

Mgr inż. Ewelina Kosicka

Wydział Mechaniczny
Politechnika Lubelska
ul. Nadbystrzycka 36, 20-618 Lublin
E-mail: e.kosicka@pollub.pl

Dr Edward Kozłowski

Wydział Zarządzania
Politechnika Lubelska
ul. Nadbystrzycka 38, 20-618 Lublin
E-mail: e.kozlovski@pollub.pl

Dr hab. inż. Dariusz Mazurkiewicz, prof. PL

Wydział Mechaniczny
Politechnika Lubelska
ul. Nadbystrzycka 36, 20-618 Lublin
E-mail: d.mazurkiewicz@pollub.pl

Wykorzystanie testów stacjonarności do analizy monitorowanych procesów resztkowych

Słowa kluczowe: *predykcja awarii, utrzymanie ruchu, testy stacjonarności, ADF, KPSS*

Streszczenie: Utrzymanie wysokiego poziomu efektywności eksploatacyjnej parku maszynowego wymaga stosowania nowoczesnych rozwiązań wspierających monitorowanie procesów resztkowych i poddawania szczegółowej analizie uzyskanych w ten sposób informacji. Naprzeciw oczekiwaniom przedsiębiorców dotyczących utrzymywania wysokiego poziomu niezawodności infrastruktury technicznej wychodzi nowoczesne podejście w obszarze gospodarki remontowo-konserwacyjnej, jakim jest predyktywne utrzymanie ruchu. W literaturze przedmiotu wielokrotnie prezentowano wykorzystanie różnych modeli statystycznych pozwalających na prognozowanie wartości szeregów czasowych. Celem niniejszej pracy było sprawdzenie czy stosowany w ekonometrii rozszerzony test Dickeya-Fullera oraz test Kwiatkowskiego, Phillipsa, Schmidta i Shina mogą zostać użyte do predykcji zdarzeń niepożądanych jakimi są awarie. Symulację przeprowadzono dla wartości jednego parametru diagnostycznego jakim była temperatura.

1. Wstęp

Dotrzymywanie zobowiązań wobec kontrahentów jest jednym z czynników wpływających na poziom efektywności eksploatacyjnej w przedsiębiorstwie. Zatem jednym ze strategicznych zadań firm jest punktualna dostawa produktów w określonej ilości i jakości. Zastosowanie nowoczesnych technologii wytwarzania oraz wysoki poziom skomplikowania procesów produkcyjnych pozwala na precyzyjną realizację zleconych zadań, ale także stanowi problem związany z utrzymaniem niezawodności wyposażenia produkcyjnego. Z tego powodu wzrasta znaczenie działań wspomagających prace działu utrzymania ruchu (UR) (wyposażenie produkcyjne musi być stale sprawne eksploatacyjnie poprzez kontrolę nad stanem technicznym maszyn i urządzeń). Jak definiuje Legutko [1], eksploatacja jest ogółem zjawisk, procesów, zdarzeń, jakie zachodzą w czasie istnienia urządzenia od chwili jego wyprodukowania do chwili jego kasacji. Pojęcie efektywności w odniesieniu do UR rozumiane jest jako właściwość ludzi bądź też obiektów technicznych, która opisuje spełnianie przez nich wymagań w różnym kontekście (m.in. niezawodnościowym, ekonomicznym czy jakościowym). Efektywność eksploatacyjna jest ilorazem efektów uzyskanych w ustalonym przedziale czasu trwania określonego stanu obiektu eksploatacji do nakładów poniesionych na uzyskanie tych efektów. Wzrost efektywności eksploatacyjnej maszyn poprzez przewidywanie awarii i przywracanie pełnej sprawności systemu produkcyjnego pozwala na terminową realizację zamówień, co z kolei przekłada się na efekty finansowe przedsiębiorstw. Jest to istotne zwłaszcza w warunkach ostrej konkurencji, gdzie ciągle doskonalenie systemów wytwarzania, rozwój stosowanych technologii oraz automatyzacja produkcji stanowi klucz do sukcesu przedsiębiorstwa.

Wzrost zainteresowania rozwijającą się wspólnie strategią predyktywnego utrzymania ruchu oraz pojawiający się w przedsiębiorstwach problem niewykorzystanych zbiorów danych pochodzących z systemów monitorujących pracę parku maszynowego stał się dla autorów podstawą do podjęcia działań zmierzających ku weryfikacji skuteczności przewidywania awarii przy wykorzystaniu testów stacjonarności. W przypadku wykrycia niepokojących objawów dodatkowo wyznaczono resztkowy czas pracy urządzeń. Sezonowe zmiany warunków otoczenia mogą negatywnie wpływać na wartości obserwowanych parametrów stanu, a tym samym na skuteczność prognoz opracowanych przy wykorzystaniu testów stacjonarności. W takim wypadku należy przedstawić założenia badanych sygnałów (w jaki sposób zmiana warunków otoczenia wpływa na wartości wektora obserwacji). Prowadzona symulacja zakłada utrzymanie stałych warunków temperaturowych otoczenia, stąd nie uwzględniono jej oddziaływania na niestacjonarność.

