

Ewelina KOSICKA
Edward KOZŁOWSKI
Dariusz MAZURKIEWICZ

THE USE OF STATIONARY TESTS FOR ANALYSIS OF MONITORED RESIDUAL PROCESSES

WYKORZYSTANIE TESTÓW STACJONARNOŚCI DO ANALIZY MONITOROWANYCH PROCESÓW RESZTKOWYCH*

Sustaining high operational efficiency of a machine park requires the use of state-of-art solutions that support both monitoring of residual processes and performing thorough analysis of thereby collected data. What meets the needs of entrepreneurs who strive for high reliability of technological infrastructure is a modern approach to maintenance prediction. The literature of the subject offers numerous studies presenting the use of various statistical models for time series prediction. The objective of this paper is to verify whether tests used in econometrics such as the augmented Dickey-Fuller test and the Kwiatkowski-Phillips-Schmidt-Shin test are suitable for failure prediction. The simulations were performed for one diagnostic parameter, i.e. temperature.

Keywords: failure prediction, maintenance, stationary tests, ADF, KPSS.

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.

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

1. Introduction

Meeting contractual obligations is one of the factors that affect operational efficiency of an enterprise. Hence, prompt delivery of a contracted quantity and quality of products is a key task of every company. On the one hand, the use of state-of-the-art manufacturing techniques and advanced production processes enables companies to meet contractual obligations; on the other, it poses problems regarding reliability of production equipment. Consequently, the actions supporting operations taken by a company's maintenance department (production equipment must be kept in constant operational efficiency by controlling technical condition of machines and devices) become increasingly significant. According to Legutko [1], operation is the whole of phenomena, processes and events that occur during the period of existence of a device, from the moment of its construction until its withdrawal from use. When used with respect to maintenance, the term "efficiency" is defined as a property of people or technical objects which determines whether they meet different requirements, e.g. in terms of reliability, economy or quality. Operational efficiency is a quotient of effects produced in a fixed time interval of duration of a given state of an operating object to the costs of achieving these effects. Increasing operational efficiency of machines via failure prediction and restoring full efficiency of a production system, ensures prompt completion of contractual obligations, which – in turn – means higher profits of the enterprise. This is of key importance given the

strong competition between enterprises, where constant improvement of manufacturing systems, development of production technologies and production automation solutions are key to success.

The growing interest in predictive maintenance combined with the problem of unused data collected by systems monitoring machine park operations have inspired the present authors to undertake studies aimed at verification the effectiveness of failure prediction by stationary tests. Additionally, on detecting alarming symptoms, residual time of machinery operation was determined, too. Seasonal changes in ambient conditions can have a negative impact on values of observed state parameters and, thus, on the efficiency of predictions made using stationary tests. If this is the case, it is necessary to present assumptions concerning investigated signals (the effect of changes in ambient conditions on observation vector values). Since the simulation assumed maintaining constant ambient temperature conditions, its impact on non-stationarity was not taken into consideration.

2. Effect of maintenance activities on operational efficiency

The observations made in the field of maintenance demonstrate that the dominant trend in most enterprises is to repair machines and devices only after failure, as a result of which the time for response actions exceeds the time for planned operations. This leads to a decrease in operational efficiency. In addition to this, poor condition

(*) Tekst artykułu w polskiej wersji językowej dostępny w elektronicznym wydaniu kwartalnika na stronie www.ein.org.pl

of technical infrastructure leads to lower productivity generating additional losses. The actions taken to improve operational efficiency of enterprises should hence strive to eliminate waste in the form of inefficient work of both machines and maintenance staff. The indicators listed in the standard EN15341 [29] for determining maintenance services efficiency can be useful for verification of the efficiency of implemented improvements [23]. One of the most widely applied indicators is Overall Equipment Effectiveness (OEE) [1, 20, 19]. The considerations of ways of improving the functioning of maintenance and repair sector management also point to connections between operational efficiency level and its selected structure [20, 23].

