WPŁYW KONDYCJI ŁOŻYSK NA UTRZYMANIE PROCESÓW PRODUKCYJNYCH

Wojciech PTASIŃSKI[1*], Artur POLLAK[1], Sebastian TEMICH[1], and Damian GĄSIOREK[2]

[1] APA Group, Gliwice; wojciech.ptasinski@apagroup.pl, artur.pollak@apagroup.pl, sebastian.temich@apagrou.pl
[2] Politechnika Śląska, Gliwice; damian.gasiorek@polsl.pl
* Korespondencja: wojciech.ptasinski@apagroup.pl

Streszczenie: Współczesne aspekty Przemysłu 4.0 ukierunkowane są na analizę danych, ale również na podejmowanie odpowiednich decyzji dotyczących produkcji biznesowej oraz na obszary związane z predykcją uszkodzeń elementów maszyn, które decydują o zachowaniu ciągłości procesów produkcyjnych. Z punktu widzenia zarządzania produkcją jest to zjawisko oczekiwane w nowoczesnym przedsiębiorstwie. Przeprowadzone badania literaturowe wykazują, że jednymi z częściej występujących uszkodzeń w maszynach przemysłowych oraz na liniach produkcyjnych są uszkodzenia łożysk, które skutkują pogorszeniem działania maszyny (częściowe uszkodzenia wywołują dodatkowe tarcie) lub jej całkowitym zatrzymaniem. Co więcej, niepoprawnie działająca maszyna może również prowadzić do uszkodzenia, w wyniku czego mogą ucierpieć osoby, znajdujące się w pobliżu, a zapewnienie bezpieczeństwa stanowiska pracy jest obligatoryjnym elementem każdego poprawnie funkcjonującego przedsiębiorstwa. Celem badań było określenie możliwości klasyfikacji anomalii dla poszczególnych uszkodzeń łożysk, z wykorzystaniem sieci neuronowych. W prezentowanym artykule przeprowadzono testy mające na celu wykrywanie anomalii w pracy łożysk kulowych z wykorzystaniem dwóch rodzajów sygnałów, tj. dźwięku i wibracji. Na podstawie danych pomiarowych opracowano algorytm bazujący na sztucznej inteligencji, który pozwala na klasyfikacje stanu łożysk kulkowych. Istotnym aspektem opracowanego podejścia jest charakter adaptacyjny, który rozwiązuje problem dostępności danych z awarii urządzenia, dlatego taki system można wykorzystać do adaptacji pracy dowolnej maszyny. Opisane podejście pozwala na zmniejszenie kosztów utrzymania firmy poprzez zmniejszenie stanów awaryjnych oraz możliwość planowania prac serwisowych na liniach produkcyjnych, a zaproponowany w artykule algorytm może dotyczyć szeregu aspektów uszkodzenia maszyn działających na liniach produkcyjnych.

Słowa kluczowe: Inteligentne linie produkcyjne, diagnostyka łożysk, inżynieria produkcji, utrzymanie ruchu

THE IMPACT OF BEARING CONDITION ON MAINTENANCE OF PRODUCTION PROCESSES

Abstract: Modern aspects of Industry 4.0 are focused not only on data analysis for the sake of making the right business decision, but also on areas related to the prediction of damage to machine elements that determine the continuity of production, which from the perspective of production management is a phenomenon expected in a modern company. The conducted research shows that one of the most frequent damages in industrial machines are ball bearing failures, which result in deterioration of the machine operation (partial damages cause additional friction) or its complete stop. What is more, a malfunctioning machine can also lead to damage, resulting in harm to people in the vicinity, and ensuring workplace safety is a mandatory part of any properly functioning enterprise. This paper presents a test approach for detecting anomalies in the operation of ball bearings using two sources, i.e. sound and vibration. The research objective was to determine the accuracy of anomaly classification for individual bearing failures using a methodology that implements artificial neural networks. Based on the measurement data, an algorithm using artificial intelligence was developed to classify the condition of ball bearings. An important aspect of the developed approach is also adaptive in nature, which solves the problem of availability of data from equipment failure, so such a system can be used to learn the current operation of any machine. The described approach allows to reduce the maintenance costs of the company by reducing the failure states and the ability to schedule maintenance work on production lines. The algorithm described in the article can apply to any aspect of machines and equipment operating on production lines.

Keywords: Smart production lines, bearing diagnostics, manufacturing engineering, maintenance

1. Wprowadzanie

Czwarta rewolucja przemysłowa polega m.in. na zaawansowanej integracji pracowników, maszyn, dostawców i innych partnerów, którzy tworzą tzw. cyfrowy ekosystem biznesowy, a także na transformacji cyfrowej wszelkich środków trwałych (Grabowska i Sieka, 2019). Ważnym elementem zmiany w podejściu do prowadzenia przedsiębiorstwa jest pionowa i pozioma integracja łańcucha wartości. Podeście do klienta czy sposobów komunikacji z klientem B2B zostaje zamienione na podejście B2B2C, gdzie ważną role zaczyna odgrywać dla przedsiębiorcy klient docelowy (Ponierewski 2019). Narzędzia, wykorzystujące sztuczną inteligencję pozwalają na lepszą analizę danych, które były dotychczas zbierane z urządzeń i monitorowane na podstawie klasycznych podejść. Jest to zapewnione m.in. przez analitykę big data, czyli opracowywanie algorytmów opartych na dużej liczbie danych. Systemy tego typu wykorzystują szeroko rozumianą sztuczną inteligencję, która pozwala na klasyfikację pewnych zjawisk (np. uszkodzeń urządzeń lub defektów produktu), a także predykcję różnych

parametrów związanych z produkcją (np. przewidywanie daty najbliższego serwisu lub zapotrzebowania energii elektrycznej w danym okresie).

