			
➤ numer 12	3,76%	1,50%	21,05%
➤ numer 13	87,97%	83,46%	84,21%
Średnia popraw. klasyfikacji dla przek. kontr.	45,86%	42,48%	52,63%

Przewidywanie

Współczynnik korelacji dla zbioru walidacyjnego w przypadku pierwszego obciążenia jest na wysokim poziomie i dotyczy wszystkich wariantów metody, przy czym największy jest dla II wariantu (tab. 6.11). Podobnie średni błąd prognozy dla przekładni kontrolnych jest bardzo mały i zbliżony, przy czym najniższy jest dla wariantu I.

Najmniejszą współzależność między danymi w przypadku zbioru walidacyjnego i największy średni błąd prognozy dla przekładni kontrolnych uzyskano przy drugim obciążeniu (tab. 6.11). Przy największym obciążeniu (tab. 6.13) współczynnik korelacji jest dość wysoki i zbliżony dla wszystkich wariantów metody. Średni błąd prognozy jest niski i najmniejszy dla wariantu I.

Tabela 6.11. Wyniki prognozy dla obciążenia wynoszącego 34,3% obciążenia nominalnego (część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	15	15	15
Współczynnik korelacji dla:			
➤ zbioru testowego	0,867	0,915	0,888
➤ zbioru walidacyjnego	0,866	0,916	0,886
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna			
odchylenie standardowe	0,458	0,466	0,466
błąd prognozy	0,0176	0,0100	0,0116
	1,86%	0,04%	0,17%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,484	0,493	0,493
odchylenie standardowe	0,0133	0,0113	0,0123
błąd prognozy	0,57%	2,62%	2,47%
Średni błąd prognozy dla 2 przekładni	1,22%	1,33%	1,32%

Tabela 6.12. Wyniki prognozy dla obciążenia wynoszącego 86,8% obciążenia nominalnego (część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	15	14	14
Współczynnik korelacji dla:			
➤ zbioru testowego	0,860	0,737	0,781
➤ zbioru walidacyjnego	0,844	0,753	0,733
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna			
odchylenie standardowe	0,471	0,465	0,464
błąd prognozy	0,0167	0,0107	0,0100
	0,98%	0,28%	0,64%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,415	0,388	0,404
odchylenie standardowe	0,0063	0,0068	0,0183
błąd prognozy	13,68%	19,27%	16,11%
Średni błąd prognozy dla 2 przekładni	7,33%	9,78%	8,37%

Tabela 6.13. Wyniki prognozy dla obciążenia wynoszącego 118,8% obciążenia nominalnego (część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Liczba neuronów w warstwie ukrytej	15	10	10
Współczynnik korelacji dla:			
➤ zbioru testowego	0,820	0,806	0,836
➤ zbioru walidacyjnego	0,829	0,820	0,830
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna			
odchylenie standardowe	0,459	0,485	0,485
błąd prognozy	0,0088	0,0060	0,0056
	1,58%	3,92%	3,91%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,490	0,480	0,479
odchylenie standardowe	0,0161	0,0072	0,0074
błąd prognozy	1,98%	0,25%	0,35%
Średni błąd prognozy dla 2 przekładni	1,78%	2,08%	2,13%

6.4.3. Metoda wektorów nośnych SVM

Koncepcja SVM może być przedstawiona jako poszukiwanie hiperpłaszczyzny, która rozdzieli dane na poszczególne klasy. Załóżmy, że mamy

dane w postaci wektora x_i dla $i = 1, 2, \dots, m$, które są liniowo separowalne i należą do dwóch klas. Pierwsza klasa oznaczona jest przez $y_i = +1$ (klasa dodatnia) a druga przez $y_i = -1$ (klasa ujemna). W takim przypadku równanie hiperpłaszczyzny (prostej) rozdzielającej dane ma postać:

$$f(x) = w^T x + b = 0 \quad (77)$$

gdzie:

w jest m – wymiarowym wektorem a b jest skalar.

Pozycja hiperpłaszczyzny separującej określona jest przez w i b . Równania w kolejności dla klasy pierwszej i drugiej mają postaci:


$$\begin{aligned} w^T x_i + b &\geq +1 \\ w^T x_i + b &\leq -1 \end{aligned} \quad (78)$$

Teoretycznie istnieje nieskończenie wiele hiperpłaszczyzn prawidłowo separujących dane. Poszukuje się jednak tej optymalnej, tzn. takiej, która zapewnia najmniejszy błąd dla nowych danych, a więc o dobrych własnościach generalizacyjnych. Należy więc znaleźć hiperpłaszczyznę, dla której margines między klasami jest największy (rys. 6.18). Uzyskuje się to poprzez rozwiązanie problemu optymalizacji:

$$\min \cdot \frac{1}{2} \|w\|^2 \quad (79)$$

przy ograniczeniach

$$y_i (w^T x_i + b) \geq 1 \quad (80)$$



Rys. 6.18. Przykład klasyfikacji dwóch klas z użyciem SVM [108]

W praktyce zamienia się to na problem optymalizacji kwadratowej z liniowymi ograniczeniami, rozwiązywanymi za pomocą mnożników Lagrange'a:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \alpha_i y_i (x_i \cdot w + b) + \sum_{i=1}^m \alpha_i \quad (81)$$

