

MODEL ADAPTACYJNEGO ALGORYTMU WSPOMAGANIA DECYZJI W SYSTEMIE UTRZYMANIA RUCHU

Słowa kluczowe:

predykcyjne utrzymanie ruchu, modele predykcyjne, awarie sprzętu, diagnozowanie usterek

1. Wstęp

Observacje prowadzone w obszarze utrzymania ruchu wskazują, że większość przedsiębiorstw posiadających w swoich strukturach Służby Utrzymania Ruchu (SUR) prowadzi głównie naprawy maszyn i urządzeń po wystąpieniu awarii, przez co czas przeznaczony na prace serwisowe przewyższa czas poświęcony na planowane prace konserwacyjno-remontowe. Efektem takiego postępowania jest niski poziom efektywności eksploatacyjnej infrastruktury technicznej. Ciągłe występowanie awarii wpływa na redukcję produktywności, co z kolei pociąga za sobą straty finansowe przedsiębiorstwa. Działania mające na celu poprawę efektywności funkcjonowania przedsiębiorstwa powinny zatem uwzględniać między innymi eliminację marnotrawstwa, jakim jest nieefektywna praca maszyn i pracowników utrzymania ruchu.

Utrzymanie wysokiego poziomu efektywności wymaga zastosowania nowoczesnych rozwiązań wspierających monitorowanie procesów resztkowych, rozumianych jako procesy termiczne, tarciove, elektryczne oraz wibroakustyczne (drżania, hałas, pulsacja medium roboczego w maszynie), będące niejednokrotnie objawem bądź determinantą zużycia [1]. Wsparcie obejmuje poddawanie szczegółowej analizie rejestrowanych parametrów w celu uzyskania na ich podstawie informacji dotyczących stanu parku maszynowego. Oczekiwania przedsiębiorców wobec utrzymywania wysokiego poziomu niezawodności infrastruktury technicznej mogą zostać zrealizowane dzięki efektywnemu wdrożeniu nowoczesnego podejścia w obszarze gospodarki remontowo-konserwacyjnej, jakim jest predyktywne utrzymanie ruchu.

Pojawiający się w przedsiębiorstwach problem niewykorzystanych zbiorów danych pochodzących z systemów monitorujących stan techniczny parku maszynowego, a także informacje pochodzące z procesu produkcyjnego w perspektywie rozwijanej obecnie strategii predykcyjnego utrzymania ruchu stał się podstawą do opracowania nowego podejścia budowania systemów prognozujących awaryjność.

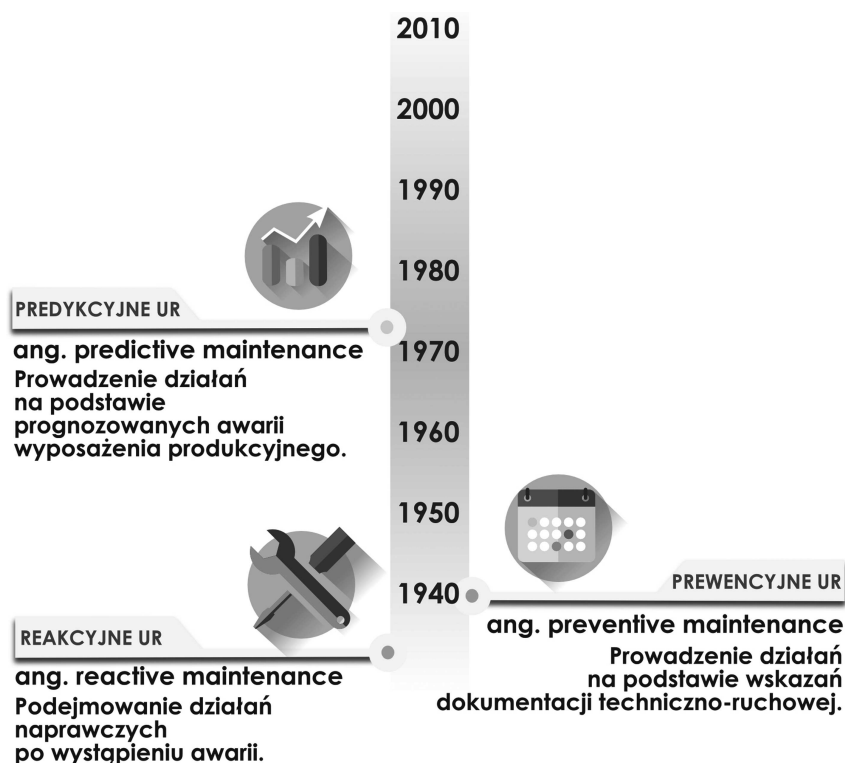
2. Predykcyjne utrzymanie ruchu

Wraz z pojawieniem się pierwszych maszyn produkcyjnych pojawił się problem związany z występowaniem awarii parku maszynowego. Początkowo prowadzone przez mechaników prace skupiały się jedynie na dokonywaniu napraw po awariach. Z biegiem lat następował rozwój stosowanych strategii utrzymania ruchu, które – oprócz pierwotnego celu, jakim było przywracanie pełnej sprawności maszyn i urządzeń po wystąpieniu awarii – obejmowały również działania wynikające z zapisów dokumentacji techniczno-ruchowej (zakres prewencyjnych konserwacji), a nawet podejmowanie działań w oparciu o stawiane prognozy.

