



## WYKORZYSTANIE SZTUCZNEJ INTELIGENCJI DO DETEKЦИИ USZKODZEŃ ŁOŻYSK TOCZNYCH

// Łożyska toczne są często psującymi się elementami maszyn i podlegają relatywnie częstym wymianom. Niektóre z nich psują się cyklicznie, aczkolwiek nie jest to regułą. Uszkodzenie łożyska może być spowodowane nadmierną eksploatacją, wadą materiałową, dokładnością wykonania czy przypadkowym zabrudzeniem. Najczęściej łożysko psuje się w sposób stopniowy. Coś inicjuje przyspieszone zużycie aż do momentu zupełnego zniszczenia. Temat wczesnego wykrycia uszkodzenia łożyska jest dobrze opracowany, na rynku istnieją zaawansowane urządzenia pozwalające na diagnostykę tychże części maszyn.



**Autor // PIOTR KMITA**


Inżynier mechanik, pasjonat zagadnień związanych ze sztuczną inteligencją i jej wykorzystaniu w szeroko rozumianym temacie predictive maintenance, czyli, najogólniej mówiąc, przewidywaniu serwisu maszyn, zanim nastąpi awaria. piotrkm@gmail.com



Popularną metodą oceny zużycia łożyska jest analiza drgań przez nie emitowanych. Sama ich amplituda, czy głośność pracy, może być oceniona organoleptycznie. Inaczej mówiąc, kiedy łożysko uszkodzi się, to zaczyna je być bardziej słychać. Nie zawsze jednak jest możliwe, aby je usłyszeć. W miejscach rzadko odwiedzanych, pracujących autonomicznie oraz tam, gdzie hałas i poziom innych dźwięków otoczenia jest zbyt duży, dźwięk samego łożyska może zostać zagłuszony.

Istnieje dobrze opracowana teoria na temat tego, jaki typ uszkodzenia powoduje zwiększoną emisję drgań. Rozróżniamy kilka podstawowych typów uszkodzeń: uszkodzenie bieżni pierścienia zewnętrznego lub wewnętrznego, uszkodzenie elementu tocznego, jak i tzw. koszyka oraz uszczelnacza. Każdy z tych typów według teorii generować będzie charakterystyczne drgania. Do oceny charakteru drgań przydaje nam się transformata Fouriera (rys. 1), z której wykresu możemy odczytać, jakie częstotliwości

są dominujące, i według opracowanych wcześniej wzorów oszacować, czy dane łożysko jest uszkodzone w konkretny sposób. Czynność ta jednak wymaga posiadania odpowiedniego sprzętu i wiedzy niezbędnej do wyciągnięcia takiego wniosku.

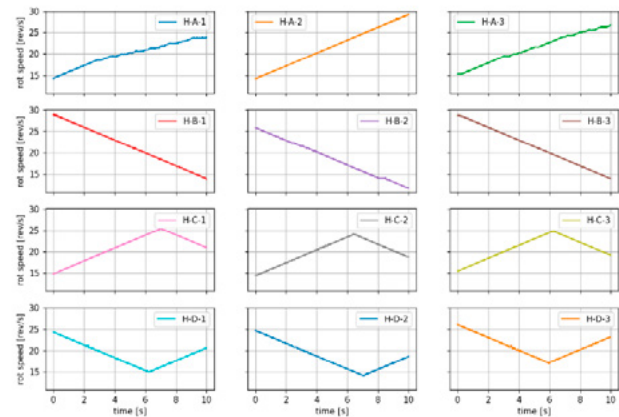


**Rys. 1.** // Wykres transformaty Fouriera FFT. Czerwona pionowa linia oznacza częstotliwość wymuszającą wynikającą z prędkości obrotowej, linia fioletowa i zielona oznaczają potencjalne występowanie pików amplitudy mogące świadczyć o danym rodzaju uszkodzenia konkretnego typu łożyska.

Sztuczna inteligencja będąca tak naprawdę pewnym rodzajem oprogramowania komputerowego, które może przyjść nam z pomocą, Według ogólnych zaleceń powinna być stosowana tam, gdzie stworzenie oprogramowania byłoby kłopotliwe z uwagi na niejednoznaczność dostarczonych do analizy danych, jak i zaszumienie sygnału czynnikami zewnętrznymi. Napisanie programu, który w sposób analityczny wykrywa uszkodzenie przy użyciu instrukcji warunkowych, mogłoby okazać się bardzo kłopotliwe. W takich właśnie przypadkach trafnym wyborem mogą okazać się algorytmy AI (Artificial Intelligence). Podejście takie nie jest jednak pozbawione wad. Algorytmy AI, których zadaniem jest niejako zakwalifikowanie łożyska jako dobrze pracujące lub uszkodzone, wymagają ich wytrenowania poprzez podanie czasem i sporej ilości danych oraz wskazanie, który z sygnałów pochodzi z jakiego stanu. Przypadek łożysk jest dodatkowo kłopotliwy, gdyż częstotliwości cech charakterystycznych są zależne od konstrukcji łożyska, tj. jego rozmiarów i ilości elementów tocznych. Niepomijalne jest również odpowiednie przygotowanie danych poprzez np. filtrowanie i skalowanie, tak aby pomóc modelowi w identyfikacji wspomnianych cech sygnału odpowiedzialnych za poszczególne typy uszkodzeń.