Należy minimalizować funkcję Lagrange'a względem parametrów w , b a maksymalizować ze względu na α [118]:

$$y_i (x_i \cdot w + b) - 1 > 0 \rightarrow \alpha_i = 0 \quad (82)$$

$$y_i (x_i \cdot w + b) - 1 = 0 \text{ wektory wspierające} \quad (83)$$

W punkcie ekstremum mamy:

$$\frac{\partial L}{\partial w} = 0, \quad \frac{\partial L}{\partial b} = 0, \quad (84)$$

Co może być zapisane w postaci [108]:

$$w = \sum_{i=1}^m \alpha_i y_i x_i, \quad \sum_{i=1}^m \alpha_i y_i = 0. \quad (85)$$

Podstawiając równanie (84) do równania (80), otrzymamy problem dualny [78]:

$$\text{maksymalizuj } \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (86)$$

przy ograniczeniach

$$\alpha_i \geq 0, \quad \sum_{i=1}^m \alpha_i y_i = 0 \quad (87)$$

Dla danych w pełni nieseparowanych liniowo równanie (78) przyjmuje postać:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i \quad (88)$$

przy ograniczeniach

$$\begin{cases} y_i (w^T x_i + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \end{cases} \quad (89)$$

gdzie:

ξ_i – zmienna dopełniająca, która zmniejsza szerokość aktualnego marginesu separacji,

C – parametr określający zależność między błędem testowania a szerokością marginesu separacji [78].

Problem dualny (86) rozwiązywany jest wtedy dla ograniczeń:

$$0 \leq \alpha_i \leq C, \quad \sum_{i=1}^m \alpha_i y_i = 0 \quad (90)$$

Duża wartość C oznacza, że margines separacji będzie mały a mała wartość C – duży. Niestety duży margines separacji może powodować większy błąd klasyfikacji a zbyt mały słabe własności generalizacyjne sieci. Parametr ten dobierany jest przez użytkownika w trakcie tworzenia sieci drogą eksperymentalną.

Sieć nieliniowa SVM używana jest dla przypadków, które nie są separowane liniowo. Dane transformuje się z przestrzeni oryginalnej N – wymiarowej do przestrzeni o większej liczbie wymiarów Q ($Q \geq N$), gdzie możliwa będzie klasyfikacja. Wykorzystuje się do tego nieliniową funkcję $\phi_j(x)$ dla $j = 1, 2, \dots, Q$. Problem dualny przyjmuje postać [78]:

$$\text{maksymalizuj } \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j K(x_i^T x_j) \quad (91)$$

Przy ograniczeniach jak dla sieci liniowej:

$$0 \leq \alpha_i \leq C, \quad \sum_{i=1}^m \alpha_i y_i = 0 \quad (92)$$

Funkcja jądra $K(x_i, x_j)$ z definicji jest funkcją symetryczną tzn. $K(x_i, x_j) = K(x_j, x_i)$ i określona jest jako iloczyn skalarny wektorów [78]:

$$K(x, x_j) = \varphi^T(x_i) \varphi(x) \quad (93)$$

Każda funkcja, która spełnia warunek Mercera [17], może być użyta jako funkcja jądra. W niniejszej pracy zastosowano radialną funkcję jądrową:

$$K(x, x_i) = \exp\left(-\gamma \|x - x_i\|^2\right) \quad (94)$$

Zastosowanie funkcji jądrowej powoduje, że nie musimy znać funkcji φ a wystarczy znajomość jądra, i wtedy można pracować w nowej przestrzeni. Funkcja decyzyjna ma wtedy postać:

$$f(x) = \sum_{i=1}^N \alpha_i y_i K(x_i, x) + b \quad (95)$$

Jak napisano na początku, z natury swojego działania sieci SVM dokonują podziału na dwie klasy. W przypadku problemu trzyklasowego rozważanego w niniejszej pracy wybrano podejście „jeden przeciw wszystkim”. Wymaga to utworzenia trzech sieci. Każda z sieci rozpoznaje jedną klasę np. sieć pierwsza rozpoznaje klasę pierwszą a reszta klas traktowana jest w tym przypadku jako druga klasa.

6.4.3.1. Wyniki oceny montażu przekładni zębatych stożkowych

Klasyfikacja

Wynik na poziomie 100% prawidłowego przydzielenia do odpowiednich klas dla obciążenia pierwszego osiągnięto tylko dla I wariantu metody (tab. 6.14). Przy drugim obciążeniu, pomimo jednoznacznej klasyfikacji dla zbioru walidacyjnego, przekładnia 13 została błędnie sklasyfikowana a przekładnia 12 częściowo, przy czym najgorszy wynik osiągnięto dla I wariantu metody (tab. 6.15). W ostatniej tabeli (tab. 6.16) wszystkie odmiany metody nieprawidłowo określiły przynależność przekładni kontrolnej 12.