Maintenance operations are undertaken to:

- maintain specific quality of products/services,
- prolong as much as possible the operation life of production equipment,
- ensure conditions for safe operation of machines and devices,
- reduce production costs as much as possible by limiting production breaks.

The above actions can be implemented following determination of a machine or process state by physical quantities. The behaviour of machines or production processes is modelled by equations of state described by some functions $f(t)$, $t \in T$, where the independent variable t is a time variable, while T is a time interval. The determination of state of a technical object is called diagnosing. Figure 1 shows schematically processes that occur in production and types of diagnosed working and accompanying processes.

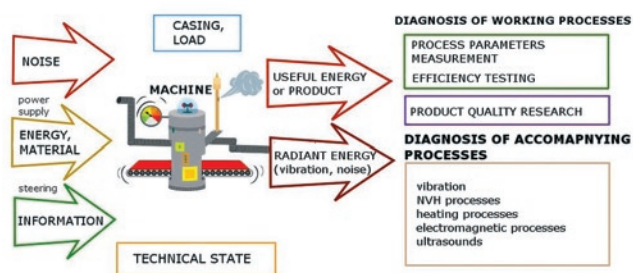


Fig. 1. Schematic representation of processes occurring in a machine and of methods for diagnosing working and accompanying processes [1]

What can occur in operational processes are random events caused, among others, by human error, impact of natural environment and operational environment. With wise modelling of random factors that affect behaviour of machines and production processes, we can increase operational efficiency of such objects [18, 24]. It can therefore be claimed that maintenance is one of the key processes that have a direct impact on increasing operational efficiency.

The efficiency of a machine park depends on operations which provide a basis for preventive maintenance. This means that decisions concerning machinery maintenance operations are taken based on technical and operational documentation. According to the predictive maintenance approach [4], the moment of maintenance operations in a production process should be scheduled based on machinery condition. For this reason, symptom monitoring, particularly in a non-invasive way, becomes more and more popular. The moments of machine maintenance operations are scheduled based on observation of residual processes using, among others, infrared cameras [37], vibroacoustic sensors [31] and pressure sensors [6]. Residual processes are thermal, frictional, electric and vibroacoustic (vibrations, noise, fluctuation of a working medium in the machine), and can often be a symptom or determinant of wear [5].

3. Stationary processes and system reliability

The behaviour of physical, economic and technical systems is usually described by mathematical models. First, based on historical data, values of structural parameters are determined, and then, following parametric identification, these models can be used to predict the behaviour of systems being described. The behaviour of machines and devices is often predicted by time series models. By predicting future values of system states, we can draw conclusions about a possibility of failure of machines and devices.

Time series can be divided into stationary and non-stationary (see e.g. [2, 11, 7, 27]).

Definition 1. The time series $\{x_t\}_{t \in N_0}$ is said to be strict stationary if for every $m \in N$, any $t_1 < t_2 < \dots < t_m$ and every $\tau \in N$ the joint distributions of the probability of m elements of random sequences $x_{t_1}, x_{t_2}, \dots, x_{t_m}$ and $x_{t_1+\tau}, x_{t_2+\tau}, \dots, x_{t_m+\tau}$ are identical.

Therefore, for stationary time series, the statistical and dynamical properties for any time shift remain unchanged. Given the above, the mean and variance of the elements of the time series $\{x_t\}_{t \in N_0}$ are constant over time.

Definition 2. The time series $\{x_t\}_{t \in N_0}$ is said to be homogeneous non-stationary (homoscedastic) if, by separating a non-random component from the time series, we obtain a stationary series. Homogeneously non-stationary series can contain among others a deterministic or stochastic trend; they can have a seasonal or periodic character. Following the application of a differential operator, such series can be reduced to stationary series [2, 11].