2. Wpływ działań podejmowanych w obszarze UR na efektywność eksploatacyjną

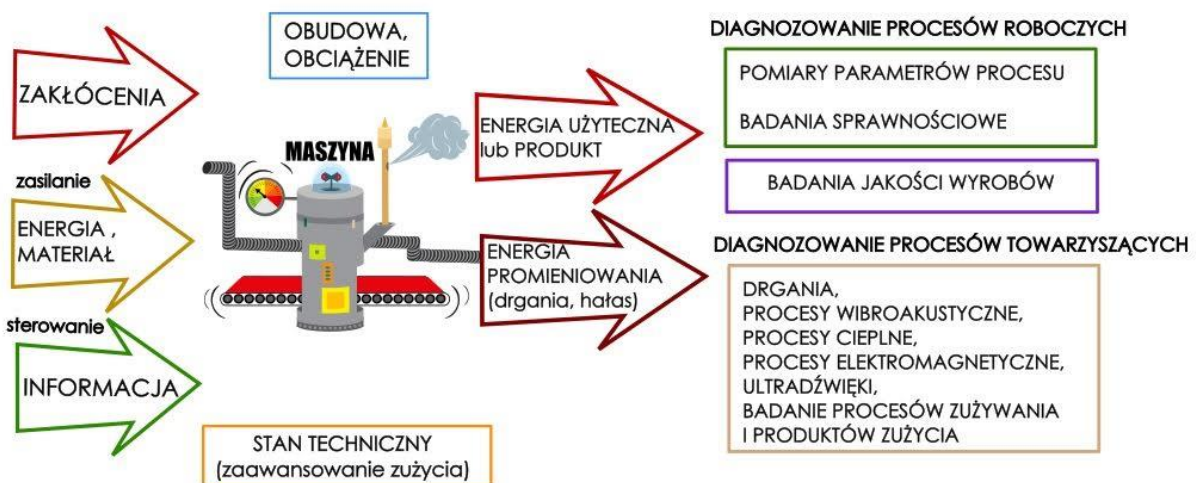
Obserwacje prowadzone w obszarze utrzymania ruchu pokazują, że w większości przedsiębiorstw dominuje podejście polegające na prowadzeniu napraw maszyn i urządzeń dopiero po awariach, w wyniku czego czas przeznaczony na prace reakcyjne przewyższa czas poświęcony na prace planowane. Skutkuje to obniżeniem poziomu efektywności

eksploatacyjnej. Ponadto zły stan infrastruktury technicznej ma wpływ na redukcję produktywności, generując przy tym dodatkowe straty. Działania podejmowane w ramach poprawy efektywności funkcjonowania przedsiębiorstw powinny zatem uwzględniać między innymi eliminację marnotrawstwa w postaci nieefektywnej pracy maszyn i pracowników utrzymania ruchu. Wskaźniki umieszczone w normie EN15341 [29], które pozwalają na określenie efektywności SUR, mogą stanowić pomoc w weryfikacji skuteczności realizowanych usprawnień [23]. Jednym z najbardziej popularnych wskaźników stosowanych w tym celu jest OEE (ang. Overall Equipment Effectiveness) [1,20,19]. Rozważania prowadzone nad poprawą funkcjonowania działu gospodarką remontowo-konserwacyjną wskazują dodatkowo na powiązania poziomu efektywności eksploatacyjnej z dobrem właściwej jego struktury [20,23].

Działania podejmowane na poziomie utrzymania ruchu mają na celu:

- zachowanie określonej jakości wyrobów/usług,
- maksymalne wydłużenie okresu użytkowania wyposażenia produkcyjnego,
- zapewnienie warunków pozwalających na bezpieczną eksploatację maszyn i urządzeń,
- zmniejszenie do minimum kosztów produkcji poprzez ograniczenie występowania przerw produkcyjnych.

Realizacja wymienionych działań może być dokonana po określeniu stanu maszyny lub procesu, który jest mierzony wielkościami fizycznymi. Zachowanie maszyn czy procesów produkcyjnych modeluje się równaniami stanu, które opisywane są za pomocą pewnych funkcji $f(t)$, $t \in T$, gdzie zmienna niezależna t jest zmienną czasową, natomiast T - przedziałem czasowym. Ustalenie stanu obiektu technicznego nazywamy diagnozowaniem. Rysunek 1 przedstawia schemat procesów, które występują w procesie produkcji oraz rodzaje diagnozowania procesów roboczych i towarzyszących.



Rys. 1 Schemat procesów występujących w maszynie i możliwości diagnozowania procesów roboczych i towarzyszących[1]

W procesach eksploatacyjnych występują zdarzenia losowe, źródłem których może być m.in. błąd człowieka, działanie środowiska naturalnego czy otoczenia eksploatacji.

Umiejętne modelowanie czynników losowych wpływających na zachowanie maszyn i procesów produkcyjnych pozwala zwiększyć efektywność eksploatacji takich obiektów [18,24]. Można zatem stwierdzić, że właśnie utrzymanie ruchu staje się jednym z kluczowych procesów, które bezpośrednio przyczynia się do wzrostu efektywności.

Na utrzymanie parku maszynowego w ciągłej sprawności ma wpływ odpowiednia jego konserwacja, stanowiąca podstawę prewencyjnego utrzymania ruchu. W przypadku tej strategii, decyzje o serwisowaniu maszyn podejmowane są w oparciu o dokumentację techniczno-ruchową. Rozwijająca się współcześnie strategia predyktywnego utrzymania ruchu [4] potwierdza słuszność wyznaczenia w trakcie realizacji procesu produkcyjnego momentów działań konserwacyjnych na podstawie stanu maszyn. Z tego powodu monitorowanie symptomów, zwłaszcza nieinwazyjne, cieszy się coraz większą popularnością. Momenty rozpoczęcia konserwacji maszyn wyznaczane są na podstawie obserwacji procesów resztkowych przy wykorzystaniu chociażby kamer termowizyjnych [37], czujników wibroakustycznych [31] czy czujników ciśnienia [6]. Procesy resztkowe są procesami termicznymi, tarciovymi, elektrycznymi oraz wibroakustycznymi (drżania, hałas, pulsacja medium roboczego w maszynie) i niejednokrotnie są objawem bądź determinantą zużycia [5].