Tabela 6.14. Wyniki klasyfikacji dla obciążenia wynoszącego 34,3% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Poprawność klasyfikacji dla: ➤ zbioru walidacyjnego	100%	100%	100%
Poprawność klasyfikacji dla przekładni kontrolnych:			
➤ numer 12	100%	53,83%	53,83%
➤ numer 13	100%	100%	100%

Tabela 6.15. Wyniki klasyfikacji dla obciążenia wynoszącego 86,8% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Poprawność klasyfikacji dla: ➤ zbioru walidacyjnego	100%	100%	100%
Poprawność klasyfikacji dla przekładni kontrolnych:			
➤ numer 12	1,53%	71,76%	74,81%
➤ numer 13	0%	0%	0%

Tabela 7.16. Wyniki klasyfikacji dla obciążenia wynoszącego 118,8% obciążenia nominalnego

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Poprawność klasyfikacji dla: ➤ zbioru walidacyjnego	100%	100%	100%
Poprawność klasyfikacji dla przekładni kontrolnych:			
➤ numer 12	0%	0%	0%
➤ numer 13	100%	100%	100%

Przewidywanie

Wysoką korelację między danymi obserwowanymi a przewidywanymi osiągnięto dla wszystkich wariantów metody przy obciążeniu pierwszym (tab. 6.17). Bardzo niski średni błąd prognozy dla obu przekładni kontrolnych uzyskano dla II i III wariantu metody. Przy drugim obciążeniu (tab. 6.18) błąd dla przekładni kontrolnej 13 jest bardzo wysoki. W ostatnim przypadku (tab. 6.19), pomimo niższej wartości współczynnika korelacji niż dla pierwszego obciążenia, uzyskano również niski błąd prognozy dla przekładni kontrolnych.

Tabela 6.17. Wyniki prognozy dla obciążenia wynoszącego 34,3% obciążenia nominalnego
(część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Współczynnik korelacji dla: ➤ zbioru walidacyjnego	0,951	0,926	0,926
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna			
odchylenie standardowe	0,447	0,466	0,466
błąd prognozy	0,0018	0,0043	0,0043
	4,24%	0,08%	0,08%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,475	0,485	0,485
odchylenie standardowe	0,0017	0,0024	0,0024
błąd prognozy	1,32%	0,76%	0,76%
Średni błąd prognozy dla 2 przekładni	2,78%	0,42%	0,42%

Tabela 6.18. Wyniki prognozy dla obciążenia wynoszącego 86,8% obciążenia nominalnego
(część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Współczynnik korelacji dla: ➤ zbioru walidacyjnego	0,951	0,757	0,670
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna			
odchylenie standardowe	0,485	0,457	0,464
błąd prognozy	0,0034	0,0025	0,0017
	4,03%	2,17%	0,65%
➤ numer 13 (0,481)			
średnia arytmetyczna	-0,356	0,340	0,347
odchylenie standardowe	0,1268	0,0275	0,0236
błąd prognozy	174,06%	29,36%	27,93%
Średni błąd prognozy dla 2 przekładni	89,05%	15,77%	14,29%

Tabela 6.19. Wyniki prognozy dla obciążenia wynoszącego 118,8% obciążenia nominalnego (część wyników pochodzi z [124])

Cecha sieci	Metoda wariant I	Metoda wariant II	Metoda wariant III
	Wartość/nazwa	Wartość/nazwa	Wartość/nazwa
Współczynnik korelacji dla: ➤ zbioru walidacyjnego	0,828	0,814	0,814
Prognoza względnej długości śladu współpracy dla przekładni kontrolnych:			
➤ numer 12 (0,467)			
średnia arytmetyczna			
odchylenie standardowe	0,472	0,475	0,475
błąd prognozy	0,0010	0,0041	0,0041
	1,08%	1,73%	1,73%
➤ numer 13 (0,481)			
średnia arytmetyczna	0,479	0,478	0,478
odchylenie standardowe	0,0019	0,0023	0,0023
błąd prognozy	0,46%	0,70%	0,70%
Średni błąd prognozy dla 2 przekładni	0,77%	1,22%	1,22%

7. PODSUMOWANIE I WNIOSKI KOŃCOWE

W monografii przedstawiono wyniki badań nad metodą szybko i obiektywnie oceniającą poprawność montażu nowych zębatach przekładni stożkowych w trakcie ich produkcji. W tym konkretnym analizowanym przypadku nie zachodzi potrzeba zmian w istniejącym procesie wytwórczym, ponieważ pomiary wykonywane są w trakcie próby stanowiskowej, mającej na celu kontrolę i dotarcie przekładni. Metoda, przedstawiona w niniejszej monografii, weryfikuje położenie kół zębatach na podstawie względnej długości śladu współpracy. Proponowany algorytm ma za zadanie, po pierwsze, klasyfikować przekładnie w trzech kategoriach – montaż bardzo dobry, dobry i niedostateczny. Taki podział zdeterminowany jest zgromadzonymi w trakcie badań przypadkami. Po drugie – przewidywać wartość względnej długości śladu współpracy, która jest interpretowana jako kryterium jakości montażu.

Na podstawie analizy procesu montażu, metod kontroli wykonania i montażu przekładni zębatach właśnie ślad współpracy wybrano jako kompleksowy wskaźnik, warunkujący o poprawnym montażu. Za sygnał diagnostyczny został wybrany sygnał drgań. Z analizy przeprowadzonej w rozdziale 2 i wniosków płynących z rozdziału 3 wynika, że metody wibroakustyczne są najlepszym rozwiązaniem przy bezdemontażowej diagnostyce przekładni zębatach.