Z nieprzebranej zawartości zasobów internetu można ściągnąć nagrania jednego typu łożyska ER16K. Dane zostały opracowane na uniwersytecie w Ottawie przez Huan Huang, Natalie Baddour i opublikowane na łamach

„ELSEVIER” jako artykuł *Bearing vibration data collected under time-varying rotational speed conditions* w 2018 r. Zawierają one odczyty pracującego łożyska zarówno dla stanu nieuszkodzonego, jak i poszczególnych typów uszkodzeń. Zarejestrowane informacje to: zmienna prędkość obrotowa łożyska i odczyty mierzonych wibracji w postaci przyspieszeń. Częstotliwość próbkowania wynosiła 200 kHz. Każdy stan łożyska został zarejestrowany dla kolejno jednostajnie wzrastającej i malejącej prędkości, jak i dla wzrastającej, a następnie malejącej i odwrotnie, po trzy różne próbki dla każdego schematu prędkości (rys. 2).



**Rys. 2.** // Wykresy prędkości obrotowej łożyska dla poszczególnych sygnałów.

Do opracowania została przyjęta metoda oceny stanu łożyska na podstawie analizy widma częstotliwości drgań (przyspieszenia) z wykorzystaniem transformaty Fouriera FFT. Obrabiany sygnał o długości 10 sekund zawierający 2'000'000 odczytów podzielono na 20 równych półsekundowych części. Dla każdej z takich części została wyznaczona osobna transformata Fouriera (rys. 3). Tak przygotowane dane następnie poddano procesowi normalizacji częstotliwości. Pod tym pojęciem rozumieć należy działanie z zakresu DSP (Digital Signal Processing), które zrównuje częstości wymuszające (w naszym przypadku jest to prędkość obrotowa) do jednej wartości np. 10 Hz – taka wartość została przyjęta na rys. 3. Dane przygotowane w ten sposób zostały użyte do treningu modelu sztucznej inteligencji.

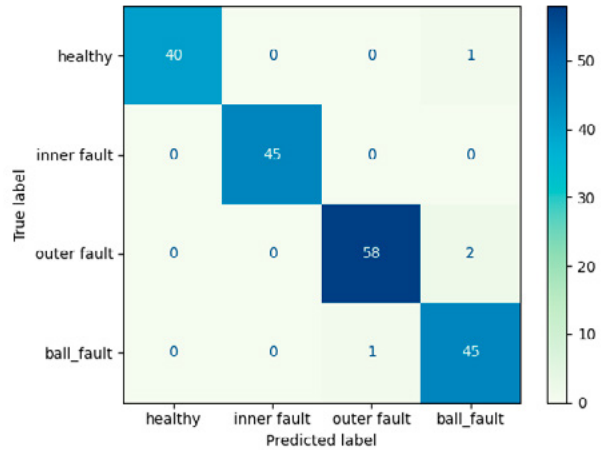


**Rys. 3.** // Zestaw widm częstotliwościowych otrzymanych z podzielonych sygnałów.

W powyższym przykładzie użyty został model z dziedziny ML (Machine Learning). Akademicką dyskusją pozostaje kwestia, czy ML nadal zaliczane jest jako AI. Według wielu definicji samej sztucznej inteligencji ML jak najbardziej się w niej mieści. Nadal są to algorytmy wymagające uczenia, choć działają w sposób odmienny niż algorytmy oparte na sieciach neuronowych ANN (Artificial Neural Network) zaliczające się z kolei do dziedziny DL (Deep Learning), chociaż to ich wielkość, a raczej głębokość o tym świadczy. Przyjmuje się, że dopiero modele o strukturze zawierające powyżej trzech warstw można nazywać modelami głębokiego uczenia.