3. Procesy stacjonarne i niezawodność systemów

Do opisu zachowania systemów fizycznych, ekonomicznych, technicznych najczęściej wykorzystuje się modele matematyczne. Na podstawie danych historycznych najpierw wyznacza się wartości parametrów strukturalnych, a następnie po identyfikacji parametrycznej istnieje możliwość wykorzystania tych modeli do prognozowania zachowań opisywanych systemów. Do predykcji zachowań maszyn i urządzeń wykorzystuje się często modele szeregów czasowych. Prognozowanie przyszłych wartości stanów systemu pozwala wnioskować o możliwych awariach maszyn czy urządzeń.

Szeregi czasowe dzielone są na stacjonarne i niestacjonarne (patrz np. [2, 11,7,27]).

Definicja 1. Szereg czasowy $\{x_t\}_{t \in N_0}$ jest ściśle stacjonarnym, jeżeli dla każdego $m \in N$, dowolnych $t_1 < t_2 < \dots < t_m$ oraz każdego $\tau \in N$ łączne rozkłady prawdopodobieństwa m elementowych ciągów losowych $x_{t_1}, x_{t_2}, \dots, x_{t_m}$ i $x_{t_1+\tau}, x_{t_2+\tau}, \dots, x_{t_m+\tau}$ są identyczne.

Zatem, dla stacjonarnych szeregów czasowych własności statyczne i dynamiczne przy dowolnym przesunięciu czasowym pozostają bez zmian. Wobec powyższego wartości średnia i wariancja elementów szeregu czasowego $\{x_t\}_{t \in N_0}$ są stałe.

Definicja 2. Szereg czasowy $\{x_t\}_{t \in N_0}$ jest niestacjonarnym jednorodnie (homoskedastycznie), jeżeli wydzielając z szeregu czasowego nielosową składową otrzymujemy szereg stacjonarny.

Szeregi niestacjonarne jednorodnie zawierają na przykład trend deterministyczny bądź stochastyczny, sezonowość, cykliczność. Takie szeregi po zastosowaniu operatora różnicowego można sprowadzić do szeregów stacjonarnych [2,11].

Definicja 3. Szereg czasowy $\{x_t\}_{t \in N_0}$ jest zintegrowany w stopniu d (oznaczany jako $\{x_t\}_{t \in N_0} \in I(d)$), jeżeli szereg $\{\Delta^k x_t\}_{t \geq k}$ dla $0 \leq k < d$ jest niestacjonarny, natomiast szereg $\{\Delta^d x_t\}_{t \geq d}$ jest stacjonarny, gdzie operator różnicowy Δ jest określony jako $\Delta x_t = x_t - x_{t-1}$, zaś $\Delta^{k+1} x_t = \Delta^k x_t - \Delta^k x_{t-1}$ dla $k \in N$ (patrz np. [2, 11, 15, 27]).

Do badania stacjonarności szeregów czasowych najczęściej wykorzystywane są: rozszerzony test Dickeya-Fullera [7], test Kwiatkowskiego, Phillipa, Schmidta i Shina [16], test Phillipa-Perrona [28] (są to przykłady testów pierwiastka jednostkowego nazywane również testami stacjonarności).

Powyższe testy stosowane w analizie szeregów czasowych można wykorzystać do badania niezawodności systemów i urządzeń. Jeżeli na podstawie klasycznych testów pierwiastka jednostkowego zostanie stwierdzona własność stacjonarności (własności statyczne i dynamiczne pozostają bez zmian) oraz wartości stanu systemu znajdują się w ustalonym przedziale (przyjmują dopuszczalne wartości), to z powodu braku niepokojących objaw przyjmuje się, że system zachowuje się prawidłowo. Jeżeli na podstawie realizacji stanów systemu zostanie stwierdzone, że własność stacjonarności nie jest spełniona, tzn. zachowanie systemu ma w sobie trend liniowy, wielomianowy (w zależności od stopnia integracji), to jest objaw niepokojący. Stosując operator różnicowy Δ^d szereg czasowy $\{x_t\}_{t \in N_0}$ niestacjonarny homoskedastycznie można sprowadzić do szeregu stacjonarnego $\{\Delta^d x_t\}_{t \geq d}$ (więcej na ten temat można znaleźć w [2, 15, 27]). Stopień integracji d określa stopień wielomianu aproksymującego część deterministyczną w szeregu czasowym (zależność pomiędzy różnicowaniem a trendem wielomianowym jest szeroko omówiona w [15, rozdz. 2.4]). Następnie korzystając z metody najmniejszych kwadratów wyznacza się trend deterministyczny w szeregu czasowym, a następnie na podstawie predykcji zachowania szeregu czasowego wyznacza się oczekiwany czas do przekroczenia wartości dopuszczalnych dla danego systemu (wartości krytycznych alarmowych) – resztkowy czas pracy urządzenia. W kolejnym rozdziale przedstawiono klasyczne testy stacjonarności, w oparciu o które wyznaczony zostanie moment podjęcia decyzji dotyczącej konserwacji urządzeń.

