

Monitorowanie stanu łożyska na podstawie transformacji Hilberta-Huanga, maszyny wektorów nośnych i regresji

By kama3 kama3

cze 8, 2025

Monitorowanie stanu łożyska na podstawie transformacji Hilberta-Huanga, maszyny wektorów nośnych i regresji A. Soualhi, K. Medjaher i N. Zerhouni Streszczenie — wykrywanie, diagnostyka i prognozowanie degradacji łożysk odgrywają kluczową rolę w zwiększaniu niezawodności i bezpieczeństwa maszyn elektrycznych, zwłaszcza w kluczowych sektorach przemysłu. W niniejszym dokumencie przedstawiono nowe podejście łączące transformację Hilberta-Huanga, maszynę wektorów nośnych i regresję wektorów nośnych w celu monitorowania łożysk kulkowych. Proponowane podejście wykorzystuje transformację Hilberta-Huanga do wyodrębniania nowych wskaźników stanu z sygnałów drgań stacjonarnych/niestacjonarnych, które mogą wykryć degradację krytycznych elementów łożysk. Stany degradacji są wykrywane przez nadzorowaną technikę klasyfikacji zwaną maszyną wektorów nośnych, a diagnostyka usterek jest przeprowadzana poprzez analizę wyodrębnionych wskaźników stanu. Oszacowanie pozostałego okresu użytkowania uzyskuje się poprzez jednoetapową prognozę szeregów czasowych opartą na regresji wektorów nośnych. Zestaw danych eksperymentalnych zebranych z zdegradowanych łożysk jest wykorzystywany do walidacji proponowanego podejścia. Wyniki eksperymentów pokazują, że wykorzystanie transformacji Hilberta-Huanga, maszyny wektorów nośnych i regresji wektorów nośnych jest odpowiednią strategią poprawy wykrywania, diagnostyki i prognozy degradacji łożysk. Awarie łożysk odpowiadają za około 42% zidentyfikowanych usterek, zwarcia międzyzwojowe w uzwojeniach stojana stanowią około 31%, a złamane pręty wirnika i uszkodzenia pierścienia końcowego stanowią około 9%. Z tych wyników wynika, że większość awarii w tych maszynach jest spowodowana defektami łożysk. Uszkodzenia łożysk mają wiele przyczyn, takich jak zanieczyszczenie środka smarnego, nadmierne obciążenie [3] lub przepływ prądów upływowych indukowanych przez falowniki PWM (Pulse Wide Modulation) [4], [5]. Dlatego też, najlepszym pomysłem na rozwiązanie tych problemów jest przyjęcie nowego, opartego na danych podejścia Prognostic and Health Management (PHM) w celu poprawy monitorowania stanu łożysk [6]-[8]. Podejście oparte na danych nie jest jedynym sposobem, aby to zrobić, istnieją dwa inne podejścia, a mianowicie: podejścia oparte na modelach i hybrydowe [9]-[14]. Pierwsze podejście wykorzystuje modele matematyczne do przedstawienia dynamicznego zachowania łożysk i zjawisk degradacji. To podejście jest stosowane, gdy dokładny model matematyczny można opracować na podstawie awarii łożyska lub trybów degradacji. Jednak łożysko jest złożonym systemem, a mechanizmy degradacji są na ogół stochastyczne, więc trudno je przedstawić za pomocą modeli matematycznych. W związku z tym zastosowanie tego podejścia może być trudne. Drugie podejście opiera się na połączeniu podejścia opartego na danych i opartego na modelach. Jeśli chodzi o łożyska i wiedząc o trudnościach w analitycznym modelowaniu ich degradacji, podejście oparte na danych wydaje się być kompromisem umożliwiającym niezawodne wykrywanie usterek, diagnostykę i prognozowanie. Podejście oparte na danych wykorzystuje zmierzone dane (tj. sygnały drgań i akustyczne, temperaturę, ciśnienie, zanieczyszczenia oleju, prądy, napięcia itp.) wyodrębnione z czujników jako źródło lepszego zrozumienia zjawisk degradacji łożysk [15]-[18]. Zaletą podejścia opartego na danych jest to, że użytkownik nie musi mieć żadnych hipotez dotyczących podstawowego modelu fizycznego. W tym artykule proponowane podejście przechodzi przez trzy kroki. - Pierwszy krok polega na ulepszeniu wykrywania i diagnostyki degradacji łożysk poprzez wprowadzenie nowych wskaźników stanu, które mogą wykrywać i diagnozować krytyczne elementy łożysk (bieżnia wewnętrzna, bieżnia zewnętrzna, kulki). Wskaźniki te są wyodrębniane z danych dotyczących drgań przy użyciu metody przetwarzania sygnałów zwanej transformacją Hilberta-Huanga (HHT) [19], [20]. W literaturze istnieją trzy metody przetwarzania sygnałów: analiza czasowa, analiza częstotliwości i analiza czasowo-częstotliwościowa. Analiza czasowa jest historycznie najstarszą metodą. Założeniem tej metody jest to, że każde wystąpienie usterek można monitorować za pomocą statystycznych wskaźników stanu, takich jak