Analiza sposobów podejmowania działań przez Służby Utrzymania Ruchu (SUR) pozwala dostrzec trzy główne strategie UR (rys. 1):

- reakcyjne utrzymanie ruchu (ang. *reactive maintenance*),
- prewencyjne utrzymanie ruchu (ang. *preventive maintenance*),
- predykcyjne utrzymanie ruchu (ang. *predictive maintenance*).

Rozwój technologii pomiarowych wpłynął na pojawienie się systemów monitorujących pracę parku maszynowego.



Rys. 1. Strategie utrzymania ruchu

W konsekwencji przedsiębiorstwa uzyskały możliwość pozyskiwania dużej ilości danych, które po zastosowaniu odpowiednich algorytmów, mogą stanowić cenne źródło informacji o kondycji infrastruktury technicznej.

Ciągłe dążenie do ulepszania procesów konserwacji zaowocowało powstaniem strategii predykcyjnego utrzymania ruchu (PdM – ang. *predictive maintenance*), polegającej na prognozowaniu awaryjności parku maszynowego w oparciu o m.in. pomiary temperatury [1], wibracji [1, 8, 14], hałasu [14], czy o informacje o układzie smarowania (m.in. ciśnienie, właściwości fizyczne czy skład chemiczny smaru/oleju) [9, 10, 12].

W ramach prowadzonych badań podejmowano działania polegające na prognozowaniu awarii parku maszynowego w oparciu o już istniejące bądź modyfikowane modele matematyczne służące predykcji zdarzeń. Badano zastosowanie regresji wielorakiej do prognozowania czasu trwania awarii koparek kołowych [7] oraz do prognozowania awaryjności systemu w elektrowni wodnej [5], gdzie dodatkowo weryfikowano prognozowanie awaryjności zmodyfikowaną metodą krigingu oraz metodą krigingu w połączeniu z sieciami neuronowymi. Wykorzystanie sztucznej inteligencji znalazło również zastosowanie do budowy systemu monitorującego stan złączy taśmowych w kopalni [6], skrzyni przekładniowej turbiny wiatrowej [3], łożysk tocznych [10] czy serwowo-mechanizmu agregatu prądotwórczego w elektrowni wodnej [1], do przewidywania awarii sprzętu telekomunikacyjnego wykorzystano algorytm genetyczny [13], zaś model ARIMA testowano do badań awaryjności śrubowej sprężarki wirnikowej [5].

Należy zaznaczyć, że skuteczność strategii predykcyjnego utrzymania ruchu jest zależna od poziomu wiedzy na poszczególnych etapach projektowania systemu prognozującego [4], jednak mimo to, w wielu przedsiębiorstwach

odnotowano wzrost efektywności eksploatacyjnej parku maszynowego po wdrożeniu PdM.

Wśród licznych argumentów przemawiających za osiągnięciem korzyści wynikających z wdrożenia predykcyjnego utrzymania ruchu, najczęściej wymieniane jest [4]:

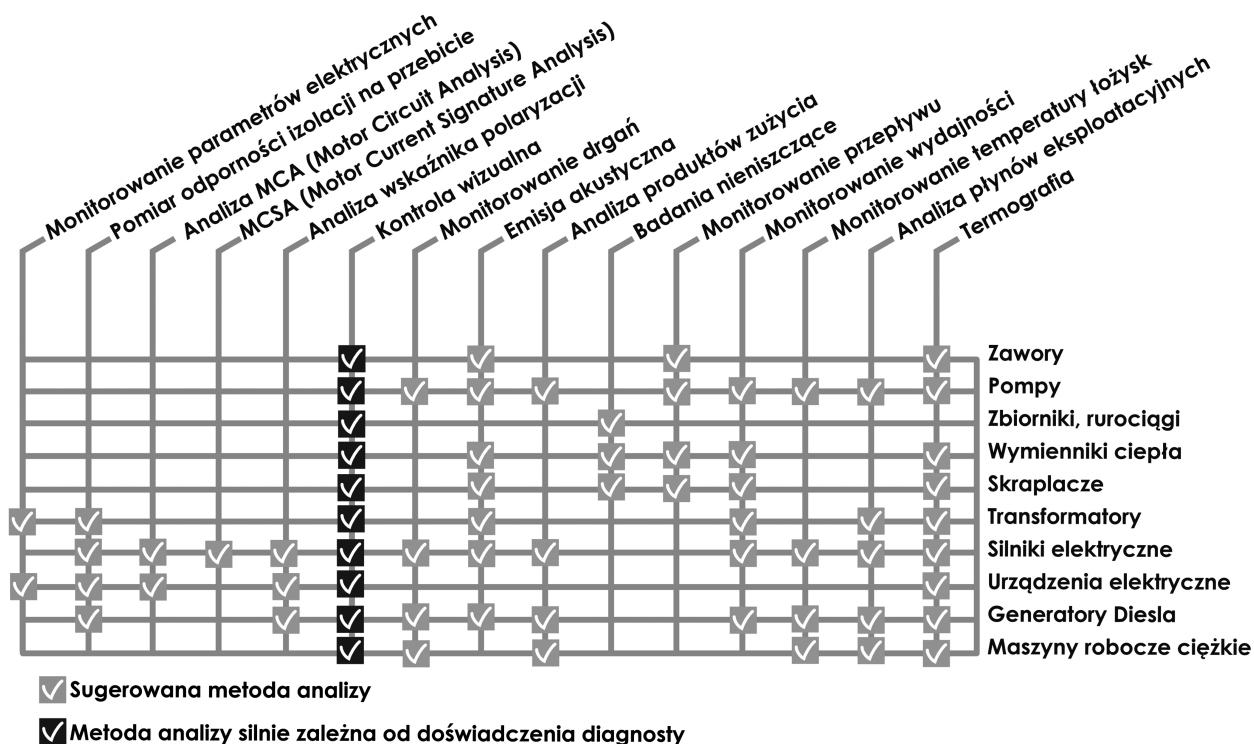
- zmniejszenie kosztów ponoszonych ze względu na pojawiające się awarie,
- zmniejszenie sumarycznego czasu przestoju,
- możliwość prowadzenia obserwacji parametrów pracy maszyny w czasie rzeczywistym,
- poprawa bezpieczeństwa pracy,
- skrócenie czasu naprawy maszyn i urządzeń,
- opracowanie procedur zapobiegających pogarszaniu się stanu maszyn i urządzeń.