4. Testy stacjonarności

Utrzymanie ciągłości ruchu produkcyjnego jest możliwe poprzez dokonywanie konserwacji urządzeń przywracających sprawność infrastruktury technicznej. Zwykle terminy konserwacji są wyznaczone na podstawie zapisów widniejących w dokumentacji techniczno-ruchowej. Problem jednak pojawia się wówczas, gdy tego typu działania mają być podejmowane na podstawie rzeczywistego stanu maszyny. Do uzyskania informacji dotyczącej konieczności przeprowadzenia remontu uzyskanej na podstawie analizy parametru diagnostycznego wykorzystano testy stacjonarności szeregów czasowych

Poniżej przedstawiono klasyczne testy stacjonarności: test ADF i test KPSS.

Aby przeprowadzić rozszerzony test Dickey-Fullera [patrz np.8,11,15,27] (test ADF, ang. Augmented Dickey-Fuller test) należy rozważyć szereg czasowy $\{x_t\}_{t \in N_0}$ postaci

$$\Delta x_t = \theta x_{t-1} + \sum_{i=1}^k \Delta x_{t-i} + \varepsilon_t, \quad (1)$$

gdzie $\{\varepsilon_t\}_{t \in N}$ jest ciągiem niezależnych zmiennych losowych o rozkładzie normalnym $N(0, \sigma^2)$. Rząd autoregresji $k \in N$ należy dobrać tak, aby wyeliminować korelacje pomiędzy elementami szeregu $\{\varepsilon_t\}_{t \in N}$. Na poziomie istotności α tworzy się wówczas hipotezę roboczą, że szereg czasowy $\{x_t\}_{t \in N_0}$ jest niestacjonarny (tzn. przyjmujemy $\theta = 0$, zatem $\{x_t\}_{t \in N_0} \in I(d)$ oraz $d \geq 1$). Jako hipotezę alternatywną przyjmuje się, że szereg czasowy $\{x_t\}_{t \in N_0}$ jest stacjonarny (tzn. $\theta \in (-2, 0)$, zatem $\{x_t\}_{t \in N_0} \in I(0)$). Statystyka testowa

$$DF = \frac{\hat{\theta}}{S(\theta)} \quad (2)$$

ma rozkład Dickey-Fullera, gdzie $\hat{\theta}$ jest estymatorem parametru θ , natomiast $S(\theta)$ oznacza odchylenie standardowe tego parametru. Wartość estymatora parametru θ oraz odchylenie standardowe wyznacza się za pomocą Metody Najmniejszych Kwadratów. Z tablic rozkładu rozkład Dickey-Fullera wyznaczana jest wartość krytyczną DF^* . Jeżeli $DF^* \leq DF$, to na poziomie istotności α nie ma podstaw do odrzucenia hipotezy roboczej, zatem elementy szeregu $\{x_t\}_{t \in N_0}$ są zintegrowane w stopniu wyższym bądź równym jeden (tzn. przyjmujemy że szereg $\{x_t\}_{t \in N_0}$ jest niestacjonarny). Jeżeli $DF < DF^*$, to na poziomie istotności α odrzuca się hipotezę roboczą na korzyść hipotezy alternatywnej oraz przyjmuje się, że szereg $\{x_t\}_{t \in N_0}$ jest stacjonarny. W przypadku stwierdzenia, że szereg $\{x_t\}_{t \in N_0}$ jest niestacjonarny dodatkowo badana jest stacjonarność szeregów $\{\Delta^d x_t\}_{t \geq d}$ dla $d \leq 1$ w celu określenia stopnia wielomianu aproksymującego część deterministyczną szeregu $\{x_t\}_{t \in N_0}$.

Weryfikację stacjonarności szeregu czasowego można przeprowadzić w oparciu o test Kwiatkowskiego, Phillipsa, Schmidta i Shina [patrz np. 11,14,15,27] (test KPSS). Należy zatem rozważyć szereg czasowy $\{x_t\}_{t \in N_0}$ postaci

$$x_t = \beta t + r_t + \varepsilon_t, \quad (3)$$

gdzie $\{\varepsilon_t\}_{t \in N}$ jest ciągiem niezależnych zmiennych losowych o rozkładzie normalnym $N(0, \sigma^2)$. Proces $\{r_t\}_{t \in N_0}$ oznacza proces błędzenia losowego

$$r_t = r_{t-1} + v_t, \quad (4)$$

gdzie $\{v_t\}_{t \in N}$ jest ciągiem niezależnych zmiennych losowych o rozkładzie normalnym $N(0, \sigma_v^2)$. Na poziomie istotności α tworzy się hipotezę roboczą, że szereg czasowy $\{x_t\}_{t \in N_0}$ jest stacjonarny (tzn. przyjmuje się $\sigma_v^2 = 0$, wtedy elementy szeregu $\{r_t\}_{t \in N_0}$ są stałe oraz $\{x_t\}_{t \in N_0} \in I(0)$). Jako hipotezę alternatywną przyjmuje się, że szereg czasowy $\{x_t\}_{t \in N_0}$ jest niestacjonarny (tzn. przyjmujemy $\sigma_v^2 > 0$, zatem $\{r_t\}_{t \in N_0}$ określa proces błędzenia