Przemysł 4.0 nabiera coraz większego znaczenia oraz staje się trendem wskazującym kierunek zmian w przemyśle i gospodarce, będących konsekwencją transformacji cyfrowej (Pollak et al. 2020). Uważa się, że koncepcje wywodzące się z aktualnych trendów przemysłu, oprócz redukcji kosztów i maksymalizacji efektywności, powinny m.in. zwiększyć elastyczność projektowania i produkcji (Zhong et al., 2017), poprawić dokładność i jakość wyrobów, skrócić czas operacji, poprawić alokację zasobów i zarządzanie materiałami(Albers et al., 2016; Sader, 2017), umożliwić odpowiednie sterowanie procesami oraz wprowadzić innowacyjne rozwiązania (Stankovic et al. 2017, Alcacer and Cruz-Machado 2019).

W APA Group prowadzone są prace badawcze w ramach projektu NAZCA 4.0, które mają na celu opracowanie zbioru narzędzi, pozwalających m.in. na usprawnienie działania sekcji serwisowej, poprzez wykorzystanie innowacyjnych algorytmów i danych z maszyn do przewidywania najbliższej akcji naprawczej i co ważne, wykrycia odchyleń od poprawnej pracy (tzw. anomalii), które są pierwszą oznaką przed awarią, a klasyczne podejścia nie zawsze są w stanie wykryć je we wczesnym etapie. Monitorowanie oraz diagnostyka urządzeń w czasie rzeczywistym, a także przewidywanie najbliższych serwisów na podstawie danych historycznych pozwalają na lepsze zarządzanie produkcją i uniknięcie nieplanowanych przestojów, które mogą być spowodowane uszkodzeniem maszyny.

W procesie produkcyjnym każdego przedsiębiorstwa można wyróżnić pewne wady produktów, które powstają wskutek braku przeszkolenia pracowników, nieodpowiedniego doboru parametrów procesu, czy też stanu maszyny. Odpowiednie metody i narzędzia pomagają na wyeliminowanie lub zapobieganie pojawianiu się wad i defektów danego produktu (Ciukaj 2020). Niepoprawnie pracująca maszyna może pogorszyć jakość produkcji, ponieważ zanim źródło powstawania wad produktu zostanie zlokalizowane, może zostać wyprodukowana pewna ilość fabrykatu z defektem, co przekłada się na straty finansowe.

W powyższej pracy autorzy skupili się na badaniu jednego z najczęściej uszkadzanych elementów maszyn, czyli łożysk. Łożyska należą do najczęściej używanych elementów, a jednocześnie są wrażliwymi ogniwami maszyn wirnikowych, gdzie ich niespodziewana awaria może spowodować kosztowne przestoje i nieplanowane czynności konserwacyjne. Dlatego też niezwykle istotne jest opracowanie metod zapewniających niezawodną i ekonomiczną pracę łożysk (Zio and Gola 2009).

Diagnostyka drganiowa zapewnia wykrywanie praktycznie wszystkich niesprawności maszyn i urządzeń eksploatowanych w warunkach przemysłowych, są to m.in.: niewyważenie elementów wirujących, przycieranie, luzy mechaniczne, uszkodzenia przekładni mechanicznych, a także uszkodzenia łożysk (Fidali 2020). Drgania wywoływane przez uszkodzone urządzenie wytwarzają również fale akustyczne, które można wychwycić

za pomocą mikrofonu. Analiza sygnału audio w czasie rzeczywistym i zaawansowane algorytmy są w stanie zidentyfikować początki awarii, spowodowane defektami, degradacją, przeciążeniem lub niewłaściwą konserwacją (F B Marin et al. 2019).

Zastosowanie do tego celu zaawansowanych algorytmów nauczania maszynowego pozwala na wydobycie cennych informacji o urządzeniu, co może pomóc w zapobiegnięciu awarii, czy też wczesnym zaplanowaniu prac serwisowych.

W pracach prowadzonych przez naukowców na świecie, dotyczących analizy i przetwarzania sygnału akustycznego oraz drganiowego, pojawiły się podejścia takie jak analiza w dziedzinie czasu, która jest klasyczną techniką wykrywania uszkodzeń np. w łożyskach. Analiza w dziedzinie czasu zazwyczaj wykorzystuje wskaźniki skalarne do określenia stanu łożyska. (Mathew et al., 1984; Tandon, 1994), analiza czasowo-częstotliwościowa (Starczyński and Sułowicz, 2016) oraz obwiedni funkcji autokorelacji (Starczyński and Sułowicz, 2016; Pawlak 2011).

Większość dotychczasowych podejść stosowanych do diagnostyki uszkodzeń łożysk, opiera się na paradygmacie uczenia nadzorowanego, co wymaga zbioru danych z poprawnej pracy oraz w trakcie awarii, zebranych a priori.