Definition 3. The time series $\{x_t\}_{t \in N_0}$ is said to be integrated of order d (defined by $\{x_t\}_{t \in N_0} \in I(d)$) if the series $\{\Delta^k x_t\}_{t \geq k}$ for $0 \leq k < d$ is non-stationary, while the series $\{\Delta^d x_t\}_{t \geq d}$ is said to be stationary, where the differential operator Δ is defined as $\Delta x_t = x_t - x_{t-1}$, while $\Delta^{k+1} x_t = \Delta^k x_t - \Delta^k x_{t-1}$ for $k \in N$ (see e.g. [2, 11, 15, 27]).

The stationarity of time series is most often investigated by the augmented Dickey-Fuller test [7], the Kwiatkowski-Phillips-Schmidt-Shin test [16], Phillips-Perron test [28] (they are examples of unit root tests also known as stationary tests).

The above tests for time series analysis can be used to investigate reliability of systems and devices. If the results of classical unit root tests confirm the presence of stationarity (static and dynamic properties remain unchanged) and values of the system state are within a fixed range (belong to acceptable interval), then – given the lack of alarming symptoms – it is stated that the system behaves correctly. If it is found (based on the realization state system) that the quality of stationarity is not met, i.e. the system's behaviour contains a linear, polynomial trend (depending on integration degree), it is an alarming symptom. By using the differential operator Δ^d the non-stationary homoscedastic time series $\{x_t\}_{t \in N_0}$ can be reduced to the stationary series $\{\Delta^d x_t\}_{t \geq d}$ (for more information see [2, 15, 27]). The integration order d defines the degree of a polynomial approximating for deterministic part in a time series (dependence between differentiation and polynomial trend is exhaustively discussed in [15, Section 2.4]). Next, using the least squares method, we determine a deterministic trend in the time series and then, based on prediction of behavior of the time series, we determine the expected time to exceeding acceptable values for a given system (alarming critical values) – residual operation time of a device. The subsequent section presents classi-

cal stationary tests that are employed to determine the moment of taking a decision with respect to device maintenance operations.

4. Stationary tests

Maintenance can be achieved by repairing devices that restore efficiency of technical infrastructure. Maintenance dates are usually scheduled based on technical and operational documentation. The problem occurs when such actions are to be taken based on the real condition of a machine. To obtain information regarding the necessity of repair based on analysis of the diagnostic parameter, we used time series stationary tests.

Below, we present two classical stationary tests: ADF and KPSS.

To perform the augmented Dickey-Fuller test (ADF) [see e.g. 8, 11, 15, 27], it is necessary to consider the time series $\{x_t\}_{t \in N_0}$ with the state equation:

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

where $\{\varepsilon_t\}_{t \in N}$ is a sequence of independent random variables with the normal distribution $N(0, \sigma^2)$. The order of autoregression $k \in N$ should be set such to eliminate correlations between the elements of the series $\{\varepsilon_t\}_{t \in N}$. Then, at the significance level α , we construct a null hypothesis that the time series $\{x_t\}_{t \in N_0}$ is non-stationary (i.e. we take that $\theta = 0$, therefore $\{x_t\}_{t \in N_0} \in I(d)$ and $d \geq 1$). As an alternative hypothesis, we take that the time series $\{x_t\}_{t \in N_0}$ is stationary (i.e.

$\theta \in (-2, 0)$, therefore $\{x_t\}_{t \in N_0} \in I(0)$). The test statistics:

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

has a Dickey-Fuller distribution, where $\hat{\theta}$ is an estimator of the θ parameter, while $S(\theta)$ denotes the standard deviation of this parameter. The estimator of the θ parameter and standard deviation are determined by the least squares method. Based on the Dickey-Fuller distribution tables, we determine a critical value DF^* . If $DF^* \leq DF$, then at the significance level α there are no grounds to reject the null hypothesis, therefore the elements of the series $\{x_t\}_{t \in N_0}$ are integrated to one or higher (i.e. we take that the series $\{x_t\}_{t \in N_0}$ is non-stationary). If $DF < DF^*$, then on the significance level α we reject the working hypothesis in favour of an alternative hypothesis and take that the series $\{x_t\}_{t \in N_0}$ is stationary. If it is found that the series $\{x_t\}_{t \in N_0}$ is non-stationary, we additionally test the stationarity of the series $\{\Delta^d x_t\}_{t \geq d}$ for $d \geq 1$ in order to determine the degree of a polynomial approximating deterministic part of the series $\{x_t\}_{t \in N_0}$.