Na rysunku 2. przedstawiono przykłady zastosowania niektórych metod monitorowania dla predykcyjnego utrzymania ruchu wybranych maszyn i urządzeń. Jak można zaobserwować, predykcja w diagnostyce różnorodnych maszyn i urządzeń może opierać się na różnych metodach analizy, które wybierane są w zależności od obserwowanego obiektu i warunków jego eksploatacji.

3. Oczekiwanie wobec systemu predykcji awarii

Predykcyjne utrzymanie ruchu jest podejściem do obsługi maszyn wzbudzającym zarówno zainteresowanie pracowników Służb Utrzymania Ruchu (ze względu na usprawnienie prowadzonych działań), jak i opory kadry zarządzającej (ze względu na obawy związane z ryzykiem inwestycyjnym).

Ze względu na wysoki stopień zaawansowania samych modeli predykcyjnych, jak i ilości danych poddawanych analizie (mowa tu o zbiorach wartości parametrów stanu, które można określić mianem tzw. zbiorów *big data*), opracowanie, a przede wszystkim wdrożenie systemu predykcyjnego



Rys. 2. Zastosowanie metod PdM w diagnostyce wybranych maszyn i urządzeń (na podstawie [4])

może stanowić olbrzymie wyzwanie dla przedsiębiorstw, zwłaszcza gdy na podstawie wskazań systemu byłyby podejmowane decyzje o realizowanych działaniach konserwacyjno-remontowych.

Pomimo tego, iż wdrożenie predykcyjnego utrzymania ruchu niesie wiele korzyści, właściwa staje się analiza oczekiwań wobec PdM związanymi z poszerzeniem obecnie funkcjonujących standardów takich systemów.

Opisywane w literaturze modele prognostyczne uwzględniają wyłącznie predykcję w oparciu o czynniki techniczne. Stosowane modele, chociaż wykorzystują rzetelne dane zapisywane automatycznie z systemów monitorujących pracę maszyn w czasie rzeczywistym, nie biorą pod uwagę aspektów nietechnicznych i cech jakościowych, które w literaturze przedmiotu są wskazywane jako czynniki rzutujące na niezawodność parku maszynowego. Jako aspekty nietechniczne rozumie się np. sezonowość czy kwestie natury ekonomicznej, natomiast cechy jakościowe są rozumiane jako m.in. stopień znajomości maszyny przez operatora, rzetelność przeprowadzonych konserwacji, czy wyniki audytu wdrożonych dobrych praktyk w ramach TPM (ang. *Total Productive Maintenance*). Nieujmowanie wymienionych czynników w stosowanych modelach predykcji awarii może wynikać z braku standardów ich wyrażania, zwłaszcza, że większość z nich z racji specyfiki ich opisu powinna być określona w formie lingwistycznej.

Chcąc uzyskać trafne prognozy mimo upływu czasu, koniecznym byłoby również uwzględnienie aspektu mającego wpływ na dokładność i rzetelność stawianych prognoz, którym jest starzenie się obserwowanego obiektu. Przegląd literatury [6, 7, 8, 15, 20] pozwala na sformułowanie wniosku dotyczącego istnienia silnego związku liczby uszkodzeń z czasem eksploatacji obiektu. Nie zauważono jednak, aby dotychczas stosowane modele predykcji awarii uwzględniały ten fakt na etapie stawiania prognoz. Właściwe byłoby zatem budowanie prognozy i wnioskowanie o awaryjności również w funkcji zmian częstotliwości występowania awarii wynikającej z okresu eksploatacji.

Wykorzystanie do generowania prognozy i podejmowania decyzji o czasie przeprowadzenia konserwacji tak wielu czynników, mających wpływ na niezawodność maszyn, daje bez wątpienia podstawę do budowy systemu ekspertowego, który zastąpi człowieka na etapie doboru metody predykcji w zależności od rodzaju parametrów wejściowych, jak i na etapie podjęcia decyzji o momencie realizacji działań naprawczych.