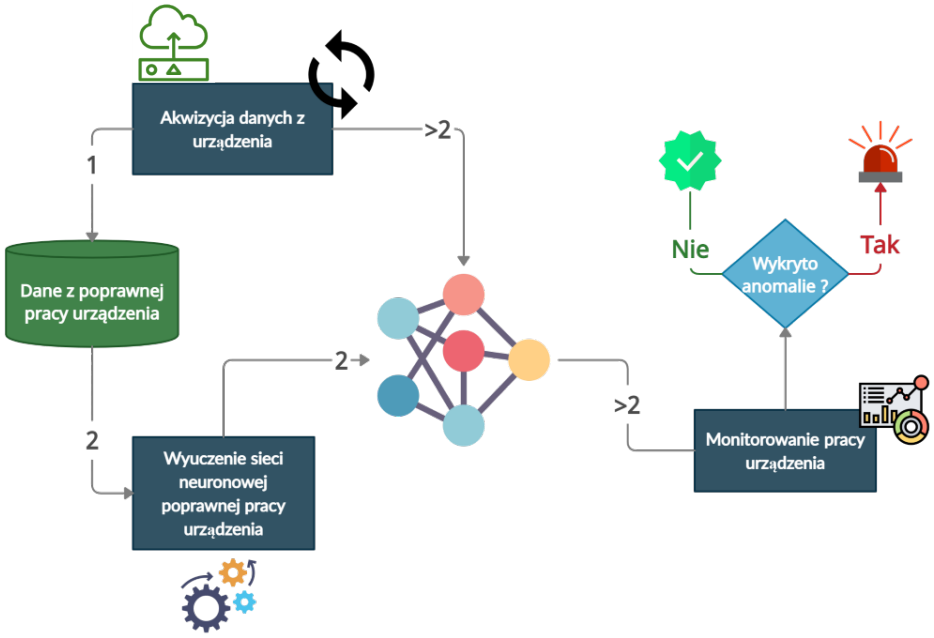

Rysunek 1. Schemat poglądowy procesu uczenia się poprawnej urządzenia przez algorytm oraz monitorowania on-line. Liczby 1 i 2 oznaczają kolejne kroki, a ">2" pracę systemu po wstępnej konfiguracji.

W niniejszym artykule przedstawiono podejście o charakterze adaptacyjnym do analizy łożysk kulkowych, a także porównanie tej samej metody dla dwóch sygnałów tj. dźwięk nagrany za pomocą mikrofonu, a także drgania mierzone z wykorzystaniem akcelerometrów. Dzięki temu podejściu, do monitorowania aktualnego stanu łożyska nie jest wymagane posiadanie danych z uszkodzeń, m.in dlatego, że dane z awarii w produkcji zazwyczaj są ciężko dostępne.

Badania zostały przeprowadzone na stanowisku diagnostycznym firmy GUNT na wydziale Mechanicznym Technologicznym Politechniki Śląskiej. Stanowisko pozwala na analizę m.in. stanu łożysk, przekładni pasowej, kół zębatych oraz innych elementów mechanicznych, i co najważniejsze, z różnymi wariantami defektów. W konfiguracji wykorzystanej do opisywanego doświadczania zbadano łożyska z uszkodzeniami kulek, bieżni wewnętrznej i zewnętrznej oraz posiadające kombinacje uszkodzeń. Poniżej w artykule zostaną przedstawione badane uszkodzenia łożysk kulkowych.

2. Procedura badawcza

Do przeprowadzenia badań na łożyskach kulkowych wykorzystano stanowisko badawcze firmy GUNT. Stanowisko składa się m.in. z jednostki napędowej, badanych łożysk kulkowych umieszczonych w piastach, dwóch akcelerometrów, urządzenia do akwizycji danych oraz przekładni pasowej.

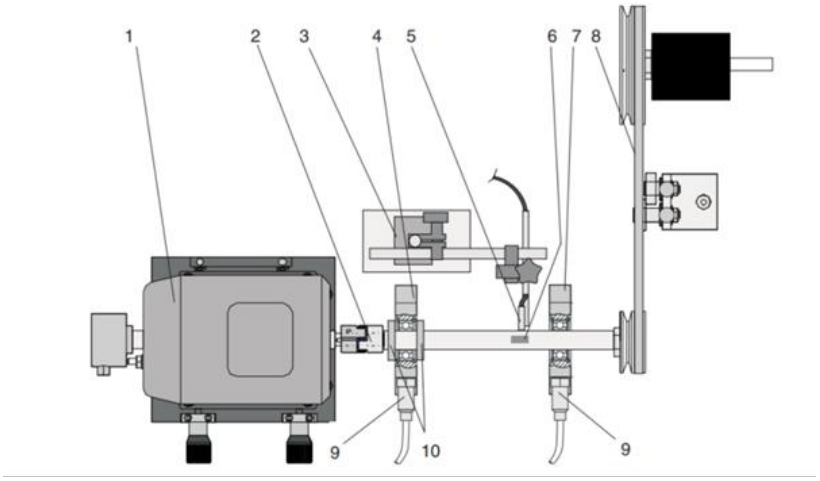

Rysunek 2. Elementy wchodzące w skład stanowiska do diagnostyki łożysk kulkowych. 1. Jednostka napędowa, 2. Sprzęgło kłowe elastyczne, 3. Zacisk magnetyczny z płytką stalową, 4. Piasta z niezniszczonym łożyskiem kulkowym, 6. Krótki wałek z oznaczeniem odblaskowym, 7. Piasta z uszkodzonym łożyskiem kulkowym, 8. Napęd pasowy, 9. Czujnik przyspieszenia (poziomy), 10. Pierścień nastawczy Adapted from: Test stand scheme from PT500_12e - V1.1 documentation GUNT

Stanowisko pozwala na testowanie ww. elementów mechanicznych poprzez zadawanie odpowiedniej prędkości na układ napędzający oraz akwizycję danych z zamontowanych akcelerometrów. Na poniższym zdjęciu widnieje stanowisko ze schematu na Rysunku 2, wyróżniono na nim akcelerometry oraz mikrofon, z których pobierane są dane w trakcie pracy układu i wymianie badanych łożysk.