The verification of time series stationarity can be done based on the Kwiatkowski-Phillips-Schmidt-Shin test [see e.g. 11, 14, 15, 27]

(KPSS test). Therefore, we must consider the series $\{x_t\}_{t \in N_0}$ with the state equation:

$$x_t = \beta t + r_t + \varepsilon_t, \tag{3}$$

where $\{\varepsilon_t\}_{t \in N}$ is a sequence of independent random variables with the normal distribution $N(0, \sigma^2)$. The process $\{r_t\}_{t \in N_0}$ denotes a random walk process

$$r_t = r_{t-1} + v_t, \tag{4}$$

where $\{v_t\}_{t \in N}$ is a series of independent random variables with the normal distribution $N(0, \sigma_v^2)$. At the significance level α we construct the null hypothesis that the time series $\{x_t\}_{t \in N_0}$ is stationary (i.e. we take that $\sigma_v^2 = 0$, then the elements of the series $\{r_t\}_{t \in N_0}$ are constant and $\{x_t\}_{t \in N_0} \in I(0)$). As an alternative hypothesis, we take that the time series $\{x_t\}_{t \in N_0}$ is non-stationary (i.e. we take that $\sigma_v^2 > 0$, then $\{r_t\}_{t \in N_0}$ denotes a random walk process, which causes that the elements of the series $\{x_t\}_{t \in N_0}$ are created as the sum of elements of a stationary $\{\varepsilon_t\}_{t \in N}$ and non-stationary $\{r_t\}_{t \in N_0}$ series). For realization $\{x_t\}_{1 \leq t \leq n}$ we use the least squares method to estimate values of parameters of the model (3) and to determine the test statistics:

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

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

weights $w(s,k) = 1 - \frac{s}{k+1}$ while k denotes the order of delay. From

the tables of the KPSS test, we take the limit value η^* . If $\eta < \eta^*$, then at the significance level α there is no ground for rejecting the null hypothesis, therefore it is taken that the elements of the time series $\{x_t\}_{t \in N_0}$ are integrated in order zero (we take that the series $\{x_t\}_{t \in N_0}$ is stationary). If $\eta \geq \eta^*$, then at the significance level α , we reject the null hypothesis in favour of an alternative hypothesis and take that that the series $\{x_t\}_{t \in N_0}$ is non-stationary.

An algorithm of the proposed approach consisting in assessment of stationarity of time series of temperature is illustrated in Fig. 2.

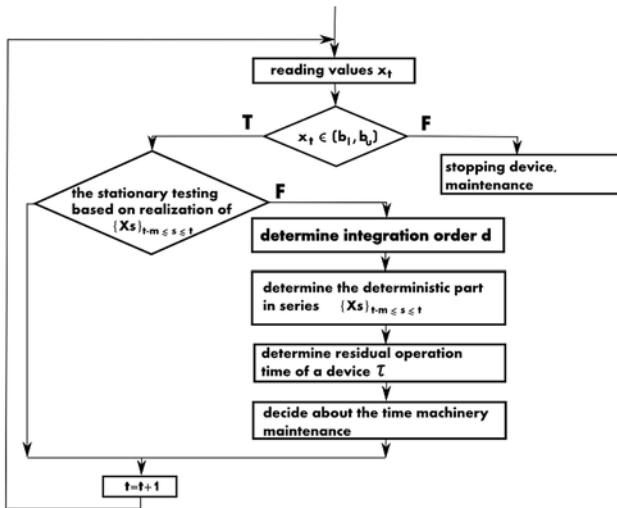


Fig. 2. Algorithm of the proposed approach consisting in assessment of stationarity of time series of temperature (prepared by the authors)