W dobie nowoczesnych technologii pomiarowych łączących się poprzez sieć z systemami bazodanowymi i zapisujących w nich wartości parametrów pracy maszyn, należy uwzględnić konieczność tworzenia narzędzi do analizy gromadzonych danych w tzw. zbiorach *big data*, które coraz częściej są traktowane jako źródło ukrytej wiedzy. Ta wiedza, z racji charakteru oraz częstotliwości zapisu wyników pomiarów, może być pozyskana jedynie dzięki wnikliwej analizie przy wykorzystaniu systemów informatycznych z wbudowanymi modelami matematycznymi. Dynamiczny charakter zmieniających się wartości parametrów, jak i specyfika funkcjonowania przedsiębiorstw, narzuca sposób podejścia do budowy modelu prognostyczno-decyzyjnego, który powinien również w sposób dynamiczny reagować

na zmieniające się warunki produkcji. Mowa tu o stawianiu prognozy i podejmowaniu decyzji natychmiast po otrzymaniu przez system odczytu z systemów pomiarowych.

Prognoza wygenerowana na podstawie wartości wejściowych (aspektów technicznych, nietechnicznych, cech jakościowych) dostarcza informacji o możliwości wystąpienia awarii w określonym przedziale czasu. Wyznaczenie terminu przeprowadzenia konserwacji powinno przebiegać przy zastosowaniu odpowiednich algorytmów decyzyjnych uwzględniających informacje dotyczące planu produkcji, harmonogramu prac SUR oraz czasu oczekiwania na części zamienne. Zastosowanie wielokryterialnego wspomaganie podejmowania decyzji pozwoli na wyłączenie czynnika ludzkiego opierającego się niejednokrotnie na intuicji, a nie na danych pochodzących wprost z procesu produkcyjnego. Konstruowanie skomplikowanych modeli prognostyczno-decyzyjnych przysparza wiele problemów we wstępnych etapach projektowych związanych z budową systemów predykcyjnych, jednak właściwym wydaje się być podejście skłaniające do podjęcia prac związanych z włączeniem wskazanych czynników w budowę prognoz awaryjności parku maszynowego. Ponadto wyłączenie człowieka z procesu decyzyjnego i zastąpienie go opracowanymi algorytmami czerpiącymi informacje z procesu produkcyjnego pozwoli na precyzyjne wyznaczenie optymalnego terminu realizacji prac SUR.

4. Koncepcja adaptacyjnego algorytmu wspomaganie decyzji w systemie utrzymania ruchu

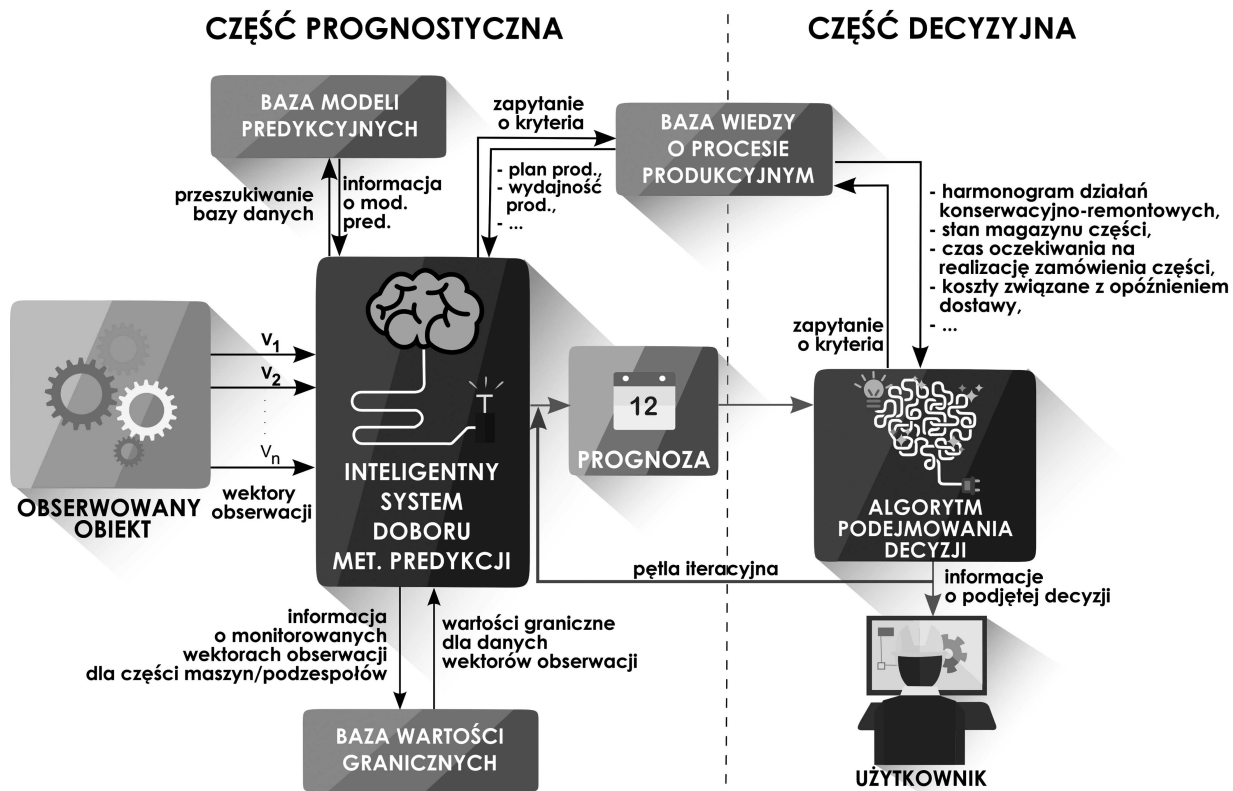
Proponowane dotychczas rozwiązania w obszarze predykcyjnego utrzymania ruchu skupiają się na zaimplementowaniu wybranego modelu matematycznego i stosowaniu go do generowania prognoz na podstawie monitorowanych procesów resztkowych. Włączenie do procesu prognozowania dodatkowych danych wejściowych obejmujących, oprócz wartości procesów resztkowych chociażby aspekty techniczne czy jakościowe, pozwoli na uzyskanie bardziej dokładnych prognoz ze względu na poszerzenie zakresu obserwowanych czynników mających wpływ na występowanie awarii.