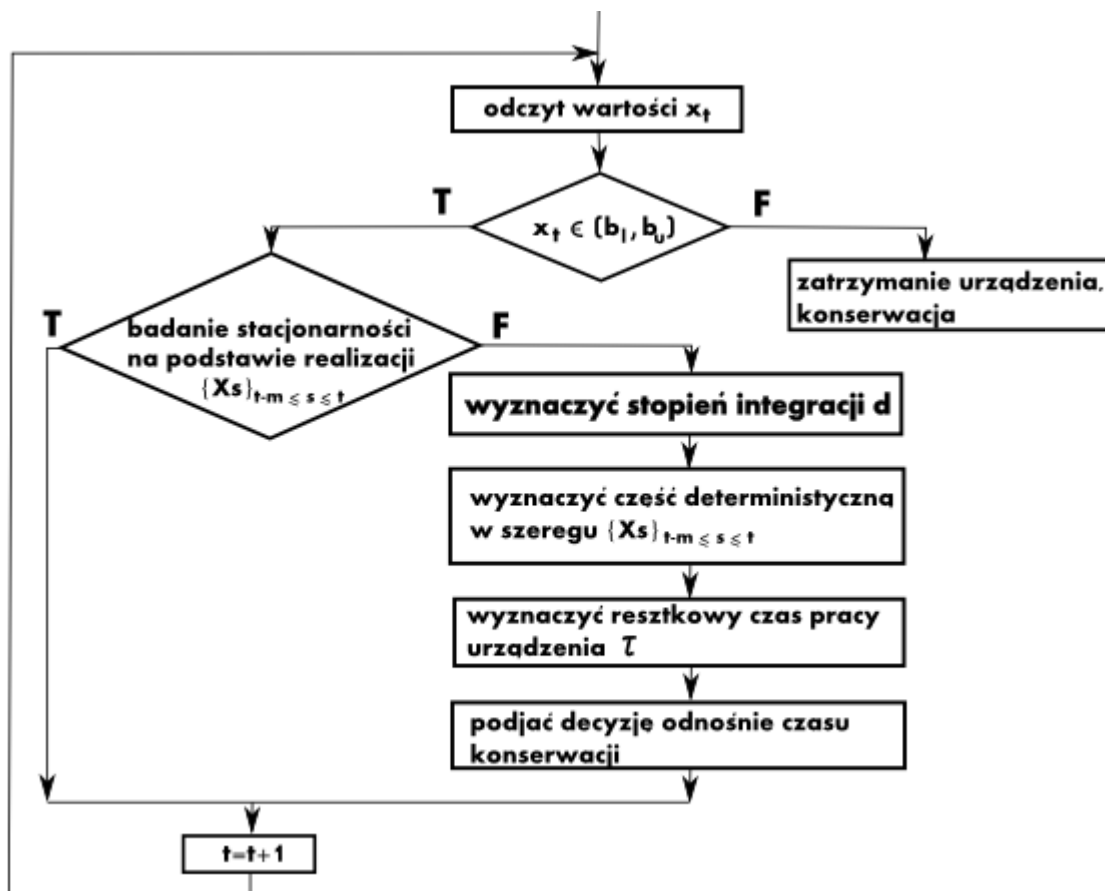
losowego, co powoduje że elementy szeregu $\{x_t\}_{t \in N_0}$ powstają jako suma elementów szeregu stacjonarnego $\{\varepsilon_t\}_{t \in N}$ i niestacjonarnego $\{r_t\}_{t \in N_0}$. Dla realizacji $\{x_t\}_{1 \leq t \leq n}$ korzystając z MNK szacuje się wartości parametrów modelu (3) oraz wyznacza statystykę testową

$$\eta = \frac{\sum_{t=1}^n S_t^2}{n^2 S^2(k)}, \quad (5)$$

gdzie $S_t = \sum_{i=1}^t \varepsilon_i$, $S^2(k) = \frac{1}{n} \left(\sum_{i=1}^n \varepsilon_i^2 + 2 \sum_{s=1}^k w(s,k) \sum_{t=s+1}^n \varepsilon_t \varepsilon_{t-s} \right)$, wagi $w(s,k) = 1 - \frac{s}{k+1}$ natomiast

k oznacza rząd opóźnienia. Z tablic testu KPSS odczytuje się wartość krytyczną η^* . Jeżeli $\eta < \eta^*$, to na poziomie istotności α nie ma podstaw do odrzucenia hipotezy roboczej, zatem przyjmuje się, że elementy szeregu $\{x_t\}_{t \in N_0}$ są zintegrowane w stopniu zero (przyjmujemy, że szereg $\{x_t\}_{t \in N_0}$ jest stacjonarny). Jeżeli $\eta \geq \eta^*$, to na poziomie istotności α odrzuca się hipotezę roboczą na korzyść hipotezy alternatywnej oraz przyjmuje, że szereg $\{x_t\}_{t \in N_0}$ jest niestacjonarny.

Algorytm proponowanego podejścia polegającego na ocenie stacjonarności szeregów czasowych temperatury przedstawiono na rys. 2.




Rys. 2 Algorytm proponowanego podejścia polegającego na ocenie stacjonarności szeregów czasowych temperatury (opracowanie własne)

5. Wykorzystanie testów stacjonarności do analizy niezawodności maszyn produkcyjnych


Bezpośredni odczyt parametrów urządzeń pozwala stwierdzić czy urządzenie pracuje prawidłowo (jeżeli wartość parametru znajduje się w granicach wartości dopuszczalnych), czy też nie. Zastosowanie testów stacjonarności podczas monitorowania pracy maszyn pomaga weryfikować w czasie rzeczywistym tezę o prawidłowej pracy tych obiektów. W przypadku wykrycia niestacjonarności w szeregu czasowym stosując MNK należy wyznaczyć trend w tym szeregu, prognozując tym samym zachowania oraz szacując resztkowy czas pracy urządzeń. Moment wyznaczenia niestacjonarności w szeregu czasowym jest momentem podjęcia decyzji odnośnie konserwacji urządzeń (należy ustalić kiedy i w jakim okresie przeprowadzić konserwację). Jeżeli pozostały czas na realizację produkcji nie przekracza resztkowego czasu pracy, to konserwację produkcji należy przeprowadzić po ukończeniu produkcji/zobowiązania, w przeciwnym razie należy wyznaczyć termin konserwacji nie przekraczający resztkowego czasu pracy.

