

Prognozy usterek dla predykcyjnej konserwacji turbin wiatrowych: stan wiedzy

By kama3 kama3
cze 11, 2025

dostępność przy jednoczesnym zmniejszeniu nieplanowanych usterek i kosztów konserwacji systemów, takich jak WT.

Monitorowanie stanu WT odbywa się poprzez monitorowanie wydajności WT (np. krzywa mocy)[10] lub monitorowanie stanu componentów, w szczególności krytycznych komponentów, takich jak maszyny wirujące (np. generator).

Prognozowanie usterek jest ważnym krokiem konserwacji predykcyjnej. Można je zdefiniować jako przewidywanie, kiedy awaria może nastąpić lub oszacowanie pozostałego okresu użytkowania (RUL), który jest czasem między wykryciem degradacji a progiem awarii.

Jest to technika online, która może dostarczyć cennych informacji na potrzeby działań proaktywnych, umożliwiających łagodzenie skutków awarii i/lub planowanie kroków konserwacji.

Przewidywanie RUL krytycznych komponentów jest bardzo trudnym zadaniem ze względu na szum czujnika, złożoność systemu i niepewność przewidywania spowodowaną przełączaniem między warunkami pracy a zmiennością środowiska (np. prędkość i kierunek wiatru).

Rys. 1: Ogólne podejście do prognozowania.

Ogólne podejście do prognozowania przedstawiono na rys. 1. Wskazuje ono trzy główne kroki prognozowania:

konstrukcja wskaźnika zdrowia (HI),

wykrywanie degradacji i

szacowanie RUL.

Najpierw HI jest konstruowany poprzez przetwarzanie danych monitorujących w celu monitorowania ewolucji wydajności systemu w czasie. Drugim krokiem jest wykrywanie degradacji wyzwalane, gdy tylko HI spadnie poniżej wstępnie zdefiniowanego progu. Trzeci krok ma na celu przewidywanie ewolucji degradacji i oszacowanie czasu, w którym system spadnie poniżej progu awarii.

Konstrukcja wskaźnika zdrowia

Konstrukcja wskaźnika zdrowia (HI) jest głównym krokiem w osiąganiu prognostyki.

Reprezentuje on ewolucję w czasie wydajności systemu. Gdy ta ewolucja maleje, wskazuje to na odchylenie od normalnych lub nominalnych warunków pracy

w kierunku awarii. Techniki dryfu koncepcji mogą być używane do monitorowania wydajności systemów poprzez uczenie się wzorców ze strumieni danych zbieranych przez czujniki [20], gdzie nowa klasa jest wykrywana, jeśli nastąpi spadek wydajności systemu

Prognostyka usterek dla predykcyjnej konserwacji turbin wiatrowych 3

według jej wartości nominalnej. HI można sklasyfikować w dwóch kategoriach: wskaźniki zdrowia fizycznego i wirtualne wskaźniki zdrowia, których nie można interpretować w sensie fizycznym. Można je również sklasyfikować do HI na podstawie pojedynczej cechy, takiej jak wykorzystanie surowych danych zebranych z

czujników, cech opartych na resztkach, domeny czasu lub cechy czasowo-częstotliwościowej wyodrębnionej z danych zmierzonych przez czujniki monitorujące. Drugi rodzaj HI opiera się na fuzji wielu cech, które mogą lepiej reprezentować stan systemu.

HI oparty na pojedynczej cesze opiera się na pojedynczej wyodrębnionej cesze, która może być bardziej interpretowalna. Większość prac prognostycznych dla turbin wiatrowych koncentruje się na monitorowaniu stanu maszyny wirującej WT (np. wału wolnoobrotowego i szybkoobrotowego, skrzyni biegów, generatora) ze względu na jej krytyczność. Monitorowanie stanu takich systemów jest osiąganę za pomocą sygnału wibracji, emisji akustycznej, analizy oleju lub analizy sygnału prądu.

W przypadku złożonych degradacji często trudno jest znaleźć jedną cechę wrażliwą na te degradacje. Dlatego nie jest wykonalne skonstruowanie HI zdolnego do śledzenia ewolucji degradacji w czasie i umożliwiającego wiarygodną estymację RUL. Aby rozwiązać ten problem, rozwiązaniem jest połączenie kilku cech w celu wykorzystania ich komplementarności. Jednak takie połączenie pociąga za sobą utratę znaczenia fizycznego (np. redukcję wymiarów lub odległość między klasami w przestrzeni cech). Ta strata prowadzi do braku możliwości interpretacji HI, więc stanowi ona wirtualny opis kondycji wydajności systemu.