W naszym przypadku został użyty model typu SVM (Support Vector Machine), a w szczególności SVC (Support Vector Classifier) jako model klasyfikacyjny. Jego zadaniem jest zakwalifikowanie danej próbki sygnału zawierającego odczyty amplitudy przyspieszeń do kategorii (klasy). W naszym przypadku będzie to [sprawne, uszkodzenie\_typ1, uszkodzenie\_typ2, uszkodzenie\_typ3].

Do oceny sprawności modelu klasyfikacyjnego używa się tzw. metryki dokładności *accuracy* przyjmującej wartości od 0 do 1, gdzie 0 oznaczać będzie jego zerową skuteczność a wartość 1 – stuprocentową. Jedną z metod wizualizacji sprawności modelu jest *confusion matrix*, nazywana w języku ojczystym macierzą konfuzji, chociaż lepiej brzmiącym tłumaczeniem wydaje się macierz pomyłek przedstawiona na rys. 4. Należy ją interpretować w następujący sposób – poziome rzędy oznaczone są jako *True label*, czyli stany rzeczywiste, *Predicted label* to wartości oszacowane przez model. Wartość 40 w lewym górnym rogu oznacza, że 40 próbek sygnału pochodzących z nieuszkodzonego łożyska (*healthy*) *True label* zostało poprawnie oznaczone przez model jako nieuszkodzone *Predicted label*. Wartość 1 w prawym górnym narożniku oznacza, że choć jeden egzemplarz sygnału w rzeczywistości miał etykietę nieuszkodzonego, został błędnie zakwalifikowany jako łożysko z uszkodzonym elementem tocznym (*ball fault*). Liczba 2 znajdująca się na skrzyżowaniu *outer fault* – *True label* i *ball fault* – *Predicted label* oznaczać będzie, że dwa sygnały pochodzące z łożyska z uszkodzonym pierścieniem zewnętrznym zostały błędnie zakwalifikowane jako z uszkodzonym elementem tocznym. W uproszczony sposób można powiedzieć, że gdy przekątna macierzy pomyłek biegnąca od lewego górnego rogu do prawego dolnego zawiera największe wartości, to model wykazuje się dobrą sprawnością oceny. Wartość podstawowej metryki dla modeli kwalifikacyjnych, tzw. dokładność (*accuracy*), jest wyrażona stosunkiem ilości wszystkich przypadków do tych poprawnie wytypowanych. Dla naszego przypadku wynosi ona 98%. Innymi słowy, na 100 pomiarów 98 zostało oznaczonych poprawnie, a 2 błędnie.



Rys. 4. // Wizualna ocena sprawności modelu z wykorzystaniem *confusion matrix* (macierz konfuzji / macierz pomyłek).

Poczynione rozważania dotyczą jedynie jednego łożyska z publicznie dostępnych danych pobranych z internetu. Pomiaru wykonano za pomocą sprzętu laboratoryjnego z odizolowanego od czynników zewnętrznych środowiska. Użyty został stosunkowo prosty podstawowy model ML - SVC. Istnieje cała gama innych modeli które mogłyby dać równie dobre wyniki. Do zadań tego typu można również zaprzęgnąć sieci neuronowe ANN z tzw. warstwą konwolucyjną do których zbędne byłoby użycie transformaty Fouriera FFT. Podsumowując, możliwości w sposobie podejścia do tematu detekcji uszkodzeń łożysk tocznych jest wiele. Jednakowoż wynik 98% jest bardzo dobry i dobrze rokuje dla tej metody.

Do powyższej analizy zostały użyte ogólnodostępne biblioteki języka Python takie jak: Numpy, Scikit-learn oraz SciPy. Wykorzystywany komputer to zwykły laptop o niewyśrubowanych parametrach. O ile *processing* danych zajmuje około kilkudziesięciu sekund, to proces treningu i samej predykcji trwa relatywnie krótko, po wciśnięciu *Enter* wynik pojawia się natychmiast. Świadczy to o tym, że do wykonania takich analiz nie są wymagane kosztowne moce obliczeniowe w postaci sprzętu, a oprogramowanie jest praktycznie darmowe.

Przykład ten ma raczej na celu przedstawienie pewnych możliwości zastosowania sztucznej inteligencji w wykrywaniu potencjalnych zjawisk. Niekoniecznie muszą to być łożyska, w rzeczywistości mogą to być dowolne inne sygnały, które można zamienić do postaci cyfrowej (zdigitalizować) takie jak wartości pobieranego przez urządzenie prądu, temperatury, odkształcenia lub dowolnych innych mierzalnych parametrów dla wartości zarówno dyskretnych, jak i zakresowych.

Wszelkie osoby zainteresowane rozwojem sztucznej inteligencji AI w dziedzinach technicznych takich jak *predictive maintenance* zapraszam do kontaktu. //