Poniżej przedstawiono symulacje monitorowania prawidłowej pracy maszyn produkcyjnych z wykorzystaniem testu stacjonarności. W tym celu wykorzystano testy ADF i KPSS. Symulacje komputerowe zostały przeprowadzone w programie MATLAB. Wygenerowane wartości liczbowe miały za zadanie reprezentować wartości temperatury odczytywane z dwóch czujników. Na podstawie tychże wartości w sposób dynamiczny tworzono wykresy dla tych czujników (

rys. 3).



CZUJNIK NR 1 TEMPERATURA W NORMIE



CZUJNIK NR 2 TEMPERATURA W NORMIE

Rys. 3 Wykresy wartości temperatury dla dwóch czujników wygenerowane w programie MATLAB (opracowanie własne)

Badanie stacjonarności w sposób dynamiczny przeprowadzane było na podstawie m -elementowej realizacji szeregu $\{x_s\}_{t-20 \leq s \leq t}$ dla $t \geq m$ (przyjęto $m = 20$). Jeżeli obserwowane wartości należą do przedziału dopuszczalnego (b_l, b_u) oraz spełniona jest własność stacjonarności, to wnioskuje się, że urządzenie pracuje poprawnie. W przypadku stwierdzenia niestacjonarności w oparciu o test ADF wykorzystano MNK do wyznaczenia trendu w tym szeregu czasowym $\{x_s\}_{t-20 \leq s \leq t}$. Dodatkowo wyznaczono przewidywany czas do momentu przekroczenia poziomu krytycznego temperatury, jako dopuszczalne wartości przyjęto przedział $(-20^0 C, 20^0 C)$. Jeżeli analiza stacjonarności jest przeprowadzona na podstawie krótkich realizacji szeregu czasowego, a urządzenie znajduje się w pomieszczeniu, gdzie warunki atmosferyczne nie wpływają na jego pracę, to wpływ środowiska można pominąć. Dodatkowo dobór czasookresu powinien być adekwatny do analizowanej problematyki. Nie ulega wątpliwości, że wartość z poprzedniej chwili obserwacyjnej ma większą wagę informacyjną niż wielkość z przed roku, tzw. „problem świeżości danych”.

Wykrycie niestacjonarności procesu, resztkowy czas prawidłowej pracy urządzenia oraz prawdopodobieństwo przyjęcia hipotezy zerowej przedstawione są na rysunku 3. Na podstawie realizacji $\{x_s\}_{60 \leq s \leq 80}$ dla czujnika 1 stosując MNK wyznaczone zostało równanie stanu postaci

$$x_{60+t} = 5.35 + 0.492t + \varepsilon_t, \quad (6)$$

gdzie $\{\varepsilon_t\}_{t \in N}$ jest ciągiem niezależnych zmiennych losowych o rozkładzie normalnym $N(0,0.83)$. Na podstawie uzyskanych wyników prognozowano dalsze wartości temperatury na czujniku nr 1 na podstawie równania

$$x_{80+t} = x_{80} + 0.492t + \varepsilon_t, \quad (7)$$


gdzie $\{\varepsilon_t\}_{t \in N}$ jest ciągiem niezależnych zmiennych losowych o rozkładzie normalnym $N(0,0.83)$ oraz $x_{80} = 14.12$. Przewidywane wartości temperatury określono za pomocą równania

$$\hat{x}_{80+t} = Ex_{80+t} = x_{80} + 0.492t. \quad (8)$$


Resztkowy czas prawidłowej pracy urządzenia wyznaczono jako

$$\tau = \min\{t \in N; \hat{x}_{80+t} \notin (-20,20)\} = 12. \quad (9)$$

Podobne wyniki uzyskano stosując test KPSS podczas monitorowania odczytów temperatury na czujniku 1.



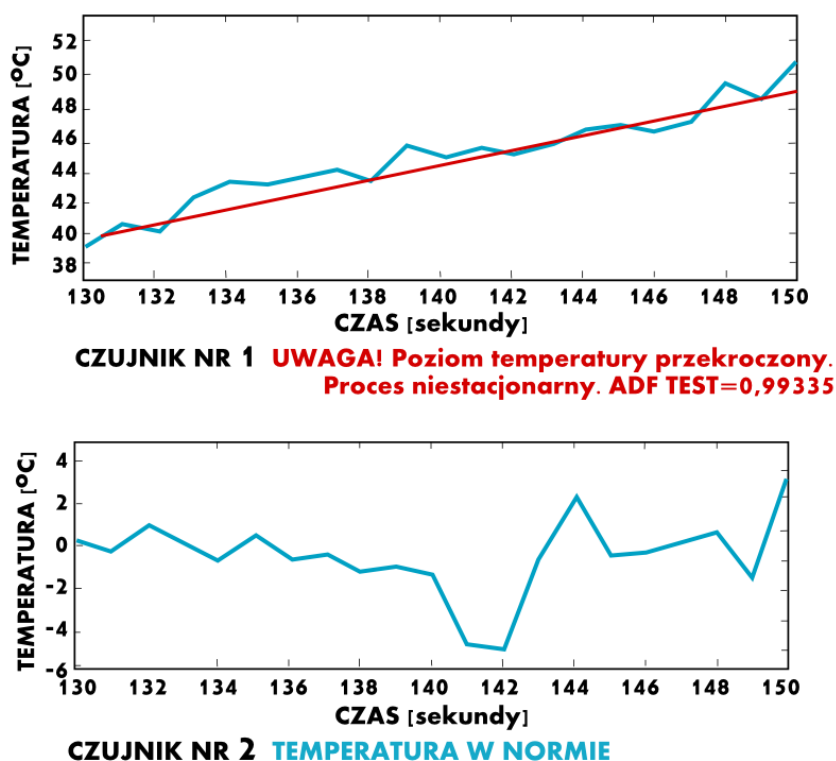
CZUJNIK NR 1 UWAGA! Poziom temperatury zostanie przekroczony za 12 sek. Proces niestacjonarny. ADF TEST=0,99433