W literaturze zaproponowano kilka metod konstrukcji HI opartych na jednej i wielu cechach, które podsumowano w tabeli. Metody konstrukcji wskaźników zdrowia

- Surowy sygnał i resztki
- Cechy domeny czasu
- Cechy czasowo-częstotliwościowe
- Wymiar redukcja
- Odległość między klasami

Wykrywanie degradacji na podstawie podziału etapów zdrowia

Obliczony HI dostarcza informacji o stanie systemu (stan i wydajność). Gdy wystąpiła degradacja (odchylenie od stanu normalnego lub

nominalnej wydajności), HI przedstawia rosnący lub malejący trend. Następnie można uruchomić moduł prognostyczny, ponieważ przewidywanie RUL, gdy nie wystąpiła żadna usterka, jest niepotrzebne. Degradację można wykryć, dzieląc HI na dwa lub

wiele etapów, używając progu zgodnie z trendem degradacji. Podział etapu zdrowia za pomocą progu jest szeroko stosowany w literaturze do tego zadania, niektóre prace stosowały techniki klasyfikacji, gdy dostępne są wystarczające dane dotyczące degradacji,

aby oszacować granicę między warunkami nominalnymi i zdegradowanymi (patrz Tabela. 2)

Metody wykrywania degradacji

- Próg
- Klasyfikacja

Celem tego podziału jest 1) zidentyfikowanie etapów, na których proces degradacji jest aktywny i 2) oddzielenie postępu lub ewolucji degradacji w czasie zgodnie z jej dynamiką (szybka, wolna, malejąca lub samonaprawiająca się, rosnąca i stabilna itd.). Podział ten pozwala na poprawę niezawodności wykrywania degradacji i szacowania RUL.

4 Prognozowanie usterek (szacowanie RUL)

Prognozowanie ma na celu oszacowanie pozostałego okresu użytkowania komponentu przy użyciu zbudowanego HI. Oszacowanie RUL rozpoczyna się po wykryciu degradacji (odchylenia od nominalnej wydajności). Zasadniczo RUL jest szacowane na podstawie zastosowania jednego z dwóch głównych podejść: podejść opartych na doświadczeniu i podejść modelowania degradacji (patrz rys. 2). Prognozowanie oparte na doświadczeniu jest osiągnięte przez stosowanie podejść opartych na niezawodności lub podobieństwie. Modelowanie degradacji można osiągnąć, stosując modele fizyczne lub podejścia oparte na danych.

4.1 Prognozowanie oparte na doświadczeniu

Metody prognozowania oparte na doświadczeniu opierają się na wykorzystaniu zestawów danych zwrotnych z konserwacji lub

inspekcji zebranych w ciągu znacznego okresu czasu.

Reprezentują one warunki operacyjne podczas całego procesu degradacji aż do awarii. Ogólnie rzecz biorąc, można je podzielić na podejście oparte na niezawodności i podobieństwie.

Podejścia oparte na modelowaniu degradacji

Ta kategoria podejść ma na celu przewidywanie ewolucji degradacji w czasie, aby oszacować awarię systemu (koniec okresu eksploatacji). Następnie RUL jest obliczany jako czas od wykrycia degradacji do awarii.

Podejścia oparte na modelu wykorzystują relacje fizyczne i matematyczne w celu modelowania trendu degradacji. Metody te są zwykle stosowane na poziomie komponentów i dotyczą zjawisk zużycia, pęknięcia i korozji.

Prawo Parisa [16] jest najczęściej stosowanym modelem fizycznym do przewidywania zużycia łożysk tocznych.

Podejścia oparte na danych przekształcają dane monitorujące zebrane z czujników w istotne informacje o zachowaniu i dynamice systemu, głównie stosowane metody to narzędzia statystyczne i sztucznej inteligencji (AI).

Techniki statystyczne szacują RUL systemów na podstawie wiedzy empirycznej, gdzie techniki sztucznej inteligencji opierają się na dwóch fazach: fazie uczenia się offline i fazie testowania online. Model wykorzystuje bazę danych do trenowania parametrów w fazie offline, po czym faza online szacuje bieżący stan zdrowia systemu i przewiduje jego przyszły stan (ewolucję) w czasie. Te metody są coraz częściej stosowane ze względu na ich zdolność do znajdowania relacji między danymi poprzez trenowanie modelu przy użyciu zestawów danych. Metody modelowania degradacji stosowane w literaturze podsumowano w Tabeli

4. Podejścia do modelowania degradacji wykorzystują dane z monitorowania online w celu obserwacji bieżącego stanu zdrowia systemu.