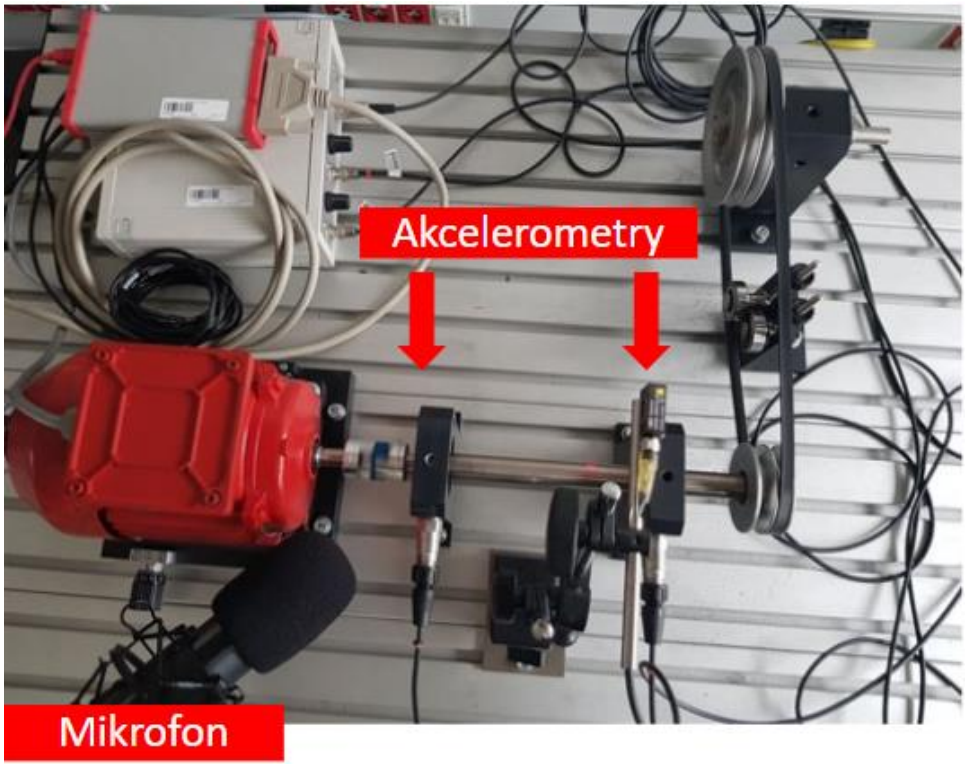

Rysunek 3. Zdjęcie stanowiska badawczego w konfiguracji do diagnostyki uszkodzeń łożysk.

Do badań wykorzystano 6 typów łożysk oznaczonych kolejno A-F, gdzie łożysko A nie jest uszkodzone, B posiada uszkodzenie bieżni zewnętrznej, C uszkodzenie bieżni wewnętrznej, D uszkodzenie kulki, E połączenie uszkodzeń bieżni wewnętrznej, zewnętrznej oraz kulki, a łożysko F posiada całkowicie zużytą bieżnię wewnętrzną i zewnętrzną. Oprócz ww. łożysk, pozostałe posiadają uszkodzenia kulek, bieżni oraz defekty łączone. Ostatecznie posiadamy jedno sprawne łożysko, a pozostałe zawierają pewne wady. Do zaimplementowania algorytmu wystarczy łożysko A, w celu zebrania informacji na temat poprawnej pracy, a następnie monitorowaniu w trakcie eksploatacji.

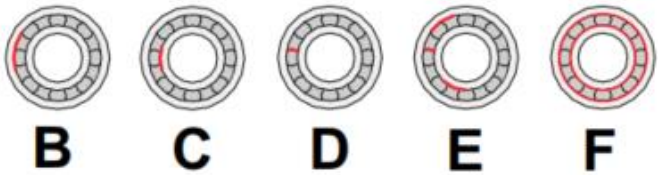

Rysunek 4. Oznaczenia poszczególnych łożysk wraz z wizualizacją uszkodzeń. Łożyska A nie zawarto na powyższym rysunku, ponieważ nie posiada ono defektów, które można zaklasyfikować jako poważne. Adapted from: Test stand scheme from PT500_12e - V1.1 documentation GUNT

Za pomocą zestawu do akwizycji danych, który znajduje się w lewym górnym rogu na Rysunku 3, zebrano dane z akcelerometrów przy użyciu odpowiedniego oprogramowania. Ścieżki dźwiękowe podczas diagnostyki poszczególnych łożysk, zostałby pobrane za pomocą mikrofonu podłączonego do urządzenia pomiarowego. Kontrole procesem akwizycji danych miała jednostka NAZCA Edge, która podłączona była do układu pomiarowego.

Do implementacji algorytmu wymagane są dane z łożyska bez uszkodzeń, ponieważ w opisywanym rozwiązaniu należy nauczyć system poprawnej pracy urządzenia. System ten następnie zbiera dane w czasie rzeczywistym z monitorowanego stanowiska i określa jak bardzo aktualny stan odbiega od tego, który został zdefiniowany na początku. Dane z uszkodzeń służą do walidacji systemu, czyli określenia skuteczności wykrywania poszczególnych uszkodzeń.

Przy założeniu, że dane są próbkowane z częstotliwością 22kHz zarówno dla akcelerometru, jak i mikrofonu, określono wielkość zbioru danych dla każdego z łożysk, jako 10 minutowe nagranie. Zbiór danych dla łożyska A powinien być reprezentatywny tzn., że musi zawierać odpowiednią ilość danych, uwzględniającą różne warunki pracy. W tym przypadku jest to doświadczenie na stanowisku laboratoryjnym, natomiast w rzeczywistości proces zbierania danych powinien zostać zaplanowany najlepiej na kilka dni, w których np. dwa razy na godzinę dokonywana jest akwizycja danych z akcelerometrów. Na rzeczywistym obiekcie jest to istotne, ze względu wpływ pozostałych obiektów na monitorowane urządzenie oraz na jego różne tryby pracy.

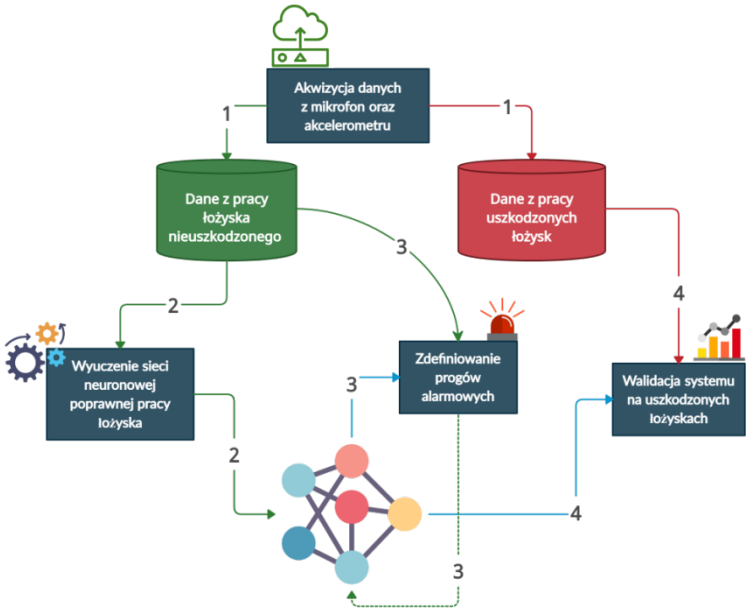

Rysunek 5. Poszczególne kroki występujące w procesie implementacji oraz walidacji systemu wykrywania anomalii. Liczby pomiędzy poszczególnymi blokami oznaczają poszczególne etapy.