Rysunek 3. przedstawia proponowany model adaptacyjnego algorytmu wspomaganie decyzji w systemie utrzymania ruchu, który ma stanowić nowe podejście do samego prognozowania awaryjności, jak i sposobu wyznaczania terminów napraw.

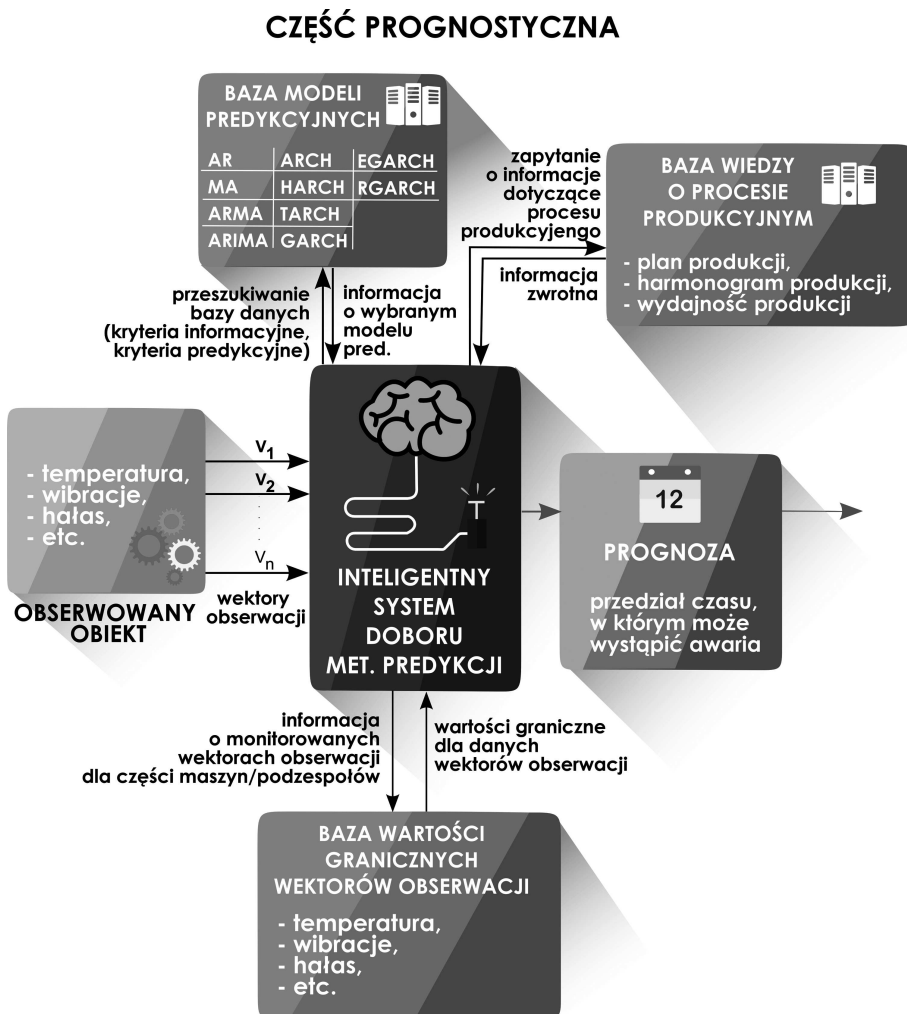
W modelu uwzględniono zarówno etap implementacji danych, generowanie prognoz w oparciu o bazy danych z zakresu modeli matematycznych, wartości granicznych wektorów obserwacji, jak i danych o procesie produkcyjnym, ale również zaznaczono proces decyzyjny opierający się na danych z zakresu produkcji oraz działań realizowanych przez SUR.

Rysunek 4. przedstawia rozwinięcie części prognostycznej modelu, zaś rysunek 5. prezentuje poszerzone ujęcie części decyzyjnej modelu.