5. Use of stationary tests for analysis of production machinery reliability

Direct reading of device parameters allows us to find whether this device operates correctly (if the parameter value is within the acceptable limit) or not. The use of stationary tests during monitoring of machinery operation enables real-time verification of whether these machines operate correctly. If non-stationarity is detected in a time series by the least squares method, it is necessary to determine a trend in this time series, predicting in this way the behaviour and residual operation time of the device. The moment of determining non-stationarity in the time series is the moment of taking a decision about device maintenance (a maintenance operation date must be scheduled). If the remaining time for production realization does not exceed the residual operation time, then the production maintenance should be done following production process/contractual obligation; otherwise, it is necessary to schedule a maintenance date which does not exceed the residual operation time.

Below, we present the simulations of monitoring correct operation of production machinery by stationary testing. To this end, we used the ADF and KPSS tests. The simulations were performed using the MATLAB programme. The generated numerical values were to represent tem-

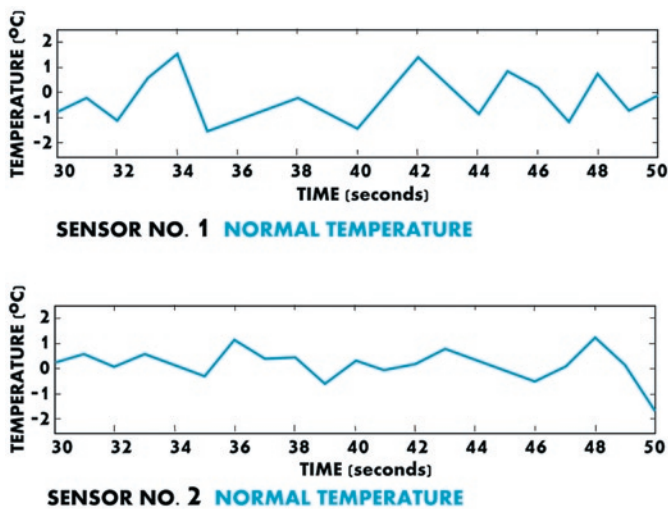


Fig. 3. MATLAB-generated diagrams showing temperatures recorded by two sensors (developed by the authors)

perature values read from two sensors. These values were used to create dynamically diagrams for these sensors (Fig. 3).

The stationary dynamical testing was conducted based on m -element realization of the series $\{x_s\}_{t-20 \leq s \leq t}$ for $t \geq m$ (where $m = 20$). If the observed values are within the acceptable interval (b_l, b_u) and

the criterion of stationarity is satisfied, then it is concluded that the device is operating correctly. If the ADF test results pointed to non-stationarity, we used the least squares method to determine a trend in this time series $\{x_s\}_{t-20 \leq s \leq t}$. In addition, we determined the predicted

time to exceeding the critical temperature level, the acceptable interval of values being set to $(-20^\circ\text{C}, 20^\circ\text{C})$. If the stationary analysis is performed based on short realizations of the time series and the device is placed in a room where atmospheric conditions does not affect its operation, the effect of environment can be omitted. Moreover, the selection of duration should be set adequately to the analyzed problem. Undoubtedly, a value from the previous observation moment is of higher informative significance than a value from the previous year, which is the so-called “data freshness problem”.