Aby pozyskać odpowiednią bazę danych do analizy metody montażu, zostały przeprowadzone badania stanowiskowe. Należy podkreślić, że w badaniach zasadniczych pod uwagę zostało wziętych trzynaście przekładni, podczas gdy w literaturze często poddaje się analizie tylko pojedyncze egzemplarze. Następnie przeprowadzono badania wstępne symulacyjne i doświadczalne. Badania symulacyjne miały na celu określenie wpływu błędów montażowych na błąd przełożenia, który to jest powiązany z wibroaktywnością przekładni. Przeprowadzona symulacja ujawniła, że pozycja inna, niż zgodna z odległościami montażowymi kół, nie zawsze oznacza większą wartość błędu przełożenia. We wstępnych badaniach stanowiskowych sprawdzono możliwość oceny montażu, bazując na sygnale drganiowym, poddanym tylko podstawowemu przetwarzaniu i używając prostego wnioskowania. Takie podejście okazało się niewystarczające.

Opracowano więc metodę, składającą się z trzech wariantów. W pierwszym wariantcie po obliczeniu miar sygnałów następuje wybór optymalnych miar za pomocą metody filtrów. W kolejnym etapie sieci neuronowe kwalifikują przekładnie do jednej z trzech klas lub przewidują względną długość śladu. W pozostałych dwóch wariantach metody sygnał drgań w pierwszym kroku poddawany jest odszumianiu, (w wariantcie II przy wykorzystaniu WT, a trzecim WT+PCA) a pozostałe etapy są takie same jak w odmianie I. Spośród różnych typów sieci neuronowych, uwzględniając skuteczność, popularność i doświadczenia z użytkowaniem tych sieci przez autorów monografii, wybrano trzy typy: MLP, RBF i SVM. Metodę zbudowano i testowano dla trzech obciążeń.

Najlepsze wyniki wszystkie sieci osiągnęły dla pierwszego obciążenia, wynoszącego 34,3% momentu nominalnego, i dla tego przypadku dokonano porównania ich efektywności działania. Dla zadania klasyfikacji najlepsze wyniki osiągnięto dla sieci MLP i SVM, przy czym dla pierwszej sieci klasyfikację 100% uzyskano dla wszystkich wariantów metody, a dla sieci SVM tylko dla wariantu I. Dlatego za lepszą sieć należy uznać MLP. W przypadku zadania predykcji najbliższy jedności współczynnik korelacji dla zbioru walidacyjnego uzyskano dla sieci MLP. Niemniej jednak, zdaniem autorów, większe znaczenie ma tutaj średni błąd prognozy dla przekładni kontrolnych. A w tym przypadku, najlepsze wyniki osiągnięto dla sieci SVM, dla wariantu II i III metody, gdzie średni błąd prognozy wyniósł 0,42%, przy czym odchylenie standardowe dla najlepszych rezultatów obu sieci jest bardzo zbliżone. Uzyskane wyniki należy uznać za bardzo dobre zarówno dla zadania klasyfikacji, jak i przewidywania.

Z przeprowadzonych badań można wywnioskować, że możliwe jest określenie poprawności montażu przekładni stożkowych, bazując na sygnale drgań.

8. LITERATURA

- [1]. Adamczyk J., Krzyworzeka P., Łopacz H.: *Systemy synchronicznego przetwarzania sygnałów diagnostycznych*. Collegium Columbinum, Kraków 1999.
- [2]. Aminghafari M., Cheze N., Poggi J. M.: *Multivariate denoising using wavelets and principal component analysis*. Computational Statistics & Data Analysis 50/2006, s. 2381–2398.
- [3]. API Standard 677. General purpose gear units for petroleum, chemical, and gas industry services. 1997.
- [4]. Augustyniak P.: *Transformacje falkowe w zastosowaniach elektrodiagnostycznych*. Uczelniane Wydawnictwa Naukowo-Dydaktyczne AGH, Kraków 2003.
- [5]. Barszcz T., Randall R. B.: *Application of spectral kurtosis for detection of a tooth crack in the planetary gear of a wind turbine*. Mechanical Systems and Signal Processing 23/2009, s. 1352–1365.
- [6]. Bartelmus W., Zimroz R.: *Optymalny zakres częstotliwości w procedurze demodulacji amplitudy w zastosowaniu do uszkodzeń lokalnych*. Diagnostyka 37/2006, s. 141–150.
- [7]. Bartelmus W.: *Diagnostyka maszyn górniczych*. Górnictwo Odkrywkowe. Śląsk, Katowice 1998.
- [8]. Bartelmus W.: *Statistical feature estimations of the process describing object condition change for maintenance decision*. Prace Naukowe Instytutu Górnictwa, 128(36)/2009, s. 5–18.
- [9]. Bartkowiak A., Zimroz R.: *Curvilinear dimensionality reduction of data for gearbox condition monitoring*. Przegląd Elektrotechniczny, 88(10b)/2012, s. 268–271.
- [10]. Batko W., Ziółko M.: *Application of wavelet theory in technical diagnostics*. Problems of Mechanical Engineering and Robotics. Kraków: Wydział Inżynierii Mechanicznej i Robotyki AGH, 2002.
- [11]. Bendat J.S., Piersol A.G.: *Metody analizy i pomiaru sygnałów losowych*. PWN, Warszawa 1976.
- [12]. Bishop C. M.: *Neural networks for pattern recognition*. Oxford University Press, 1995.
- [13]. Boczkowski A.: *Detekcja typowych uszkodzeń skrzyń przekładniowych metodami wibroakustycznymi*. Zeszyty Naukowe Akademii Morskiej w Szczecinie, 10(82)/2006, s. 83–96.
- [14]. Boczkowski A.: *Sposób wykorzystania technik wibroakustycznych w ocenie jakości wykonania i montażu samochodowych skrzyń*

