

Fizycznie ugruntowane wielomodalne uczenie samonadzorowane z wykorzystaniem dekompozycji tensorowych do detekcji i identyfikacji cyklostacjonarnych impulsowych sygnaturow uszkodzeń w maszynach obrotowych

Współczesny przemysł jest silnie uzależniony od maszyn wirujących. Praktycznie w każdej maszynie znajdują się układy napędowe, a w nich łożyska czy przekładnie zębate (te również mają w sobie łożyska). Zatem łożyska toczne i koła zębate to kluczowe komponenty w układach mechanicznych. Ich nieoczekiwane awarie są kosztowne i niekiedy niebezpieczne — powodują przestoje produkcyjne, wysokie koszty napraw i ryzyko dla bezpieczeństwa eksploatacji. Problem polega na tym, że inicjacja uszkodzenia przebiega w sposób niezauważalny. Jednak, nawet na wczesnym etapie drobny defekt generuje bardzo słabe, powtarzalne ślady, czyli charakterystyczne „odciski” w sygnałach drganiowych lub akustycznych. W przetwarzaniu sygnałów określa się je jako cyklostacjonarne sygnaturowe impulsowe, tzn. krótkie zdarzenia udarowe powtarzające się z rytmem związanym z ruchem obrotowym maszyny. W praktyce sygnaturowe te bywają zakłócone przez hałas lub drgania (często o impulsowym charakterze) pochodzące z wewnętrznych i zewnętrznych źródeł, a zmienność warunków operacyjnych (zmiana prędkości i obciążenia) może wpływać zarówno na sygnał informacyjny, jak i na poziom oraz strukturę zakłóceń. Dodatkowo ta sama maszyna, realizująca proces technologiczny w innych warunkach może ze względu na poziom i strukturę zakłóceń zewnętrznych być trudniejsza do zdiagnozowania.

Celem projektu jest opracowanie nowej generacji inteligentnych metod umożliwiających znacznie wcześniejsze wykrywanie i identyfikację uszkodzeń niż obecnie, przy zachowaniu wysokiej niezawodności dla różnych maszyn, czujników, lokalizacji oraz warunków eksploatacji. Zamierzamy rozwijać zaawansowane metody uczenia maszynowego (ML), w szczególności metody samouczące się na podstawie danych wielomodalnych (sygnały wibracyjne i akustyczne). Dążymy też do tego, aby opracowane algorytmy były obliczeniowo wydajne i mogły być uruchamiane w środowisku o ograniczonych zasobach obliczeniowych.

Aby zrealizować te cele, projekt łączy nauki komputerowe, matematykę stosowaną i statystykę, przetwarzanie sygnałów oraz inżynierię mechaniczną. Interdyscyplinarny zespół jest tu kluczowy: inżynierowie dostarczają wiedzę o fizycznym zachowaniu maszyn i mechanizmach uszkodzeń, matematycy rozwijają i analizują modele statystyczne oraz metody przetwarzania sygnałów, a informatycy projektują i implementują algorytmy ML oraz odporne strategie uczenia. Dzięki temu powstające rozwiązania nie są „czarnymi skrzynkami”, lecz uwzględniają prawa fizyczne rządzące zachowaniem maszyn, są bardziej odporne na zakłócenia i zmienność warunków oraz łatwiejsze do weryfikacji. Rzeczywiste uwarunkowania przemysłowe i wiedza fizyczna będą dodatkowo inspirować rozwój nowych metod obliczeniowych w obszarze ML. Wizja ta będzie realizowana etapami w ramach trzech wzajemnie powiązanych pakietów roboczych.

W pierwszym etapie opracujemy metody przekształcania sygnałów pomiarowych w reprezentacje uwydatniające bardzo słabe wczesne symptomy uszkodzenia. Będą one stabilne mimo zmian prędkości obrotowej lub obciążenia. Zbudujemy procedury tłumiące przypadkowe zakłócenia przy zachowaniu powtarzalnych wzorców generowanych przez defekty. Łącząc informacje z drgań i akustyki, wzmocnimy komponenty wspólne dla obu czujników (sygnaturę uszkodzenia), ograniczając składniki specyficzne dla pojedynczej modalności. Następnie, wykorzystując wiedzę fizyczną o modelach uszkodzeń, opracujemy samouczące się algorytmy o architekturze enkodera z głowicami zadaniowymi dostrojonymi do kluczowych cech zjawisk fizycznych, zdolne do uczenia się na dużych multimodalnych zbiorach danych z normalnej eksploatacji, przy minimalnym lub nawet całkowitym braku danych ze stanów awaryjnych. Jest to kluczowe, ponieważ zwykle brakuje dobrze opisanych przypadków uszkodzenia do trenowania standardowych modeli. Modele będą uczyć się użytecznych wzorców poprzez starannie zaprojektowane zadania treningowe odzwierciedlające fizykę pracy maszyn. Po przeniesieniu na nową maszynę lub do nowej lokalizacji dostosują się na podstawie bieżących danych, nawet bez opisów awarii z danego obiektu. Opracowane kompaktowe i szybkie modele będą przede wszystkim wkładem do wiedzy podstawowej. W ostatnim etapie zajmiemy się przypadkami współwystępowania wielu uszkodzeń. Opracujemy metody separacji nakładających się sygnałów oraz ich klasyfikacji zgodnej z rodzajami występujących uszkodzeń, co umożliwi wiarygodne raportowanie więcej niż jednego uszkodzenia jednocześnie.

Oczekiwane rezultaty będą istotne dla rozwoju nauki i społeczeństwa. W obszarze informatyki i uczenia maszynowego projekt poszerza możliwości uczenia na rzeczywistych szeregach czasowych: zaszumionych, niestacjonarnych i zróżnicowanych pomiędzy środowiskami. Dla społeczności badawczej projekt dostarczy narzędzi informatycznych oraz zestawy danych referencyjnych, wspierając badania odtwarzalne i przyspieszając postęp. Równocześnie wypracowane zostaną podstawy metodologiczne umożliwiające tworzenie systemów wcześniejszego i bardziej wiarygodnego ostrzegania, które mogą ograniczać awarie, przestoje i koszty utrzymania w sektorach takich jak produkcja, energetyka, surowce, transport, lotnictwo czy systemy morskie. Dla cyfrowego społeczeństwa opartego na IT projekt wzmacnia podstawy „inteligentnego utrzymania ruchu”: maszyn samomonitorujących się, udostępniających rzetelną informację o ich stanie i zapobiegających awariom zanim one nastąpią.