Podejścia do degradacji oparte na modelu są stosowane na ogół w prognozowaniu na poziomie komponentów, gdzie zapewniają większą precyzję, ale wymagają rozległych eksperymentów i weryfikacji modelu. Modele te są niezawodne, gdy stan systemu nie został zmieniony ani uaktualniony. Modele można interpretować, ponieważ ich parametry są wyodrębniane z fizyki systemu.

Jednak trudno jest wygenerować zachowanie degradacji, szczególnie w przypadku złożonego systemu, w którym w systemie zachodzi wiele zjawisk.

Podejścia oparte na danych są uważane za modele czarnej skrzynki, w których relacja między danymi wejściowymi i wyjściowymi jest złożona i trudna do zinterpretowania, ale można je stosować, gdy system jest złożony i gdy rozwój dokładny model fizyczny lub matematyczny nie jest wykonalny. Na poziomie komponentów, mogą być mniej precyzyjne niż podejścia oparte na modelu, jednak są bardziej odpowiednie i wydajne dla złożonych systemów, których proces degradacji jest zbyt trudny do modelowania i reprezentowania przez modele fizyczne.

Metryki prognostyczne

Gdy RUL są przewidywane online dla każdej próbki czasu, RUL muszą być oceniane przy użyciu odpowiednich i znaczących metryk. Średni błąd kwadratowy (RMSE) i średni bezwzględny błąd procentowy (MAPE) są szeroko stosowane w literaturze do oceny RUL w zależności od rzeczywistego RUL.

Podejścia do modelowania degradacji

Podejście oparte na modelu fizycznym. - Umiejętność interpretacji przez fizykę. Zapewnij dokładne prognozy RUL na poziomie komponentów. - Wymagana jest szczegółowa wiedza na temat zachowania systemu. Złożony model degradacji systemów jest trudny do zbudowania.

Podejście oparte na danych - Metody statystyczne - Średnia krocząca [6] Skrzynia biegów Silnik ARMA[34] Filtr bayesowski[14] Akumulator, silnik z turbo wentylatorem, Filtr cząstek [40] Element mechaniczny - Zrozumienie mechanizmu degradacji nie jest wymagane. Skuteczne w opisywaniu niepewności procesu degradacji. - W dużym stopniu zależy od informacji o trendach historycznych obserwacji. Mniej precyzyjne w przewidywaniu RUL złożonych systemów.

Metody sztucznej inteligencji - RNN [27][9], SVR [3][18][22] Namiar HMM[24] Namiar Skrzynia biegów, ing. - Potrafi zrozumieć złożone nieliniowe zależności pomiędzy danymi. OFICJALNIE[31] Skrzynia biegów i przekładnie wał Zrozumienie mechanizmu degradacji nie jest wymagane. Oczekuje się dobrej wydajności w przewidywaniu RUL złożonych systemów. - Potrzeba wystarczających danych do treningu. Brak znaczenia fizycznego. Trudności w wyborze parametrów modelu.

Wnioski

W artykule przedstawiono przegląd podejść do prognozowania usterek w celu monitorowania i predykcyjnego utrzymania WT. Prognozowanie usterek WT jest trudnym zadaniem ze względu na złożoność dynamiki, różne warunki pracy i dużą zmienność otoczenia. Omawiane w tym artykule podejścia prognostyczne są porównywane według ich potencjalnych wymagań w Tabeli 5, gdzie każde wymaganie może być „Wymagane”, „Niewymagane” i „Korzystne” dla każdego podejścia prognostycznego.

Tabela 5: Wymagania podejść prognostycznych.

Podejścia	Model inżynierski	Historia degradacji	Aktualny stan zdrowia	Wykrywanie degradacji
Niezawodność	Nie wymagane	Wymagane	Nie wymagane	Nie wymagane
Podobieństwo	Nie wymagane	Wymagane	Wymagane	Korzystne
Oparte na modelu	Wymagane	Korzystne	Wymagane	Wymagane
Oparte na danych	Nie wymagane	Korzystne	Wymagane	Wymagane

Tabela 6 przedstawia porównanie czterech podejść prognostycznych pod względem

precyzji, stosowalności, kosztów i interpretowalności. W przypadku kryteriów precyzji również prognostyka na poziomie komponentu i na poziomie systemu jest porównywana dla każdego podejścia prognostycznego, gdzie (+) odnosi się do zalety, a (-) odnosi się do wady metod.