- przekładniowych*. Rozprawa doktorska, Politechnika Śląska, Zabrze 2004.
- [15]. Boczkowski A.: *Zastosowanie demodulacji amplitudowej w diagnostyce jakości wykonania skrzyń przekładniowych*. Zeszyty Naukowe Akademii Morskiej w Szczecinie, 5(77)/2005, s. 85–96.
 - [16]. Boczkowski A.: *Zastosowanie estymatorów punktowych i ich dyskrymant w ocenie poprawności wykonania i montażu samochodowych skrzyń przekładniowych*. Diagnostyka, 27/2002, s. 54–59.
 - [17]. Burges C. J. C.: *A tutorial on support vector machines for pattern recognition*. Data Mining and Knowledge Discovery, 2/1998, s. 121–167.
 - [18]. Cempel Cz., Tomaszewski F. (redakcja naukowa): *Diagnostyka Maszyn. Zasady ogólne. Przykłady zastosowań*. MCNEMT, Radom 1992.
 - [19]. Cempel Cz.: *Diagnostyka wibroakustyczna maszyn*. PWN, Warszawa 1989.
 - [20]. Cempel Cz.: *Podstawy wibroakustycznej diagnostyki maszyn*. WNT, Warszawa 1982.
 - [21]. Cempel Cz.: *Wibroakustyka stosowana*. PWN, Warszawa 1989.
 - [22]. Cholewa W., Kazimierczak J.: *Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów*. Wydawnictwo Politechniki Śląskiej, Gliwice 1995.
 - [23]. Cholewa W., Moczulski W.: *Diagnostyka techniczna maszyn. Pomiary i analiza sygnałów*. Wydawnictwo Politechniki Śląskiej, Gliwice 1993.
 - [24]. CNR-Auto. *Rysunek pomiaru luzu normalnego*. [dostęp: 5-09-2013]. Dostępny w Internecie: <http://avto-remont-volgograd.ru/manuals/outlander2007/SEARCH/2007/27/html/M127100550002800ENG.HTM>
 - [25]. Combet F., Gelman L.: *An automated methodology for performing time synchronous averaging of a gearbox signal without speed sensor*. Mechanical Systems and Signal Processing 21/2007, s. 2590–2606.
 - [26]. Combet F.: *Gear fault diagnosis and industrial applications*. Diagnostyka 61/2012, s. 9–12.
 - [27]. Crocker M.J. (redakcja naukowa): *Handbook of noise and vibration control*. Wiley 2007.
 - [28]. Czech P., Łazarz B., Wojnar G.: *Wykrywanie lokalnych uszkodzeń zębów kół przekładni z wykorzystaniem sztucznych sieci neuronowych i algorytmów genetycznych*. ITE, Katowice-Radom 2007.
 - [29]. Czech P.: *Classification of fault diagnosis in a gear wheel by used probabilistic neural network, fast fourier transform and principal component analysis*. Problemy Transportu, 2(4)/2007, s. 99–106.

- [30]. Dąbrowski Z.: *O możliwości diagnozowania przekładni zębatych metodami wibroakustycznymi*. Przegląd Mechaniczny 5–6/1996, s. 7–12.
- [31]. Decker H.J., Lewicki D. G.: *Spiral bevel pinion crack detection in a helicopter gearbox*. NASA/TM—2003-212327, 2003.
- [32]. Dietrich M. (redakcja naukowa): *Podstawy Konstrukcji Maszyn, t. 1*, WNT, Warszawa 1999.
- [33]. Dybała J., Mączak J., Radkowski S.: *Wykorzystanie sygnału wibroakustycznego w analizie ryzyka technicznego*. ITE, Warszawa-Radom 2006.
- [34]. Dybała J., Radkowski S.: *Wykorzystanie sieci neuronowych cp w wibroakustycznej diagnostyce uszkodzeń przekładni zębatej*. Diagnostyka 31/2004, s. 59–66.
- [35]. Farago F. T., Curtis M. A.: *Handbook of dimensional measurement*. Industrial Press Inc. New York 1994, s. 479–508.
- [36]. Frazer R. C.: *Measurement uncertainty in gear metrology*. Rozprawa doktorska, School of Mechanical and Systems Engineering, Newcastle University, UK 2007.
- [37]. Gajewski J., Jedliński Ł., Jonak J.: *Classification of wear level of mining tools with the use of fuzzy neural network*. Tunnelling and Underground Space Technology, 2013, vol. 35, s. 30–36.
- [38]. Gear Technology.: *CMM Gear Inspection*. Gear Technology 30(1)/2013, s. 11–13. [dostęp: 20-08-2013]. Dostępny w Internecie: <http://www.geartechnology.com/>
- [39]. Gleason. *Informacje o produktach*. [dostęp: 23-08-2013]. Dostępny w Internecie: <http://www.gleason.com/>.
- [40]. Goch G.: *Gear Metrology*. CIRP Annals – Manufacturing Technology, 52(2)/2003, s. 659–695.
- [41]. Halim E. B., Shoukat Choudhury M. A. A., Shah S. L., Zuo M. J.: *Time domain averaging across all scales: A novel method for detection of gearbox faults*. Mechanical Systems and Signal Processing 22/2008, s. 261–278.
- [42]. Hebda M., Niziński S., Pelc H.: *Podstawy diagnostyki pojazdów mechanicznych*. WKŁ, Warszawa 1984.
- [43]. Hexagon Metrology. *Informacje o produktach*. [dostęp: 22-08-2013]. Dostępny w Internecie: <http://www.leitz-metrology.com/>.
- [44]. Jasiński M., Mączak J., Radkowski S.: *Zastosowanie filtracji trzecjowej sygnału wibroakustycznego w wykrywaniu błędów montażu przekładni zębatej*. Przegląd Mechaniczny, 11-12/1998, s. 20–26.