CZUJNIK NR 2 TEMPERATURA W NORMIE

Rys. 4 Komunikat o niestacjonarności procesu wygenerowany w skutek zmiany temperatury (opracowanie własne)

Przekroczenie poziomu krytycznego/dopuszczalnego temperatury zostało zakomunikowane użytkownikowi systemu w postaci informacji wyświetlonej pod wykresem (rys. 5).



Rys. 5 Komunikat o przekroczonym poziomie temperatury na czujniku 1 (opracowanie własne)

Uzyskane wyniki symulacji testu stacjonarności wykazały skuteczność zarówno testu ADF jak i KPSS w predykcji awarii przy uwzględnieniu wartości jednego procesu resztkowego, którym w analizowanym przypadku była wartość temperatury. Do badania niestacjonarności jednorodnej oprócz testów ADF i KPSS można użyć np. testy Philipsa-Perrona, Leybourne-McCabe, Engle-Granger cointegration test, Johansen cointegration test itp., natomiast do badania niestacjonarności niejednorodnej (heteroscedastyczności, np. do analizy wibracji) należy użyć innych testów, np. Engle's ARCH test, Breusch-Pagan test, White's test, itp.

6. Wnioski

Nadzór nad stanem parku maszynowego jest jednym z czynników pozwalających uzyskać wzrost poziomu efektywności eksploatacyjnej. O ile samo monitorowanie parametrów diagnostycznych nie daje podstawy do podejmowania decyzji odnośnie konieczności realizacji działań konserwacyjno-remontowych, to wykorzystanie odpowiednich modeli matematycznych do analizy danych daje taką możliwość. Jednosymptomowa diagnostyka może przebiegać przy użyciu statystycznych testów stacjonarności procesu,

takich jak chociażby test ADF czy KPSS, co przedstawia wykonana w programie MATLAB symulacja komputerowa. Wykrycie niestacjonarności oraz wyznaczenie resztkowego czasu pracy urządzenia może stanowić wskazanie dla Służb Utrzymania Ruchu do podjęcia czynności konserwacyjnych podzespołów czy części maszyn, w których zachodzą niepokojące zmiany. Świadczyć mogą o tym uzyskane wyniki symulacji- niepokojące zmiany wartości temperatury będącej parametrem diagnostycznym zostały zasygnalizowane w programie, a dodatkowo zakomunikowano przewidywany czas do pojawienia się awarii.

Zastosowanie wymienionych testów statystycznych do predykcji awarii możliwe jest dzięki analizie zbioru danych obejmujących wartości monitorowanych wektorów obserwacji odnoszących się do stanu maszyny. Obecnie dostępne technologie pozwalające na tworzenie zapisu wartości obserwowanych parametrów, a także łatwy dostęp do serwerów pozwalających na przechowywanie danych, przyczyniają się do powstawania dużych zbiorów danych. Jeśli gromadzone dane są zmienne i różnorodne, wówczas określa się je mianem zbiorów *big data* [33].

Należy jednak zaznaczyć, że przy wielosymptomowej diagnostyce maszyn, dającej szerokie spojrzenie na zmianę stanu infrastruktury technicznej, proponowane rozwiązanie należałoby rozszerzyć o wykrywanie korelacji pomiędzy zredukowanymi wektorami obserwacji. Wskazane staje się zatem zbudowanie standardu do tworzenia modelu opartego na niezależnych i zupełnych parametrach stanu i wspierającego optymalizację efektywności eksploatacyjnej. Przy opracowaniu modelu należałoby także wziąć pod uwagę losowy charakter niektórych wartości pomiarów.

Literatura

1. Antosz K., Stadnicka D. Mierniki oceny efektywności funkcjonowania maszyn w dużych przedsiębiorstwach: wyniki badań. Eksploatacja i Niezawodność- Maintenance and Reliability 2015;17.
2. Box G. E. P., Jenkins G.M. Analiza szeregów czasowych. Warszawa: PWN, 1983.
3. Burnos A. Efektywność utrzymania ruchu. Agro Przemysł 2012;2..
4. Carnero MC. Selection of diagnostic techniques and instrumentation in a predictive maintenance program. A case study. Decision Support Systems 2005; 38.
5. Cempel Cz. Diagnostyka wibroakustyczna maszyn. Warszawa: PWN, 1989.
6. Cieślowski B. Proces diagnostyki układu hydrauliki siłowej w mechanizmie obrotu pługa. Inżynieria Rolnicza 2009; 9.
7. Chow G.C. Ekonometria. Warszawa: PWN, 1995.
8. Dickey D.A, Fuller W.A. Distributions of the estimators for autoregressive time series with a unit root. Journal of the American Statistical Association 1979; 74: 427-431.