Na Rysunku 4 zaprezentowano cały proces implementacji systemu wykrywania anomalii, który zaczyna się od akwizycji danych z poprawnie pracującego urządzenia, następnie na podstawie tego zbioru trenowany jest odpowiedni algorytm, który wyucza się charakterystycznych cech sygnału. W kolejnym kroku definiowany jest próg alarmowy, którego przekroczenie będzie świadczyło o wystąpieniu anomalii. Ostatecznie, na podstawie wyznaczonego progu alarmowego, algorytm jest poddawany procesowi walidacji. Wykorzystując dane z uszkodzonych łożysk sprawdzana jest poprawność wykrywania

anomalii dla mniejszych oraz większych defektów, w sposób zero-jedynkowy, a także drugi określający jak bardzo dane uszkodzenie odbiega od poprawnej pracy.

3. Wyniki badań

W niniejszym badaniu przeprowadzono weryfikację skuteczności działa algorytmu na danych oddzielonych od zbioru treningowego, czyli takich, których algorytm nie przetwarzał w procesie uczenia. Próbki danych testowych zapewniono dla łożyska sprawnego, a także dla poszczególnych uszkodzeń, badanych w tym doświadczeniu. Na poniższym histogramie przedstawiono błędy odwzorowania, obliczone dla zbioru testowego, dla poszczególnych uszkodzeń. Im bardziej rozkład błędu odwzorowania dla danego łożyska jest przesunięty w prawo, tym bardziej diagnozowany element odbiega od wyuczonego wzorca.

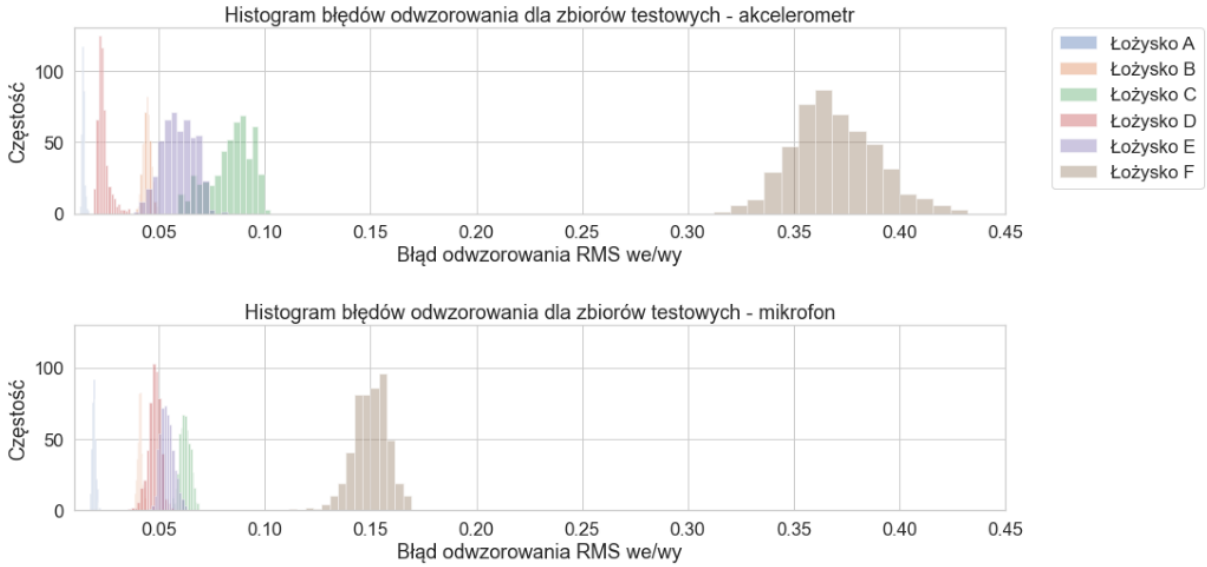

Rysunek 6. Wizualizacja histogramów wartości (błąd odwzorowania RMS we/wy), na podstawie której, pomiary klasyfikowane są jako anomalia, lub zgodne z poprawną pracą. Histogramy zwizualizowano dla danych z mikrofonu oraz akcelerometru.

Na powyższym rysunku 5 można zauważyć, że najbardziej oddalony w prawo rozkład jest dla łożyska F. Oznacza to, że częstotliwości badanego elementu mechanicznego, odbiegają najbardziej od tych, do których algorytm został wyuczony. Sytuacja ta jest podobna zarówno dla akcelerometru, jak i dla danych pochodzących z mikrofonu. Dla akcelerometru błąd odwzorowania jest bardziej oddalony w prawo, niż dla dźwięku, to znaczy, że algorytm znalazł więcej odbiegających częstotliwości od poprawnej pracy, niż dla dźwięku, który mógł być zakłócony poprzez pracę innych urządzeń w laboratorium.