średnia kwadratowa (RMS), wartość szczytowa i kurtoza. Jednak te wskaźniki, nawet jeśli są dobrze przystosowane do monitorowania online, nie identyfikują wady odpowiedzialnej za degradację. Co więcej, wskaźniki czasowe często generują „fałszywe alarmy”, gdy sygnały nie są gaussowskie. Analiza częstotliwości zapewnia widmo częstotliwości dla każdej próbki czasu, wykonując wyprowadzenie charakterystycznych częstotliwości usterek łożysk. Jednak skuteczność analizy częstotliwości, w przypadku łożysk kulkowych, w dużym stopniu zależy od warunków pracy: stacjonarnych lub niestacjonarnych. W rzeczywistości zarejestrowane drgania Monitorowanie stanu łożyska oparte na przekształceniu Hilberta-Huanga, maszynie wektorów nośnych i regresji Sygnał jest wynikiem mieszanki różnych źródeł odpowiadających środowisku zewnętrznemu, jak również niestacjonarnych sygnałów indukowanych przez wewnętrzne komponenty łożyska kulkowego. W literaturze istnieje kilka technik analizy czasowo-częstotliwościowej stosowanych do monitorowania łożysk: krótkotrwała transformata Fouriera (STFT) [21], rozkład Wignera-Ville'a (WVD) [22] i analiza falkowa (WA) [23]. Jednak w STFT rozdzielczości w czasie i częstotliwości są zawsze stałe, a WVD może prowadzić do pojawienia się terminów krzyżowych, co z kolei prowadzi do błędnej interpretacji sygnału. Efektywność analizy falkowej w dużym stopniu zależy od jakości analizowanego sygnału. W przypadku łożysk kulkowych odpryskiwanie powoduje wstrząsy i rezonans łożyska. Zjawisko to występuje przy wysokich częstotliwościach przez szczyty, które stopniowo rosną w miarę pogarszania się stanu łożyska. To powoduje dławienie niskich częstotliwości i uniemożliwia wczesne wykrywanie usterek. W tym przypadku chodzi o oddzielenie wkładu różnych źródeł drgań za pomocą transformacji Hilberta-Huanga. Ostatnie prace badawcze wykorzystujące HHT są opisane w literaturze. Cytujemy na przykład prace opublikowane w [24] i [25]. W [24] autorzy stosują rozkład trybu empirycznego zespołu (EEMD) i HHT do diagnostyki uszkodzeń łożysk. EEMD wyodrębnia z oryginalnego sygnału drgań nowy sygnał złożony z zestawu wybranych funkcji trybu wewnętrznego (IMF) poprzez oszacowanie chwilowej amplitudy i chwilowej częstotliwości w dowolnym momencie. Dlatego uszkodzenie łożyska można rozpoznać, używając widma transformacji Hilberta-Huanga. W [25] autorzy stosują HHT i EEMD do obliczenia modulacji amplitudy różnych IMF. Umożliwia to wyodrębnienie wskaźników zdrowia z informacji zawartych w IMF. Podobnie jak [24], [25], proponowana przez nas metoda ekstrakcji cech rozkłada każdy sygnał drgań na zestaw IMF. Każdy IMF znajduje się w określonym paśmie częstotliwości. Różnica między proponowaną metodą a tymi cytowanymi w badanych pracach polega na ekstrakcji wskaźników zdrowia. Ta ekstrakcja