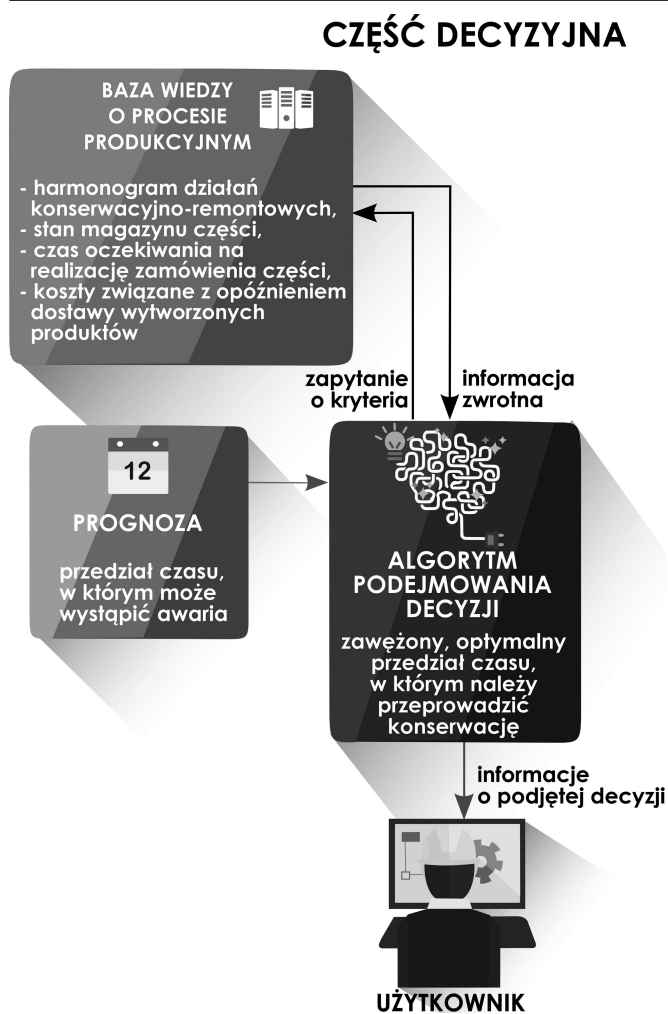
Informacje pochodzące z systemu monitorującego pracę obserwowanego obiektu, takie jak odczyty temperatury, wibracji czy natężenia hałasu, oznaczone na rysunku jako *wektory obserwacji*, trafiają do *inteligentnego systemu*



Rys. 3. Model adaptacyjnego algorytmu wspomaganie decyzji w systemie utrzymania ruchu



Rys. 4. Część prognostyczna modelu adaptacyjnego algorytmu wspomaganie decyzji w systemie utrzymania ruchu



Rys. 5. Część decyzyjna modelu adaptacyjnego algorytmu wspomaganie decyzji w systemie utrzymania ruchu

doboru metody predykcji. System w oparciu o kryteria informacyjne i predykcyjne wybiera z bazy danych zawierającej modele predykcyjne odpowiedni model służący do stawiania prognozy (AR, MA, ARMA, ARIMA, ARCH, HARCH, TARCH, GARCH, EGARCH lub RGARCH). Model matematyczny wybierany jest w sposób dynamiczny ze względu na występującą dynamikę zmian monitorowanych wektorów. Z tego względu należałoby uwzględnić opracowanie narzędzia, które na podstawie wartości kryteriów informacyjnych i predykcyjnych pozwoli na dobór optymalnego rozwiązania. Jako rozwiązanie optymalne, rozumiany jest model, który uzyskał ponad połowę wskazań przez wspomniane kryteria. Dodatkowo system jest połączony z *bazą wartości granicznych wektorów obserwacji*, która to określa bezpieczny poziom wielkości wektorów obserwacji dla poszczególnych części/podzespołów maszyn, po przekroczeniu którego wzrasta ryzyko wystąpienia uszkodzenia. Informacje o bezpiecznych wartościach procesów resztkowych powinny pochodzić z odpowiednich norm (np. PN-ISO 10816-1:1998 - *Drgania mechaniczne - Ocena drgań maszyny na podstawie pomiarów na częściach niewirujących - Wytyczne ogólne*) czy z badań eksperymentalnych.

Prognoza stawiana jest ponadto w oparciu o informacje pochodzące z *bazy danych o procesie produkcyjnym*, dotyczące planu, harmonogramu oraz wydajności produkcji. Uwzględnienie ich jako czynniki mające wpływ na awaryjność parku maszynowego pozwoli doprecyzować prognozę, uzależniając ją od warunków pracy maszyn – wszelkiego rodzaju przerwy w produkcji lub planowane spadki wydajności, przyczynią się do przesunięcia w czasie potencjalnej awarii, co z kolei spowoduje wydłużenie czasu pomiędzy konserwacjami prowadzonymi przez Służby Utrzymania Ruchu. Wygenerowana przez system prognoza będzie jedynie przedziałem czasu, w którym istnieje ryzyko wystąpienia awarii i zostanie przesłana do drugiej części modelu, jaką jest część decyzyjna (rys. 5).

Część decyzyjna modelu składa się z *algorytmu podejmowania decyzji*, do którego trafia wygenerowana prognoza, a także z *bazy danych o procesie produkcyjnym*, która to tym razem będzie dostarczała informacji skupiających się na obszarze działań Służb Utrzymania Ruchu. Do przykładowych zakresów dostarczanych informacji należeć będzie harmonogram działań konserwacyjno-remontowych, stan magazynu części, czas oczekiwania na realizację zamówienia części, czy koszty związane z wystąpieniem opóźnień w realizacji produkcji.