Figure 3 shows the detection of process non-stationarity, residual time of correct operation of the device and the probability of the zero hypothesis. Based on the realization of $\{x_s\}_{60 \leq s \leq 80}$ for Sensor 1 by the least squares method, we also determined the state equation:

$$x_{60+t} = 5.35 + 0.492t + \varepsilon_t, \tag{6}$$

where $\{\varepsilon_t\}_{t \in N}$ is a sequence of independent random variables with the normal distribution $N(0, 0.83)$. Based on the results, we predicted subsequent temperature values on Sensor 1 using the equation:

$$x_{80+t} = x_{80} + 0.492t + \varepsilon_t, \tag{7}$$

where $\{\varepsilon_t\}_{t \in N}$ is a sequence of independent random variables with the normal distribution $N(0, 0.83)$ and $x_{80} = 14.12$. The predicted temperature values are determined by the equation:

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

The residual time of correct operation of the device is determined as:

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

Similar results were produced using the KPSS test during the monitoring of temperature reading on Sensor 1. The system user is notified about the exceeding of the critical/acceptable temperature limit by the information displayed under the diagram (Fig. 5). The simulated stationary test results demonstrate that both the ADF and KPSS test are effective methods for failure prediction based on the values of one residual process, i.e. temperature. Besides the ADF and KPSS tests, homogenous non-stationarity can also be investigated using such tests as the Philips-Perron test, Leybourn-McCabe test, Engle-Granger cointegration test, Johansen cointegration test, while non-homogeneous non-stationarity (heteroscedasticity, e.g. for vibration analysis) can be investigated by the Engle’s ARCH test, Breusch-Pagan test, White’s test, etc.

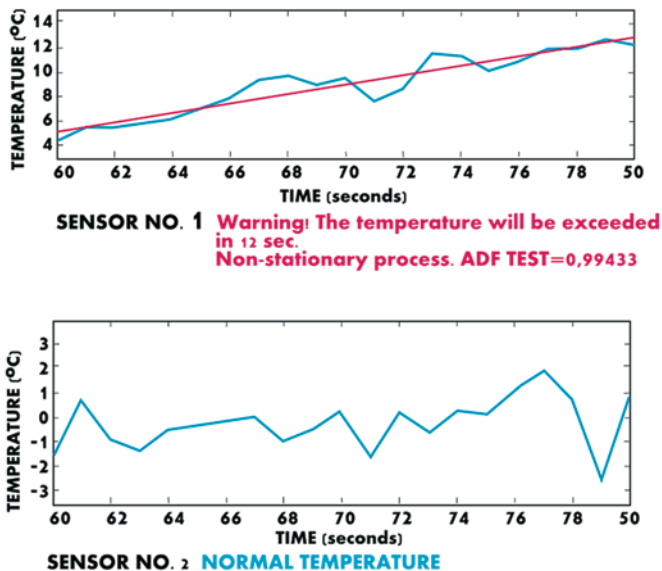


Fig. 4 Notification about process non-stationarity generated due to changes in temperature (developed by the authors)

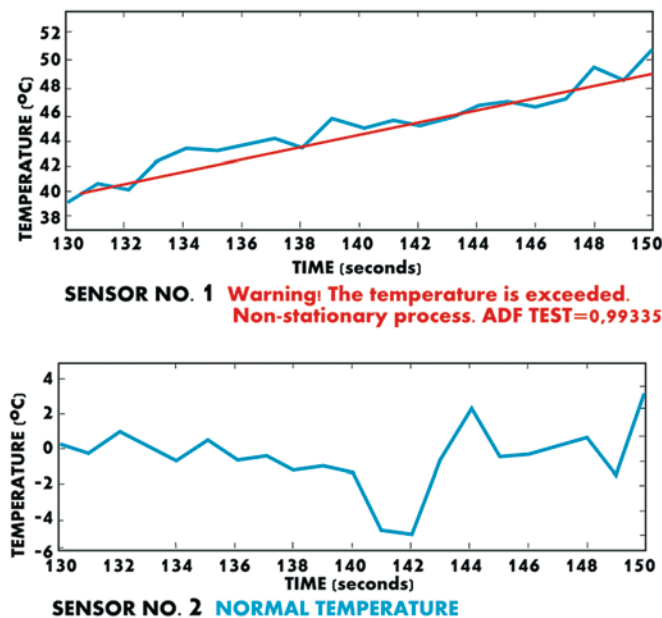


Fig. 5 Notification that the temperature has been exceeded on Sensor 1 (prepared by the authors)