odbywa się poprzez obliczenie gęstości widmowej Hilberta charakterystycznych częstotliwości uszkodzeń łożysk w dowolnym momencie w każdym IMF i wybranie tej(-ych), która(-e) maksymalizuje(-ą) tę ilość widmową. Wybrane IMF umożliwiają wyodrębnienie wskaźników zdrowia poprzez obliczenie widma brzegowego Hilberta. Wskaźniki te są zatem w stanie zidentyfikować zdegradowany komponent i oszacować poziom degradacji. - Drugi krok polega na tym, jak wykorzystać wyodrębnione wskaźniki zdrowia do wykrywania usterek i diagnostyki. Istnieją dwie metody szacowania degradacji łożysk. Pierwsza metoda łączy wszystkie wskaźniki stanu łożysk w jeden wskaźnik. Uzyskuje się to, stosując dobrze ugruntowane techniki liniowej/nieliniowej redukcji wymiarowości (cechy), takie jak analiza głównych składowych i ISOMAP [26]. Jednak redukcja cech oznacza utratę informacji, co może mieć wpływ na monitorowanie łożysk. Nie jest to wada, ale warunek uzyskania jednego wskaźnika stanu degradacji. Druga metoda proponuje połączenie wskaźników stanu w celu skonstruowania przestrzeni reprezentacyjnej. Przestrzeń ta umożliwia identyfikację podprzestrzeni, zwanych „klasami”, które grupują podobne miary reprezentujące różne stany degradacji łożysk [27], [28]. Rozpoznawanie wzorców (PR) jest dobrze znaną techniką klasyfikowania nowych miar w tych klasach. Klasyfikacja ta jest uzyskiwana przy użyciu nadzorowanych technik klasyfikacji. W literaturze istnieje kilka technik nadzorowanej klasyfikacji, tj. statystyki bayesowskie, estymatory jądra, K-najbliższych sąsiadów i lasy losowe [29]-[31]. Jednak bardziej zaawansowane są sztuczne sieci neuronowe i maszyna wektorów nośnych (SVM) [32], [33]. Podczas gdy sieci neuronowe są ostatecznym systemem „czarnej skrzynki” następującym po heurystycznym rozwoju z rozległymi eksperymentami poprzedzającymi teorię, rozwój SVM wymagał najpierw solidnej teorii, następnie wdrożenia i eksperymentów. SVM to nowa, obiecująca nieliniowa, nieparametryczna technika klasyfikacji, która już wykazała dobre wyniki w diagnostyce medycznej, optycznym rozpoznawaniu znaków, prognozowaniu

obciążenia elektrycznego i innych dziedzinach. - Trzeci krok polega na oszacowaniu pozostałego okresu użytkowania (RUL) łożysk przy użyciu prognozowania szeregów czasowych. Szereg czasowy to sekwencja obserwacji uzyskanych w kolejnych odstępach czasu. Tak więc typowe podejście do oszacowania RUL polega na nauczaniu się tego szeregu czasowego w celu prognozowania jego ewolucji w przyszłości. Odbywa się to za pomocą modelu prognozowania zwanego Regresją wektorów wsparcia (SVR). SVR to wersja SVM do regresji zaproponowana przez Vapnika, Stevena Golowicha i Alexa Smolę [34]. Została ona pomyślnie zastosowana w szerokim zakresie problemów prognozowania, szczególnie w maszynach obrotowych

[Read more](#)