Na podstawie takich informacji, algorytm będzie w stanie wygenerować zawężony optymalny przedział czasu, w którym konieczne jest przeprowadzenie konserwacji. Wielo-kryterialne podejście do kwestii ustalenia terminu pozwoli osobom odpowiedzialnym za przywracanie pełnej sprawności infrastruktury technicznej na elastyczne planowanie i harmonogramowanie prac naprawczych. Ponadto, przyczyni się do świadomego zarządzania magazynem części zamiennych maszyn i urządzeń oraz racjonalizacji prowadzonych zamówień.

5. Podsumowanie

Świadoma eksploatacja parku maszynowego jest odpowiedzią na zmieniające się warunki rynkowe, w których to terminowość realizowanych zamówień, a także utrzymywanie na tym samym poziomie jakości wytwarzanych produktów, wpływa na budowanie wizerunku firmy. Szukając zatem rozwiązań wspierających Służby Utrzymania Ruchu w zakresie działań dążących do zmniejszenia występowania awarii parku maszynowego, przedsiębiorstwa mają coraz szerszą możliwość korzystania z rozwiązań opierających się na koncepcji predykcyjnego utrzymania ruchu. Za wdrożeniem takiej strategii przemawia również fakt, iż coraz więcej maszyn i urządzeń wyposażonych jest w systemy monitorowania parametrów pracy, dzięki czemu przedsiębiorstwa stają się właścicielami ogromnych zbiorów danych (tzw. *big data*), które zawierają szczegółowe informacje o zmieniającej się sprawności infrastruktury technicznej.

Istniejące obecnie systemy predykcyjnego utrzymania ruchu opierają się na wnioskowaniu o przyszłych zdarzeniach na podstawie monitorowanych procesów resztkowych z wykorzystaniem narzuconego modelu predykcyjnego. Pomimo korzyści, jakie przynoszą przedsiębiorstwom po ich wdrożeniu (jak chociażby oszczędności będące efektem

uniknięcia awarii), konieczne jest zwrócenie uwagi na brak elastycznego dopasowania modelu do zmieniających się w sposób dynamiczny wartości wektorów obserwacji (z racji prowadzonych w czasie rzeczywistym odczytów), który może dostarczyć bardziej trafne prognozy.

Zaproponowany model adaptacyjnego algorytmu wspomaganie decyzji w systemie utrzymania ruchu może stać się alternatywnym podejściem do tematyki predykcji awarii parku maszynowego ze względu na możliwość dopasowania się do zmieniającego się w czasie rzeczywistym charakteru monitorowanych parametrów.

Wbudowany w część prognostyczną modelu algorytm analizy części deterministycznej pozwoliłby uniknąć odgórnego narzucenia modelu predycyjnego wyznaczającego przyszłe wartości monitorowanych parametrów i pozwoliłby na jego dobór w zależności od wyników analizy świadczącej o heteroskedastyczności i homoskedastyczności ciągu. Z powodu występowania sytuacji, w której istnieje możliwość zastosowania kilku modeli stacjonarnych (ma to miejsce dla ciągu homoskedastycznego – AR, MA, ARMA oraz heteroskedastycznego – ARCH, HARCH, TARCH, GARCH, EGARCH, RGARCH), konieczne jest zastosowanie narzędzia wspomagającego wybór optymalnej metody w oparciu o wyniki kryteriów informacyjnych i predycyjnych.

Postawienie prognozy i przekazanie jej do algorytmu decyzyjnego, który będzie korzystał z informacji dotyczących produkcji oraz funkcjonowania Służb Utrzymania Ruchu, pozwoli wyłączyć czynnik ludzki z etapu ustalenia optymalnego terminu przeprowadzenia konserwacji.

Predycyjne utrzymanie ruchu zyskuje coraz większą liczbę zwolenników, jednak wciąż wielu przedsiębiorcom brakuje dojrzałego podejścia do gromadzonych, a nieprzetworzonych danych. Nabycie świadomości o znaczeniu posiadanych zbiorów będących źródłem wiedzy o posiadanym parku maszynowym może przynieść przedsiębiorstwom korzyści nie tylko pod względem wizerunkowym, lecz przede wszystkim ekonomicznym. Proponowane rozwiązanie oparte na koncepcyjnym modelu adaptacyjnego algorytmu wspomaganie decyzji w systemie utrzymania ruchu stanowi nowatorskie podejście i może stać się alternatywą dla stosowanych dotychczas systemów predycyjnych.