- [45]. Jasiński M., Radkowski S.: *Zastosowanie składowych głównych w diagnozowaniu maszyn*. Diagnostyka 30/2004, s. 207–210.
- [46]. Jaśkiewicz Z.: *Przekładnie stożkowe i hipoidalne*. WKŁ 1978.
- [47]. Jedliński Ł., Jonak J.: *Optimum choice of signals' features used in toothed gears' diagnosis*. Diagnostyka 55/2010, s. 9–12.
- [48]. Jedliński Ł., Jonak J.: *Quality evaluation of the bevel gear assembly based on analysis of the vibration signal*. Diagnostyka 53/2010, s. 23–26.
- [49]. Jedliński Ł., Jonak J.: *Toothed gear transmission diagnosis based on optimal features of vibration signal*. Zeszyty Naukowe Akademii Morskiej w Szczecinie, 26(98)/2011, s. 33–37.
- [50]. Jedliński Ł., Kisiel J., Jonak J.: *Diagnosing the condition of gear transmission on the basis of periodic and residual components of the signal spectrum*. Diagnostyka 49/2009, s. 57–61.
- [51]. Jedliński Ł.: *Multi-channel registered data denoising using wavelet transform*. Eksploatacja i Niezawodność, 14/2012, s. 59–63.
- [52]. Jonak J., Jedliński Ł., Gajewski J.: *Analysis of the mining torque signal with continuous wavelet transform*. Mechanics and Control, vol. 29, nr 4/2010 s. 169–173.
- [53]. Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W. (redakcja naukowa): *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*. WNT, Warszawa 2002.
- [54]. Koronacki J., Mielniczuk J.: *Statystyka dla studentów kierunków technicznych i przyrodniczych*. WNT, Warszawa 2006.
- [55]. Korzyński M.: *Metodyka eksperymentu. Planowanie, realizacja i statystyczne opracowanie wyników eksperymentów technicznych*. WNT, Warszawa 2006.
- [56]. Kozik J.: *Diagnostyka maszyny synchronicznej z zastosowaniem metod sztucznej inteligencji*. Rozprawa doktorska, AGH, Kraków 2011.
- [57]. Kuryjański R., Skawiński P.: *Przekładnie stożkowe o kołowo-łukowej linii zęba*. Mechanik, 8–9/2002, s. 593–596.
- [58]. Lei Y., Zuo M.J., He Z., Zi Y.: *A multidimensional hybrid intelligent method for gear fault diagnosis*. Expert Systems with Applications 37/2010, s. 1419–1430.
- [59]. Lei Y., Zuo M.J.: *Gear crack level identification based on weighted K nearest neighbor classification algorithm*. Mechanical Systems and Signal Processing 23/2009, s. 1535–1547.
- [60]. Li C. J.: *Gear diagnostics*. Encyclopedia of Vibration, 2001, s. 597–603.
- [61]. Li C.J., Limmer J.D.: *Model-based condition index for tracking gear wear and fatigue damage*. Wear 241/2000, s. 26–32.

- [62]. Lindstedt P.: *Praktyczna diagnostyka maszyn i jej teoretyczne podstawy*. Wydawnictwo Naukowe Akson, Warszawa 2002.
- [63]. Litvin F. L., Fuentes A., Hayasaka K.: *Design, manufacture, stress analysis, and experimental tests of low-noise high endurance spiral bevel gears*. Mechanism and Machine Theory, 41/2006, s. 83–118.
- [64]. Lyons R. G.: *Wprowadzenie do cyfrowego przetwarzania sygnałów*. WKŁ, Warszawa 2006.
- [65]. Łączkowski R.: *Wibroakustyka maszyn i urządzeń*. WNT, Warszawa 1983.
- [66]. Madej H., Czech P., Konieczny Ł.: *Wykorzystanie dyskryminant bezwymiarowych w diagnostyce przekładni zębatych*. Diagnostyka 28/2003, s. 17–22.
- [67]. Mallat, S.G., 1989. *A theory for multiresolution signal decomposition: the wavelet representation*. IEEE Transactions on Pattern Analysis and Machine Intelligence 11/7, s. 674–93.
- [68]. Marciniak A.: *Analiza ząbkowania i śladu współpracy przekładni stożkowych o kołowo-łukowej linii zęba*. Zeszyty Naukowe Politechniki Rzeszowskiej nr 188, Mechanika z. 57, Koła zębate KZ, OWPRz, 2001, s. 165–175.
- [69]. Marsh S.: *How to design and install bevel gears for optimum performance: lessons learned*. Gear Technology (30)4/2013, s. 60–69.
- [70]. Mączak J.: *Wykorzystanie zjawiska modulacji sygnału wibroakustycznego w diagnozowaniu przekładni o zębach śrubowych*. Rozprawa doktorska, Politechnika Warszawska 1998.
- [71]. Micro-Epsilon. *Informacje o produktach*. [dostęp: 24-08-2013]. Dostępny w Internecie: www.micro-epsilon.com/index.html.
- [72]. Miller S.: *Teoria maszyn i mechanizmów. Analiza układów kinematycznych*. Oficyna Wydawnicza PW, 1996.
- [73]. Müller L.: *Przekładnie zębate. Projektowanie*. WNT, Warszawa 1996.
- [74]. Niziński S., Michalski R.: *Diagnostyka obiektów technicznych*. Biblioteka Problemów Eksploatacji. ITE, Radom 2002.
- [75]. Ochęduszek K.: *Koła zębate, Sprawdzanie*, t. 3. WNT, Warszawa 1970.
- [76]. Ochęduszek K.: *Koła zębate, Wykonanie i montaż*, t. 2. WNT, Warszawa 1976.
- [77]. Osowski S., Cichocki A., Siwek K.: *Matlab w zastosowaniu do obliczeń obwodowych i przetwarzania sygnałów*. Oficyna Wydawnicza PW, Warszawa 2006.
- [78]. Osowski S.: *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza PW, Warszawa 2006.