References

1. Antosz K, Stadnicka D. Evaluation measures of machine operation effectiveness in large enterprises: study results. *Eksploracja i Niezawodność – Maintenance and Reliability* 2015; 17 (1): 107–117, <http://dx.doi.org/10.17531/ein.2015.1.15>.
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, <http://dx.doi.org/10.1016/j.dss.2003.09.003>.
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. *Ekonomometria*. 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.utzymanieruchu.pl/menu-gorne/artukul/article/rosnaca-rola-systemow-cmms/> (dostęp: 12.03.2015r.).
10. Doman M., Doman R. *Ekonomometryczne modelowanie dynamiki polskiego rynku finansowego*. Poznań: Wydawnictwo Akademii Ekonomicznej w Poznaniu, 2004.

6. Conclusions

The control of a machine park is one of the factors that enable increasing operational efficiency. While the monitoring of diagnostic parameters does not provide a basis for deciding about the necessity of taking maintenance and repair activities, this decision can be taken based on adequate mathematical models for data analysis. One-symptom diagnostics can be performed using statistical stationary tests such as the ADF and KPSS tests, as demonstrated by the MATLAB simulation. The detection of non-stationarity and the determination of a residual operational time of a device can serve as a guideline for maintenance services, signalling that it is necessary to undertake maintenance activities regarding subassemblies or machine components exhibiting alarming changes. This is proved by the simulation results – the alarming changes in the diagnostic parameter, i.e. temperature, were signaled in the programme and, additionally, the predicted time to failure occurrence was announced.

The above statistical tests can be applied for failure prediction due to the fact that they enable analysis of data sets containing values of monitored observation vectors describing machine condition. With the current technologies for recording values of observed parameters and easy access to data storage servers, it is possible to create extensive collections of data. If the collected data are variable and diverse, they are described as *big data* [33].

It must however be stressed that given the multi-symptom machinery diagnostics offering a broad perspective on changing condition of technical infrastructure, the proposed solution should be extended to enable detecting correlations between reduced observation vectors. It is therefore recommended establishing a standard of model development which is based on independent and complete state parameters and fosters optimization of operational efficiency. When developing such model, it should also be taken into account that some measurement results can be random.

11. Hamilton J.D. Time Series Analysis. Princeton: Princeton University Press, 1994.
12. Hetmańczyk M. Predykcje utrzymania 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, [http://dx.doi.org/10.1016/S1059-0560\(00\)00073-3](http://dx.doi.org/10.1016/S1059-0560(00)00073-3).
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, [http://dx.doi.org/10.1016/0304-4076\(92\)90104-Y](http://dx.doi.org/10.1016/0304-4076(92)90104-Y).
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, <http://dx.doi.org/10.1108/01443579810206334>
20. Loska a. exploitation assessment of selected technical objects using taxonomic methods. Eksploatacja i Niezawodność – Maintenance and Reliability 2013; 15 (1): 1–8.
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. Młynczak M. Metodyka badań eksploatacyjnych obiektów mechanicznych. Wrocław: Oficyna Wydawnicza Politechniki Wrocławskiej, 2012.
25. Muchirra 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, <http://dx.doi.org/10.1080/00207540903160766>.
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, <http://dx.doi.org/10.2307/1913712>.
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), <http://dx.doi.org/10.1108/13552511111134565>.
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 / Miłkuła 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, <http://dx.doi.org/10.1016/j.tust.2013.05.004>.
37. Żabicki D. Zastosowanie kamer termowizyjnych. Monitorowanie i Diagnostyka 2014; 2: 16-19.