Podejścia oparte na doświadczeniu (niezawodność i podobieństwo) są łatwiejsze do zastosowania, gdy dostępna jest historia degradacji, ale mniej precyzyjne na poziomie prognostycznym systemu ze względu na zmienność warunków operacyjnych i środowiskowych. Podejścia modelowania degradacji dzielą się na podejścia oparte na modelu i oparte na danych.

Prognostyka oparta na modelu może mieć dobrą precyzję na poziomie komponentu (tj. pęknięcia

Tabela 6: Porównanie podejść prognostycznych.

Podejścia	Precyzja	i stosowalność	Implementacja	Koszt	Interpretowalność
Poziom komponentów	+	-	++	-	-
Poziom systemu	-	+	+	-	-
Niezawodność	+	-	++	-	-
Podobieństwo	+	-	++	-	-
Model	++	+	-	-	+
Oparte na danych	+	++	+	+	-

propagacja łożysk). Chociaż, gdy system jest bardziej złożony, tego rodzaju podejścia mogą nie być precyzyjne, ani nawet stosowalne. Pomimo braku interpretowalności podejść opartych na danych, są one najbardziej odpowiednie do wykonywania zadania prognostycznego złożonych systemów dynamicznych, takich jak turbiny wiatrowe.

Nawet przy rosnącej liczbie publikacji dotyczących prognozowania usterek w celu predykcyjnej konserwacji turbin wiatrowych, nadal należy podjąć kilka wyzwań. Przykładami takich wyzwań są: jak zapewnić prognozę, gdy nie ma wiedzy a priori na temat zachowania degradacji (tj. nowo zainstalowany system), która metoda konstrukcji HI jest odpowiednia w tym przypadku, wybór wartości progowej jest również trudny, a przewidywanie ewolucji degradacji bez informacji a priori na jej temat jest trudne.

Użycie technik dryfu koncepcji może być alternatywnym rozwiązaniem, które przyczyni się do rozwiązania tych wyzwań. Mogą być one używane w celu skonstruowania HI i wykrycia dryfu od warunków nominalnych. Gdy zostanie zebrana wystarczająca ilość danych na temat degradacji, cecha, która najlepiej pasuje do monotoniczności i tendencji podczas degradacji, musi zostać wybrana jako HI.

Wartość progowa musi zostać wybrana w celu wykrycia degradacji tak wcześnie, jak to możliwe, unikając jednocześnie maksymalnej liczby fałszywych alarmów. Ponadto należy rozważyć wielokrotny podział etapów w celu potwierdzenia wystąpienia degradacji. Model prognozowania degradacji musi być również aktualizowany za pomocą zebranych danych przychodzących, aby poprawić wydajność prognozowania (precyzję).

Warto wspomnieć, że inne wyzwanie dla prognozowania błędów jest związane z szacowaniem RUL dla złożonego systemu ze względu na liczne interakcje między ich poszczególnymi składnikami (patrz rys. 3).

Inne wyzwanie jest związane z opracowaniem fazy postprognostycznej w celu interpretacji wyników prognostycznych dla operatorów ludzkich, przy użyciu języka naturalnego

Referencje:

- . Lei, Y., Li, N., Guo, L., Li, N., Yan, T., Lin, J.: Machinery health prognostics: A systematic review from data acquisition to rul prediction. *Mechanical Systems and Signal Processing* 104, 799–834 (2018)
12. Lei, Y., Li, N., Lin, J.: A new method based on stochastic process models for machine remaining useful life prediction. *IEEE Transactions on Instrumentation and Measurement* 65(12), 2671–2684 (2016)
13. Malhi, A., Yan, R., Gao, R.X.: Prognosis of defect propagation based on recurrent neural networks. *IEEE Transactions on Instrumentation and Measurement* 60(3), 703–711 (2011)
14. Mosallam, A., Medjaher, K., Zerhouni, N.: Data-driven prognostic method based on bayesian approaches for direct remaining useful life prediction. *Journal of Intelligent Manufacturing* 27(5), 1037–1048 (2016)
15. Niu, G., Yang, B.S.: Intelligent condition monitoring and prognostics system based on data-fusion strategy. *Expert Systems with Applications* 37(12), 8831–8840 (2010)
16. Paris, P., Erdogan, F.: A critical analysis of crack propagation laws. *Journal of basic engineering* 85(4), 528–533 (1963)

[Read more](#)