

Analiza sygnałów elektrycznych wyjaśniona przez Samotics

cze 8, 2025

Pierwszym krokiem w każdym programie inteligentnego monitorowania stanu jest zainstalowanie stałych czujników w celu ciągłego przechwytywania danych o wysokiej częstotliwości.

Systemy ESA różnią się od wszystkich tych systemów tym, że czujniki elektryczne nie muszą znajdować się w pobliżu rzeczywistej maszyny. ESA wykorzystuje transformatory prądowe i odczepy napięcia, które instaluje się w szafie sterowniczej silnika, gdzie przechwytyują wszystkie trzy fazy prądu i napięcia o wysokiej częstotliwości przez całą dobę.

Istnieje kilka sposobów, w jaki systemy ESA wykorzystują dane o prądzie i napięciu, aby zapewnić wgląd w maszynę.

Na przykład analiza widmowa mapuje siłę różnych częstotliwości w sygnale wejściowym.

Analiza boczna i skrętna pozwala uzyskać wgląd w drgania maszyny w przód i w tył oraz drgania obrotowe.

Analiza mocy ujawnia nieregularności sygnału, takie jak nierównowaga napięcia i zniekształcenia harmoniczne.

Każda z tych kategorii wykorzystuje kilka algorytmów — konkretne przepisy na przetwarzanie danych.

Przykłady obejmują ciągłą transformację falkową, transformację Hilberta i rozszerzone podejście wektorowe Parka. Każdy algorytm ujawnia coś innego na temat maszyny, a razem zapewniają kompleksowy obraz.

Poprzez wielokrotne

wykonywanie tych algorytmów w miarę napływania nowych danych, ESA może identyfikować zmiany, które ujawniają rozwijające się usterki. Może również ujawniać zachowanie systemu, które ostatecznie spowoduje rozwój usterek, takie jak kawitacja pompy.

Analiza sygnatury elektrycznej wykonuje również podstawowe obliczenia na surowym prądzie i napięciu, aby uzyskać wartość skuteczną prądu i napięcia, częstotliwość zasilania, współczynnik mocy, liczbę uruchomień i zatrzymań maszyny, czas pracy maszyny itd. Te metryki są wykorzystywane do dostarczania informacji o energii i wydajności.

Ale najpierw przyjrzyjmy się bliżej jednemu z najbardziej podstawowych algorytmów ESA: szybkiej transformacji Fouriera.

Szybka transformacja Fouriera

Pierwszym krokiem w analizie widmowej jest konwersja przechwyconych danych z dziedziny czasu do dziedziny częstotliwości. Rozbija to sygnał przychodzący na jego składowe częstotliwości. Możesz myśleć o powstałym wykresie jako o „sygnaturze” częstotliwości sygnału – S w ESA.

Dane przychodzące mogą być dowolnym sygnałem zależnym od przestrzeni lub czasu: napięcie, wibracje, temperatura, mowa... Niezależnie od źródła, analiza widmowa zaczyna się od tej konwersji.

Istnieją różne sposoby konwersji danych, ale najpopularniejszym sposobem jest szybka transformata Fouriera, czyli FFT.

To niezwykle cenne narzędzie: największe na świecie stowarzyszenie inżynierów uznało ją za jeden z 10 najlepszych algorytmów XX wieku, a nawet nazwano ją „najważniejszym algorytmem numerycznym naszego życia”. Opiera się na odkryciu Josepha Fouriera z 1822 r., że jeśli dodasz do siebie wystarczająco dużo fal sinusoidalnych, możesz naśladować praktycznie każdą funkcję.

FFT mówi Ci, ile każdej fali sinusoidalnej potrzebujesz, aby zbudować sygnał, który jej podałeś. Dłuższe okno czasowe oznacza inny sygnał, a zatem inną odpowiedź. Jeśli Twoje okno próbkowania jest zbyt długie, otrzymasz odpowiedź, która nie odzwierciedla rzeczywistego stanu maszyny w żadnym momencie. Możesz usłyszeć termin krótkotrwała transformata Fouriera, aby opisać użycie wystarczająco małych okien, aby dokładnie uchwycić zachowanie maszyny.

Po przekonwertowaniu wystarczającej ilości danych przychodzących możesz utworzyć to, co nazywa się mapą cieplną.