Ewelina KOSICKA

Dariusz MAZURKIEWICZ

Mechanical Engineering Faculty

Lublin University of Technology

ul. Nadbystrzycka 36, 20-618 Lublin, Poland

Edward KOZŁOWSKI

Faculty of Management

Lublin University of Technology

ul. Nadbystrzycka 38, 20-618 Lublin, Poland

E-mail: e.kosicka@pollub.pl, d.mazurkiewicz@pollub.pl

e.kozlovski@pollub.pl

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

Dotrzymanie 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

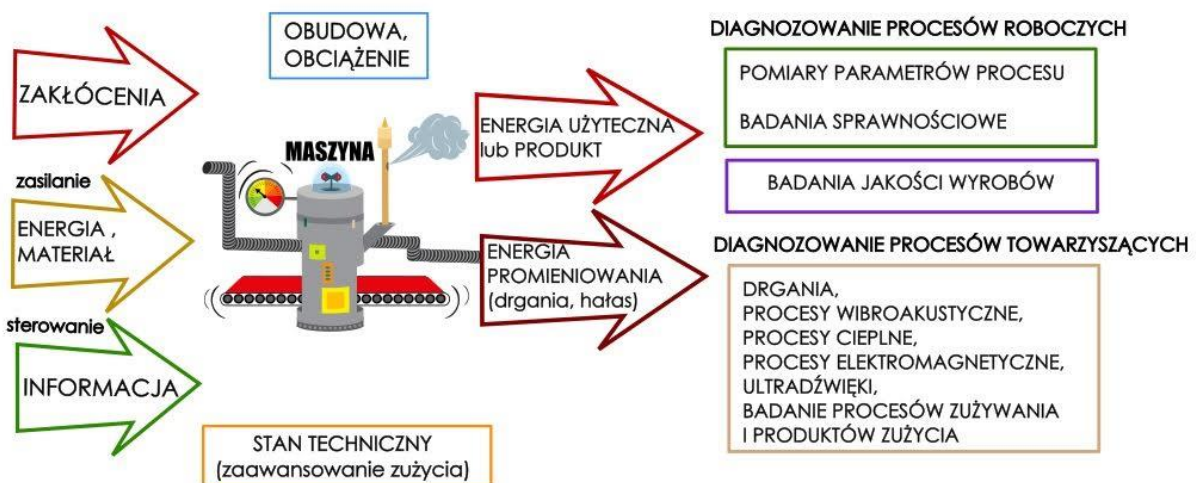
Obserwacje prowadzone w obszarze utrzymania ruchu pokazują, że w większości przedsiębiorstw dominuje podejście polegające na prowadzeniu napraw maszyn i urządzeń dopiero po awariach, w wyniku czego czas przeznaczony na prace reakcyjne przewyższa czas poświęcony na prace planowane. Skutkuje to obniżeniem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

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

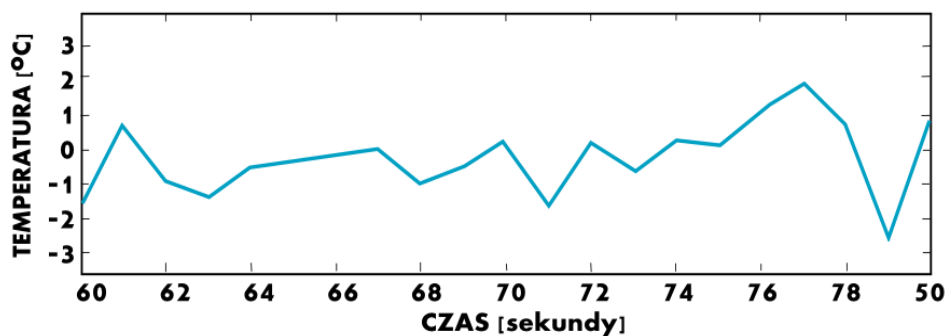
Resztkowy czas prawidłowej pracy urządzenia wyznaczono jako

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

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, Leybournna-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.