9. Dutkowska B. Rosnąca rola systemów CMMS.
<http://www.utrzymanieruchu.pl/menu-gorne/arttykul/article/rosnaca-rola-systemow-cmms/> (dostęp: 12.03.2015r.).
10. Doman M., Doman R. Ekonometryczne modelowanie dynamiki polskiego rynku finansowego. Poznań: Wydawnictwo Akademii Ekonomicznej w Poznaniu, 2004.
11. Hamilton J.D. Time Series Analysis. Princeton: Princeton University Press, 1994.
12. Hetmańczyk M. Predykcyjne utrzymanie ruchu. Inżynieria & Utrzymanie Ruchu Zakładów Przemysłowych 2015: 1, 60-64.
13. Ho T. The government spending and private consumption: a panel cointegration analysis. International Review of Economics & Finance 2002; 10: 95-108.
14. Komitet Inżynierii Produkcji PAN. Istota inżynierii produkcji. Warszawa: PAN, 2012.
15. Kozłowski E. Analiza i identyfikacja szeregów czasowych.
http://www.kozlowski.pollub.pl/analiza_szeregow.pdf (dostęp: 12.06.2015r.).
16. Kwiatkowski D., Phillips P.C.B., Schmidt P., Shin Y. Testing the Null Hypothesis of Stationary Against the Alternative of a Unit Root. Journal of Econometrics 1992; 54: 159-178.
17. Legutko S. Podstawy eksploatacji maszyn i urządzeń. Warszawa: Wydawnictwa Szkolne i Pedagogiczne, 2004.
18. Leszek W., Mazurkiewicz A., Trzos M. Projektowanie eksperymentalnych systemów badawczych w budowie i eksploatacji maszyn. Radom: Biblioteka Problemów Eksploatacji. Instytut Technologii Eksploatacji, 1999.
19. Ljungberg Ö. Measurement of overall equipment effectiveness as a basis for TPM activities. International Journal of Operations & Production Management 2002; 18: 495-507.
20. Loska A.: Exploitation assessment of selected technical objects using taxonomic methods. Eksploatacja i Niezawodność- Maintenance and Reliability 2013: 15.
21. Ludwig, B. Predicting the future: Have you considered using the Delphi methodology. Journal of Extension 2005; 6.

22. Mazurkiewicz D. Studium wybranych aspektów diagnostyki eksploatacyjnej transportu taśmowego. Politechnika Lubelska. Lublin, 2011.
23. Mączyński W., Nahirny T. Efektywność służb utrzymania ruchu jako składowa efektywności przedsiębiorstwa. Innowacje w zarządzaniu i inżynierii produkcji / red. R. Knosala. Opole: Oficyna Wydaw. Polskiego Towarzystwa Zarządzania Produkcją, 2012.
24. Młyńczak M. Metodyka badań eksploatacyjnych obiektów mechanicznych. Wrocław: Oficyna Wydawnicza Politechniki Wrocławskiej, 2012.
25. Muchiria P. N, Pintelona L, Martinb H, De Meyerc A. M. Empirical analysis of maintenance performance measurement in Belgian industries. International Journal of Production Research 2010; 20.
26. Nowicki R., Bate M. Inteligentne podejście w rozpoznawaniu anomalii pracy maszyn napędzanych silnikami elektrycznymi. Zeszyty Problemowe – Maszyny Elektryczne 2013; 2.
27. Osińska M. Ekonometria finansowa. Warszawa: PWE, 2006.
28. Perron P. The great crash, the oil price shock, and the unit root hypothesis. Econometrica 1989; 6: 1361-1401.
29. Polska Norma PN-EN 15341:2007 - Maintenance - Maintenance Key Performance Indicators. Warszawa: Polski Komitet Normalizacyjny, 2007.
30. Simões J.M, Gomes C.F, Yasin M.M. A literature review of maintenance performance measurement: A conceptual framework and directions for future research. Journal of Quality in Maintenance Engineering 2011; 2(17).
31. Sobieski W. Stanowisko laboratoryjne do badania zjawiska kawitacji metodą wibroakustyczną. Diagnostyka 2004; 32: 37-42.
32. Srivastava N.K., Mondal S. Development of a Predictive Maintenance Model Using Modified FMEA Approach. IUP Journal of Operations Management 2014; : 7-16.
33. Tabakow M., Korczak J., Franczyk B. Big Data – definicje, wyzwania i technologie informatyczne. Informatyka Ekonomiczna = Business Informatics 2014; 1.
34. Uhl T., Barszcz T. Informatyczne aspekty projektowania systemów monitorowania stanu maszyn- sprzęt i oprogramowanie. Diagnostyka 2001; 24.

35. Walczak M. System utrzymania ruchu czynnikiem przewagi konkurencyjnej przedsiębiorstwa// Historia i perspektywy nauk o zarządzaniu. Księga pamiątkowa dla uczczenia jubileuszu 40-lecia pracy naukowo-dydaktycznej prof. zw. dra hab. Arkadiusza Potockiego / Miłkula B. [red]. Kraków: Fundacja Uniwersytetu Ekonomicznego w Krakowie, 2012.
36. Yuan Y., Jiang X., Liu X. Predictive maintenance of shield tunnels. Tunnelling and Underground Space Technology 2013; 38.
37. Żabicki D. Zastosowanie kamer termowizyjnych. Monitorowanie i Diagnostyka 2014; 2: 16-19.