- [79]. Pawłow B. W.: *Badania diagnostyczne w technice*. WNT, Warszawa 1967.
- [80]. Pawłow B. W.: *Diagnostyka niedomagań maszyn*. PWRiL, Warszawa 1975.
- [81]. PN-80/M-88522/03. Przekładnie zębate stożkowe i hipoidalne. Dokładność wykonania. Nazwy, określenia i wartości odchyłek. 1980.
- [82]. PN-ISO 10816-1. Drgania mechaniczne. Ocena drgań maszyny na podstawie pomiarów na częściach niewirujących. Wytyczne ogólne. 1998.
- [83]. PN-ISO 8579-2. Przepisy odbioru przekładni zębatych. Określanie drgań mechanicznych przekładni zębatych podczas badań odbiorczych. 1996.
- [84]. Randall R. B.: *Vibration-based condition monitoring: industrial, aerospace and automotive applications*. Wiley, New Delhi 2011.
- [85]. Rousseeuw P.: *Least median of squares regression*. Journal of the American Statistical Association 79/1984, s. 871–880.
- [86]. Sałaciński T.: *Podstawy kształtowania i współpracy powierzchni zębów przekładni zębatych stożkowych*. Prace Naukowe Politechniki Warszawskiej, Mechanika z. 200. OWPW, Warszawa 2003.
- [87]. Samanta B. *Gear fault detection using artificial neural networks and support vector machines with genetic algorithms*. Mechanical Systems and Signal Processing 18/2004, s. 625–644.
- [88]. Samuel P. D., Darryll J. P.: *A review of vibration-based techniques for helicopter transmission diagnostics*. Journal of Sound and Vibration 282/2005, s. 475–508.
- [89]. Scott A. I.: *Denoising by wavelet thresholding using multivariate minimum distance partial density estimation*. Rozprawa doktorska, Rice University, Texas 2006.
- [90]. Sheveleva G. I., Volkov A. E., Medvedev V. I.: *Algorithms for analysis of meshing and contact of spiral bevel gears*. Mechanism and Machine Theory, 42/2007, s. 198–215.
- [91]. Sick B.: *On-line and indirect toolwear monitoring in turning with artificial neural networks: a review of more than a decade of research*. Mechanical Systems and Signal Processing 16(4)/2002, s. 487–546.
- [92]. Sidahmed M., Dalpiaz Q.: *Signal generation models for diagnostics*. Encyclopedia of Vibration, 2001, s. 1184–1193.
- [93]. Singh R.: *Gear Noise: Anatomy, Prediction and Solutions*. Plenary Lecture, Paper # 666, INTER-NOISE 2009, Ottawa, Canada, August 23–26, 2009.
- [94]. Skawiński P., Siemiński P.: *Badanie śladu współpracy i generowanie wykresów ruchowych spiralnych przekładni stożkowych w środowisku*