Możesz również usłyszeć słowa spektrogram lub wodospad. To sposób na przeglądanie wszystkich wykresów z dłuższego okresu czasu, aby zobaczyć, jak rzeczy się zmieniały. (Oczywiście oprogramowanie do monitorowania stanu nie musi przeglądać wykresów, ale są one przydatne dla nas, ludzi.)

Podobnie jak wykres FFT, mapa cieplna przedstawia częstotliwość na osi x, ale zamiast energii przedstawia czas na osi y. Gdyby tak było, mielibyśmy po prostu duży czarny kwadrat, ponieważ każda częstotliwość jest obecna w bieżącym sygnale, gdy maszyna pracuje. Musimy również zobaczyć ilość każdej częstotliwości. W tym celu mapy cieplne wykorzystują kolor. Na pokazanej tutaj mapie cieplnej niebieski oznacza niską energię, a czerwony oznacza wysoką, z żółtym na środku. Dzięki temu uniwersalnemu formatowi, ze starszą sytuacją na górze i najnowszą sytuacją na dole, możesz zobaczyć na pierwszy rzut oka, że coś się zmieniło w tej maszynie.

Teraz zobaczmy, jak ESA określa, co się zmieniło, kontynuując analizę widmową opartą na FFT jako nasz przykład.

Analiza oparta na modelu

Na poniższym wykresie narysowaliśmy aktualną sygnaturę częstotliwości konkretnego silnika w dwóch różnych punktach czasowych: nowszy na niebiesko, starszy na czarno. Jak widać, nie pokrywają się one dokładnie. To mówi, że coś się zmieniło.

Czasami będzie to normalna zmiana procesu – może uruchamiasz silnik szybciej lub pompujesz gęstszy płyn. Ale zobaczysz również zmiany, gdy coś wewnątrz urządzenia ulegnie zmianie: na przykład łożysko zacznie się zużywać, sprzęgło zacznie się luzować lub izolacja pokrywająca uzwojenia w stojanie silnika zacznie się degradować.

Tak więc pierwszym sposobem, w jaki analiza widmowa pomaga wykryć rozwijające się problemy, jest śledzenie tych zmian w czasie i porównywanie ich z biblioteką znanych mechanizmów awarii. Nazywamy je „odciskami palców awarii”. Na wykresie, który tutaj oglądamy, niebieskie szczyty przy wielokrotnościach częstotliwości obrotowej tego silnika są znakiem rozpoznawczym złamanego pręta wirnika.

(Nie dzieje się tu nic wyjątkowego – to jest to, co robi każda technologia monitorowania stanu. Istnieją identyfikowalne odciski palców awarii dla oleju, ciepła, wibracji, dźwięku itd. MCSA po prostu wykorzystuje tę ustaloną technikę w oparciu o inne źródło danych, z innymi odciskami palców.)

Analiza oparta na danych

Oto druga maszyna, której aktualna sygnatura w dziedzinie częstotliwości znacznie różni się od tej na stronie 7. Tak więc część wyzwania w analizie widmowej (niezależnie od rodzaju używanych danych) polega na określeniu, jak wygląda „odcisk palca awarii” dla każdej unikalnej maszyny.

— Dlatego dobry system monitorowania stanu wykonuje również analizę opartą na danych, a nie tylko analizę opartą na modelu.

„Oparta na danych” oznacza, że system uczy się, jak wygląda zdrowe zachowanie dla danego sprzętu, więc gdy zaczną zachodzić zmiany, system może od razu odróżnić normalne odchylenia od zmian oznaczających problem.

W tym miejscu absolutnie musisz mieć system oparty na sztucznej inteligencji. Żaden człowiek, bez względu na to, jak bardzo jest ekspertem, nie nadąży za ilością informacji wymaganą przez tę głębię analizy. Ale algorytmy uczenia maszynowego mają trzy supermoce: po pierwsze, pracują 24 godziny na dobę, 7 dni w tygodniu, 365 dni w roku, przetwarzając terabajty danych bez przerwy. Po drugie, potrafią wykryć drobne zmiany, których ludzki obserwator by nie zauważył.

Każdy silnik i maszyna ma inny zdrowy wzorzec, którego system monitorowania stanu musi się nauczyć, jeśli ma wykryć rozwijające się usterki wystarczająco wcześnie, aby pomóc. Ostatnie postępy w uczeniu maszynowym sprawiły, że ten poziom wykrywania jest w zasięgu ręki.