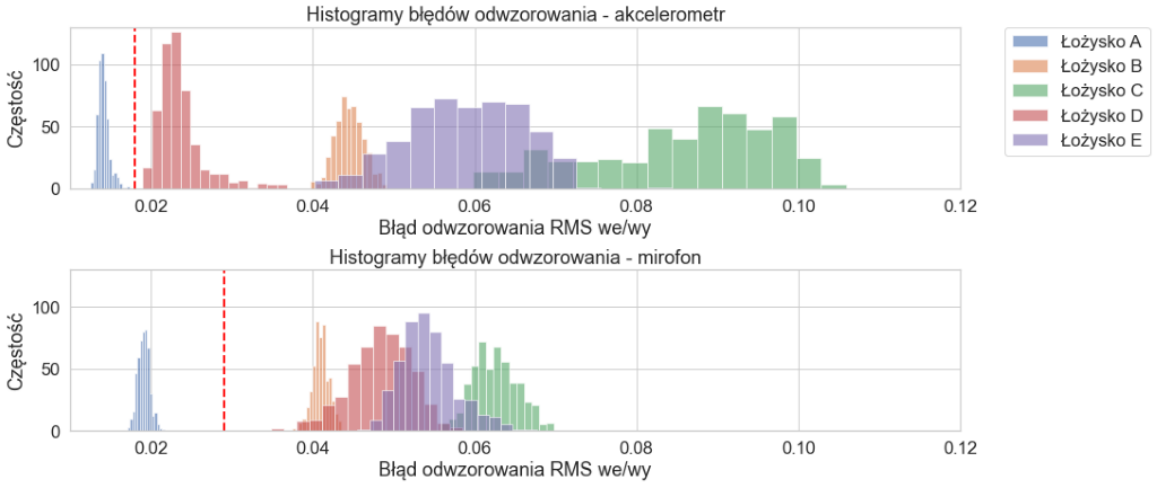

Rysunek 7. Wizualizacja histogramu błędu odwzorowania RMS we/wy, z wyłączeniem łożyska F. Czerwoną przerywaną linią zaznaczono wartość progową, powyżej której dane łożyska klasyfikowane są jako anomalia.

W przeciwieństwie do rozkładu łożyska F, wszystkie pozostałe znajdują się znacznie bliżej odpowiadającemu danym z nieuszkodzonego łożyska A. Dla danych z mikrofonu, poszczególne uszkodzenia praktycznie pokrywają się ze sobą, gdzie w przypadku akcelerometru pokrycie aż w takim stopniu nie występuje (Rysunek 6).

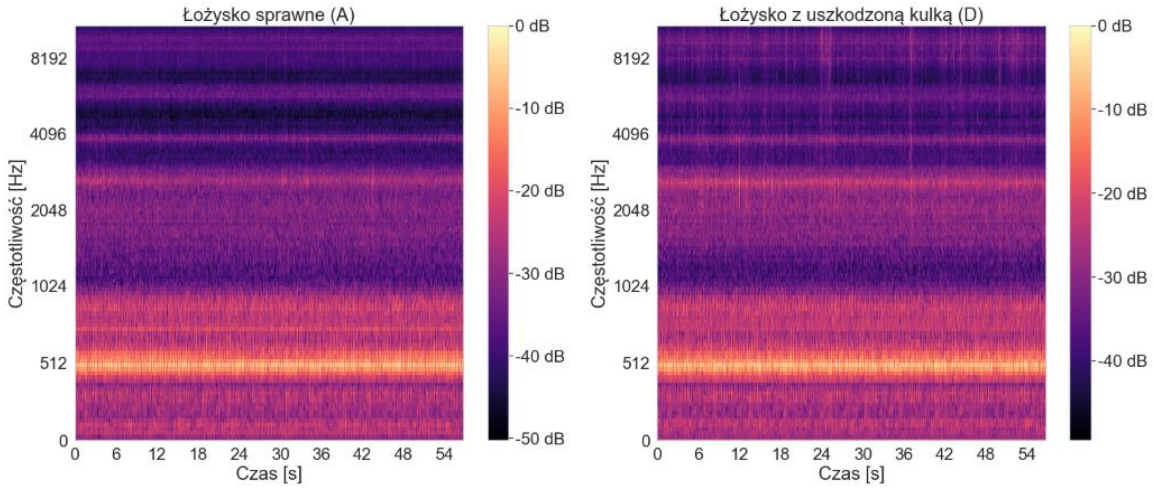

Rysunek 8. Porównanie spektrogramów łożyska sprawnego i z uszkodzoną kulką, dla pomiarów otrzymanych za pomocą akcelerometru.

Warto zwrócić uwagę na łożysko D, w którym uszkodzona jest kulka – w przypadku akcelerometru rozkład tego łożyska znajduje się bardzo blisko rozkładu poprawnej pracy, a więc częstotliwości charakteryzujące ten właśnie element mechaniczny, nie różnią się w aż tak w dużym stopniu, jak w porównaniu np. do łożyska C, w którym uszkodzony jest bieżnia wewnętrzna. Podobieństwo częstotliwości dla dwóch opisanych przypadków zaprezentowano na rysunku 7. W niektórych miejscach spektrogramu łożyska D można zauważyć częstotliwości świadczące o uszkodzonej kulce.