Literatura:

- [1] Cempel Cz., *Diagnostyka wibroakustyczna maszyn*. PWN, Warszawa 1989.
- [2] Chuang F., Luqing Y., Liu Y., Ren Y., Benoît I., Yuan-chu Ch., *Predictive maintenance in intelligent-control-maintenance-management system for hydroelectric generating unit*. "IEEE Transactions on Energy Conversion" 19(1)/2004, pp. 179-186.
- [3] Fidali M., *Ultradźwięki w diagnostyce i eksploatacji łożysk tocznych*. „Utrzymanie Ruchu” 1/2015, s. 56-61.
- [4] Garciaa M. C., Sanz-Bobia M.A., Del Picob J., *Simap: Intelligent System for Predictive Maintenance: Application to the health condition monitoring of a wind-turbine gearbox*. "Computers in Industry" 57 (6)/2006, pp. 552-568.
- [5] Hetmańczyk M., *Predycyjne utrzymanie ruchu*. „Inżynieria & Utrzymanie Ruchu” 1/2015, s. 60-64.
- [6] Kaźmierczak J., *Zastosowanie liniowych modeli procesów losowych do prognozowania w diagnostyce maszyn*. Rozprawa habilitacyjna. Politechnika Śląska, Gliwice 1989.
- [7] Legutko S., *Eksploatacja maszyn*. Wydawnictwo Politechniki Poznańskiej, Poznań 2007.
- [8] Legutko S., *Podstawy eksploatacji maszyn i urządzeń*. Podręcznik. WSiP, Warszawa 2008.
- [9] Lipski J., *Diagnostyka procesów wytwarzania*. Politechnika Lubelska, Lublin 2013.
- [10] Lucifredi A., Mazziari C., Rossi M., *Application of multiregressive linear models, dynamic kriging models and neural network models to predictive maintenance of hydroelectric power systems*. "Mechanical Systems and Signal Processing" 14(3)/2000, pp. 471-494.
- [11] Mazurkiewicz D., *Studium wybranych aspektów diagnostyki eksploatacyjnej transportu taśmowego*. Politechnika Lubelska, Lublin 2011.
- [12] Rogalska M., *Prognozowanie czasu trwania awarii koparek kołowych z zastosowaniem metod sieci neuronowych, regresji wielorakiej i ARIMA*. Cz. 1. Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach 97/2012, s. 433-448.
- [13] Sobieski W., *Stanowisko laboratoryjne do badania zjawiska kawitacji metodą wibroakustyczną*. „Diagnostyka” 32/2004, s. 37-42.
- [14] Szafranski B., *Filtracja olejów sposobem na bezawaryjną pracę maszyn*. „Inżynieria & Utrzymanie Ruchu” 2/2015, s. 48-52.
- [15] Sze-Jung Wu, Gebraeel N., Lawley M.A., Yih Y., *A Neural Network Integrated Decision Support System for Condition-Based Optimal Predictive Maintenance Policy*. "IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans" 37/2007, pp. 226-236.
- [16] Tabaszewski M., *Wielosymptomowa prognoza stanu i czasu do awarii z wykorzystaniem sieci neuronowych*. „Diagnostyka” 42/2007, s. 43-48.
- [17] Tabaszewski M., Cempel C., *Zastosowanie teorii szarych systemów do modelowania i prognozowania w diagnostyce maszyn*. „Diagnostyka” 42/2007, s. 11-18.
- [18] Walczak M., *System utrzymania ruchu czynnikiem przewagi konkurencyjnej przedsiębiorstwa*, [w:] *Historia i perspektywy nauk o zarządzaniu*, red. B. Miłkuła. Fundacja Uniwersytetu Ekonomicznego w Krakowie, Kraków 2012.
- [19] Weiss G.M., *Timeweaver: a Genetic Algorithm for Identifying Predictive Patterns in Sequences of Events*. "Proceedings of the Genetic and Evolutionary Computation Conference" 1999, pp. 718-725.
- [20] Żabicki D., *Zastosowanie kamer termowizyjnych*. „Monitorowanie i Diagnostyka” 2/2014, s. 16-19.
- [21] Żółtowski B., Niziński S., *Modelowanie procesów eksploatacji maszyn*. Bydgoszcz – Sulejówek 2002.

A MODEL OF ADAPTIVE ALGORITHM FOR MAINTENANCE DECISION SUPPORT SYSTEM

Key words:

predictive maintenance, predictive models, equipment failure, fault diagnosis

Abstract:

Currently used predictive maintenance systems predict future events by monitoring residual processes using the enforced predictive model. Despite the benefits resulting from their implementation in companies (e.g. savings resulting from preventing failure), it is necessary to draw attention to the fact that such models lack flexibility in adapting to the dynamically changing values of observation vectors due to real-time readout which can provide more accurate predictions.

The paper proposes a model of adaptive algorithm for maintenance decision support system which – depending on the changing parameters of residual processes – selects an adequate mathematical model based on predictive and informative criteria. Moreover, to produce more accurate predictions this model uses additional input data for prediction including values of residual processes as well as technical or quality-related aspects due to the extended range of observed factors that affect failure occurrence. The proposed model additionally contains a maintenance decision-related part which – based on the information about actions taken by maintenance services – generates a constrained optimal time interval for performing the necessary maintenance work.

Dr hab. inż. Dariusz Mazurkiewicz, prof. PL

mgr inż. Ewelina Kosicka

Politechnika Lubelska

Wydział Mechaniczny

Katedra Podstaw Inżynierii Produkcji

e.kosicka@pollub.pl

d.mazurkiewicz@pollub.pl

Dr inż. Arkadiusz Gola

Politechnika Lubelska

Wydział Zarządzania

Katedra Organizacji Produkcji a.gola@pollub.pl