- programów CAD. Zeszyty Naukowe Politechniki Rzeszowskiej nr 259, Mechanika z. 75, Koła Zębate KZ, OWPRz, Bezmiechowa 2008, s. 188–197.
- [95]. Skawiński P.: *Integracja projektowania i wytwarzania kół zębatych stożkowych o zębach kołowo-łukowych*. Prace Naukowe, Mechanika z. 236, OWPW, Warszawa 2010.
- [96]. Skoć A.: *Prognozowanie własności dynamicznych przekładni zębatych stożkowych*. Wydawnictwo Politechniki Śląskiej, Gliwice 2007.
- [97]. Sobolak M.: *Zastosowanie systemu CAD do procedury V-H check dla kół przekładni stożkowej*. Zeszyty Naukowe Politechniki Rzeszowskiej nr 232, Mechanika z. 69, Koła zębate KZ, OWPRz, Rzeszów 2006, s. 215–220.
- [98]. Sokołowski A.: *Wybrane zagadnienia projektowania układów diagnostycznych obrabiarki i procesu skrawania*. Wydawnictwo Politechniki Śląskiej, Gliwice 2003.
- [99]. Sowa J., Marciniec A.: *Konstrukcja reduktorów napędu głównego śmigłowców produkowanych w Europie Wschodniej*. Zeszyty Naukowe Politechniki Rzeszowskiej nr 259, Mechanika z. 75, Koła Zębate KZ, OWPRz, Bezmiechowa 2008, s. 211–223.
- [100]. Stateczny A., Praczyk T.: *Sztuczne sieci neuronowe w rozpoznawaniu obiektów morskich*. Gdańskie Towarzystwo Naukowe, Gdynia 2002.
- [101]. StatSoft (2006). *Elektroniczny Podręcznik Statystyki PL*, Kraków, WEB: <http://www.statsoft.pl/textbook/stathome.html>.
- [102]. Szabelski K., Jancelewicz B., Łucjanek W. (redakcja naukowa): *Wstęp do konstrukcji śmigłowców*. WKŁ, Warszawa 1995.
- [103]. Townsend D.P., Zakrajsek J.J.: *Evaluation of a vibration diagnostic system for the detection of spiral bevel gear pitting failures*. NASA Technical Memorandum 107228, 1996.
- [104]. Večeř P., Kreidl M., Šmíd R.: *Condition indicators for gearbox condition monitoring systems*. Acta Polytechnica, Vol. 45, No. 6/2005.
- [105]. Vision Systems Design. Publikacja pt. *3D mapping system used to inspect gears for u.s. car maker*. [dostęp: 24-08-2013]. Dostępny w Internecie: <http://www.vision-systems.com/articles/2013/06/3d-mapping-system-used-to-inspect-gears-for-u-s--car-maker.html>.
- [106]. Wawrzyniak K.: *Analiza akustycznych obrazów falowych w aspekcie zwiększenia informacji o parametrach sprężystych i zbiornikowych skał*. Rozprawa doktorska, Akademia Górniczo-Hutnicza, Kraków 2007.
- [107]. Wenyi L., Zhenfeng W., Jiguang H., Guangfeng W.: *Wind turbine fault diagnosis method based on diagonal spectrum and clustering binary tree SVM*. Renewable Energy 50/2013, s. 1–6.

- [108]. Widodo A, Yang Bo-Suk: *Support vector machine in machine condition monitoring and fault diagnosis*. Mechanical Systems and Signal Processing 21/2007, s. 2560–2574.
- [109]. Wilk A., Łazarz B., Madej H.: *Metody przetwarzania sygnałów drganiowych w diagnozowaniu przekładni zębatych*. Diagnostyka 30/2004, s.183–186.
- [110]. Wilk A., Madej H., Łazarz B. (redakcja naukowa): *Wibrokatywność przekładni zębatych. Wpływ cech konstrukcyjnych i zużycia elementów na wibroaktywność układów napędowych z przekładniami zębatymi*. ITE, Katowice – Radom 2009.
- [111]. Wojtkiewicz A. (redakcja naukowa): *Cyfrowe przetwarzanie sygnałów. Ćwiczenia laboratoryjne*. Oficyna Wydawnicza PL, Warszawa 2000.
- [112]. Worden K., Staszewski W. J., Hensman J. J.: *Natural computing for mechanical systems research: a tutorial overview*. Mechanical Systems and Signal Processing, 25/2011, s. 4–111.
- [113]. Wójcik Z.: *Przekładnie stożkowe. Konstrukcja i technologia*. WNT, Warszawa 1984.
- [114]. Wu J. D., Kuo J. M.: *An automotive generator fault diagnosis system using discrete wavelet transform and artificial neural network*. Expert Systems with Applications, 36/2009, s. 9776–9783.
- [115]. Yang B.S., Han T., An J.L.: *ART–KOHONEN neural network for fault diagnosis of rotating machinery*. Mechanical Systems and Signal Processing 18/2004, s. 645–657.
- [116]. Zakrajsek J.J., Handschuh F. F., Decker H.J.: *Application of fault detection techniques to spiral bevel gear fatigue data*. NASA Technical Memorandum 106467, 1994.
- [117]. Zakrajsek J.J., Townsend D.P., Decker H.J.: *An analysis of gear fault detection methods as applied to pitting fatigue failure data*. Technical Report NASA TM-105950, 1993.
- [118]. Zemła A., Wolter M.: *Using Support vector machine algorithm for multivariate data analysis in HEP experiments*. XXII-th International Symposium on Nuclear Electronics and Computing. Bulgaria, Varna 2009.
- [119]. Zieliński T. P.: *Cyfrowe przetwarzanie sygnałów. Od teorii do zastosowań*. WKŁ, Warszawa 2007.
- [120]. Zimroz R., Bartkowiak A.: *Two simple multivariate procedures for monitoring planetary gearboxes in non-stationary operating conditions*. Mechanical Systems and Signal Processing 38/2013, s. 237–247.

- [121]. Zimroz R.: *Metody adaptacyjne w diagnostyce układów napędowych maszyn górniczych*. Oficyna Wydawnicza Politechniki Warszawskiej, Wrocław 2010.
- [122]. Żółtowski B., Cempel C. (redakcja naukowa): *Inżynieria diagnostyki maszyn*. ITE, Warszawa, Bydgoszcz, Radom 2004.
- [123]. Żółtowski B.: *Podstawy diagnozowania maszyn*. Wydawnictwa Uczelniane UTP, Bydgoszcz 2011.
- [124]. Jedliński Ł., Jonak J.: *A disassembly-free method for evaluation of spiral bevel gear assembly*. Mechanical Systems and Signal Processing 88/2017, s. 399–412.