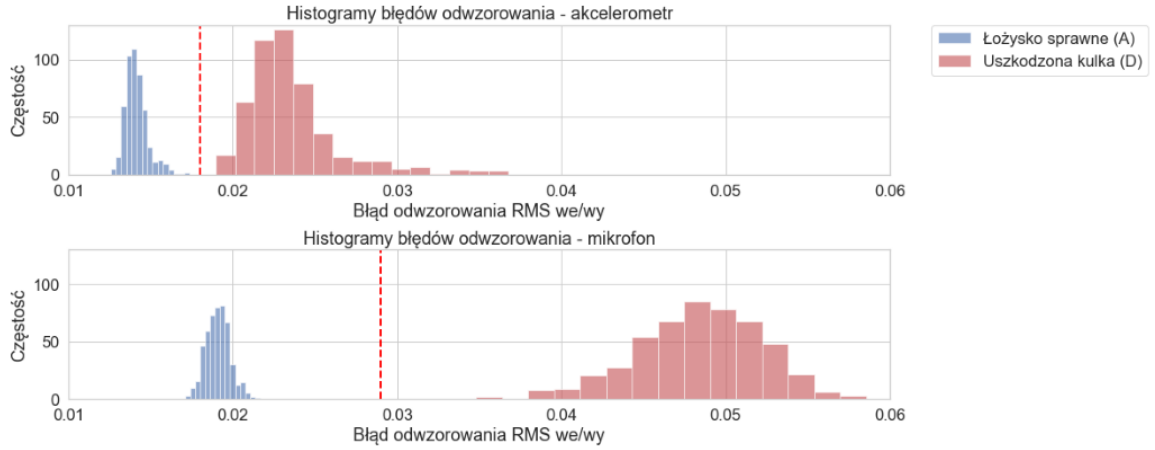

Rysunek 9. Wizualizacja histogramu błędu odwzorowania RMS we/wy, dla łożyska sprawnego oraz drugiego, posiadającego uszkodzoną kulkę - porównanie danych z akcelerometru oraz mikrofonu.

Na rysunku 8 widać, że nawet w najbardziej skrajnym przypadku dla akcelerometru, na podstawie czerwonej przerywanej linii, która oznacza próg alarmowy, jesteśmy w stanie odseparować pomiary będące anomaliami od poprawnie pracującego łożyska. Z kolei dla mikrofonu, to uszkodzenie, jak i inne, są lepiej oddzielone od poprawnej pracy urządzenia.

Histogram błędu odwzorowania, obliczony na podstawie danych z akcelerometru dla łożyska sprawnego jest bliższy wartości zero niż dla danych pochodzących z mikrofonu. Oznacza to, że algorytm był w stanie lepiej się wyuczyć danych z akcelerometru, powodem tego zjawiska prawdopodobnie jest szum zbierany przez mikrofon.

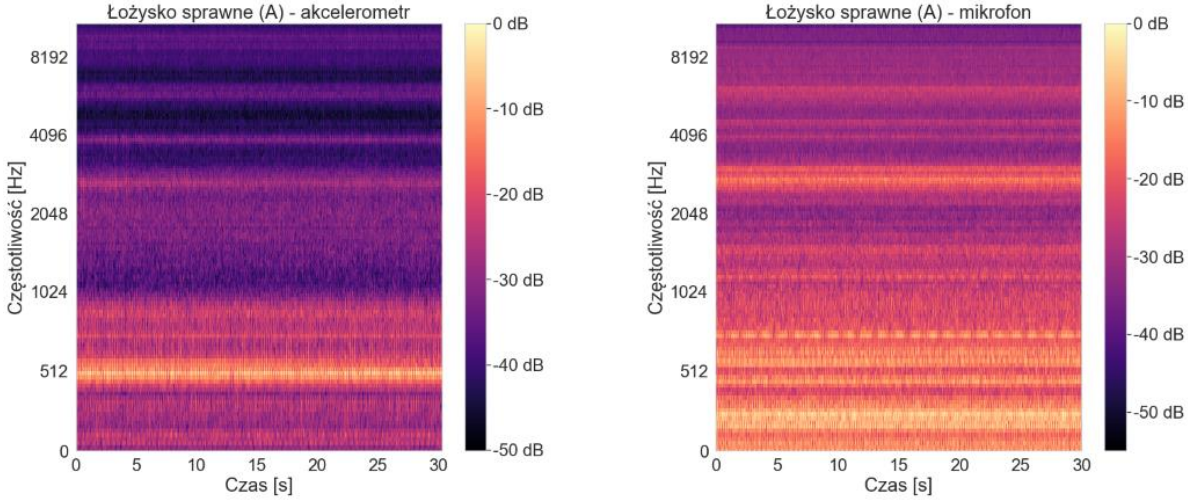

Rysunek 10. Porównanie spektrogramów łożyska sprawnego dla pomiarów otrzymanych za pomocą akcelerometru oraz mikrofonu.

Po walidacji algorytmu na danych zebranych w trakcie pracy łożysk, uzyskano 100% skuteczność klasyfikacji anomalii, dla wszystkich diagnozowanych uszkodzeń. Należy zaznaczyć, że analizowane dane zebrano w warunkach laboratoryjnych i w rzeczywistości te wyniki mogą się znacznie różnić.

4. Podsumowanie

Zapewnienie informacji serwisowej na temat zbliżającej się naprawy danego urządzenia, określonej na podstawie analityki danych, usprawnia proces planowania i zmniejsza koszty akcji serwisowych, które dokonywane były okresowo – serwisowanie urządzenia, w momencie, gdy faktycznie jest to wymagane.

W niniejszym artykule zastosowanie systemu do wykrywania anomalii zostało zaprezentowane na przykładzie analizy drganiowej łożysk kulkowych. Niemniej jednak, ten sam algorytm może zostać wykorzystany do różnego typu danych, bez względu na częstotliwość próbkowania. W przypadku danych z akcelerometru, czy też mikrofonu, wstępne przetwarzanie danych (zanim zostaną przesłane do sieci neuronowych) będzie się różniło od przetwarzania np. zmiennych procesowych lub pomiarów temperatury.

Badania przeprowadzone na stanowisku diagnostycznym łożysk kulkowych, pozwoliły na zaimplementowanie algorytmu, który może być wykorzystany do dowolnego typu danych. W celu weryfikacji algorytmu porównano dźwięk zarejestrowany przez mikrofon, z drganiami pobranymi przez akcelerometr. Charakter adaptacyjny podejścia pozwala na wytrenowanie modelu zarówno do pracy fabrycznie nowego urządzenia, jak i takiego, które od dłuższego czasu jest w produkcji i po akcji serwisowej określono jego stan jako zgodny z normą.

Zaletą zaproponowanego rozwiązania jest łatwość monitorowania parametrów maszyny zarówno w trybie online, jak i wsadowo. Prezentowane podejście umożliwia wskazanie odstępstw od poprawnej pracy, które zarejestrowano na łożysku kulkowym, co stanowi ważną informacje dla sekcji serwisowej mówiącą o potencjalnym wystąpieniu uszkodzenia lub postępującym procesie degradacji elementu. Wczesne wykrycie anomalii może zapobiec nieplanowanym przestojom linii produkcyjnej, do których może dojść przez ignorowanie występujących odstępstw w pracy danego urządzenia.

Podejście przedstawione w artykule, a także inne, które prowadzone są w APA Group, pozwalają na wdrażanie narzędzi, które mają za zadanie wspierać proces wnioskowania, poprzez wyciąganie informacji z danych, które są cenne z punktu widzenia zarządzania i jakości produkcji.

Bibliografia

1. Albers A., Gladysz B., Pinner T., Butenko V., Stürmlinger T. (2016), Procedure for Defining the System of Objectives in the Initial Phase of an Industry 4.0 Project Focusing on Intelligent Quality Control Systems, "Procedia CIRP", Vol. 52. DOI: 10.1016/j.procir.2016.07.067.
2. Alcacer, V.; Cruz-Machado, V. Scanning the Industry 4.0: A Literature Review on Technologies for Manufacturing System. Eng. Sci. Technol. Int. J. 2019, 22, 899–919. Retrived from: https://reader.elsevier.com/reader/sd/pii/S2215098618317750?token=AB6D8DE2B63AF115D6B64DC4FD2F947A93E4F7C829B91BD0460ED21375C541705766EDBF5CF63C6C7F2F424835BFA719
3. Ciukaj J. (2020). Analiza przyczyn powstawania i opracowanie sposobu zapobiegania występowania wad w procesie produkcji plastikowych części samochodowych. *Management and Quality-Zarządzanie i Jakość*, *Vol. 2,* No 4, pp-pp. Retrived from http://zij.edu.pl/wp-content/uploads/2020/12/Ciukaj-J..pdf
4. Fidali, M. (2020). *Metody diagnostyki maszyn i urządzeń w predykcyjnym utrzymaniu ruchu*. Katowice: Elamed Media Group.
5. Grabowska S. and Sieka K. (2019). Inteligentne fabryki Przemysłu 4.0. *Management and Quality-Zarządzanie i Jakość*, *Vol. 1, No* 1, pp-pp. Retrived from http://zij.edu.pl/wp-content/uploads/2020/09/S.-Grabowska-K.-Sieka.pdf
6. Marin, F B, C Solomon, and M Marin. "Bearing Failure Prediction Using Audio Signal Analysis Based on SVM Algorithms." IOP Conference Series: Materials Science and Engineering 485 (March 27, 2019): 012012. https://doi.org/10.1088/1757-899X/485/1/012012.
7. Mathew, J., and R. J. Alfredson. "The condition monitoring of rolling element bearings using vibration analysis." Journal of Vibration and Acoustics 106.3 (1984): 447-453.
8. Pawlak M.: Zastosowanie analiz sygnałów akustycznych do wykrywania uszkodzeń wirników i łożysk w silnikach indukcyjnych. „Zeszyty Problemowe – Maszyny Elektryczne" 92/2011. http://www.komel.katowice.pl/ZRODLA/FULL/92/ref_35.pdf
9. Pollak, A., Hilarowicz, A., Walczak, M., and Gąsiorek, D., „A Framework of Action for Implementation of Industry 4.0. 398an Empirically Based Research", Sustainability, t. 12, nr 14, Art. nr 14, sty. 2020, doi: 10.3390/su12145789.
10. Ponierewski, A. (2019). *SPEED bez granic w cyfrowym świecie*. Amazon Digital Services.
11. Sader S., Husti I.,Daroczi M. (2017). Total Quality Management in the context of industry 4.0. Synergy International Conferences – Engineering, Agriculture and Green Industry Innovation Gödöllő, Hungary, October 16-19 (2017)
12. Stankovic, M.; Gupta, R.; Figueroa, J.E.; Calzadilla-Sarmiento, B.; Memedovic, O.; Authried, O.; Rueth, T. Industry 4.0. Opportunities Behind the Challenge, Background Paper, UNIDO 2017. Retrived from: https://www.unido.org/sites/default/files/files/201711/UNIDO%20Background%20Paper%20on%20Industry%204.0_27112017.pdf
13. Starczyński, J., and M. Sułowicz. "Wykrywanie uszkodzeń w silnikach indukcyjnych w oparciu o sygnały akustyczne." Maszyny Elektryczne : zeszyty problemowe Nr 4 (108) (2015). Retrived from http://yadda.icm.edu.pl/yadda/element/bwmeta1.element.baztech-41e6347a-9569-413f-87db-6ffcd793d456.
14. Tandon, N. "A comparison of some vibration parameters for the condition monitoring of rolling element bearings." Measurement 12.3 (1994): 285-289.
15. Zhong, Ray Y., Xun Xu, Eberhard Klotz, and Stephen T. Newman. "Intelligent Manufacturing in the Context of Industry 4.0: A Review." *Engineering* 3, no. 5 (October 1, 2017): 616–30. https://doi.org/10.1016/J.ENG.2017.05.015.
16. Zio, Enrico, and Giulio Gola. "A Neuro-Fuzzy Technique for Fault Diagnosis and Its Application to Rotating Machinery." *Reliability Engineering & System Safety*, Maintenance Modeling and Application, 94, no. 1 (January 1, 2009): 78–88. https://doi.org/10.1016/j.ress.2007.03.040.

Wyniki projektu pt.
„Opracowanie na drodze prac B+R platformy optymalizacji produkcji Nazca 4.0”
współfinansowanego ze środków EFRR w ramach RPO WSL na lata 2014-2020 (umowa nr UDA-RPSL.01.02.00-24-047G/19-00)