

**dr inż. Łukasz Sobaszek**

**dr inż. Arkadiusz Gola**

**prof. dr hab. inż. Antoni Świć**

Katedra Informatyzacji i Robotyzacji Produkcji

Wydział Mechaniczny, Politechnika Lubelska

ul. Nadbystrzycka 36, 20-816 Lublin, Polska

e-mail: l.sobaszek@pollub.pl, a.gola@pollub.pl, a.swic@pollub.pl

## **ALGORYTM WSPARCIA STRATEGII TBM W WIELOMASZYNOWYCH SYSTEMACH WYTWÓRCZYCH**

### **TIME-BASED PREDICTION OF MACHINE FAILURES IN MULTI-MACHINES MANUFACTURING SYSTEMS**

***Streszczenie:** Realizacja procesów produkcyjnych w rzeczywistych systemach wytwórczych wiąże się z występowaniem wielu zakłóceń, do których zalicza się głównie awarie maszyn technologicznych. W związku z tym obserwowany jest rozwój różnorodnych strategii utrzymania ruchu. Coraz większy nacisk kładziony jest na efektywne działania prewencyjne, do których zalicza się także działania określone w czasie (ang. *Time-Based Maintenance* – TBM). W niniejszej publikacji zaprezentowano algorytm predykcji awarii maszyn w wielomaszynowych systemach wytwórczych wspierający prewencyjne utrzymanie ruchu. Na wstępie omówiono zagadnienia związane z typowymi strategiami stosowanymi w obszarze UR. Ponadto omówiono tematykę predykcji awarii, zwracając uwagę na ujęcie czasu pracy maszyny jako czasu trwania, a także kluczową rolę wykorzystania danych historycznych dotyczących awarii maszyn. Następnie zaprezentowano proponowany algorytm predykcji wspierający działania określone w czasie. Prezentowane prace zakończono dwuetapową weryfikacją proponowanej metody, która potwierdziła jej skuteczność oraz zasadność wykorzystania.*

***słowa kluczowe:** system produkcyjny, utrzymanie ruchu, niezawodność, awarie maszyn, predykcja, *Time-Based Maintenance**

#### **1. Wstęp**

Rzeczywistość produkcyjna związana jest z występowaniem wielu zakłóceń, które w negatywny sposób mogą wpływać na realizowane procesy, powodując ich dezorganizację [14]. Do kluczowych czynników niepewności należy zaliczyć występowanie awarii maszyn technologicznych. Z praktycznego punktu widzenia, określenie czasu wystąpienia awarii jest niezwykle ważnym zagadnieniem. Znajomość czasów występowania usterek pomaga w podejmowaniu przemysłanych działań prewencyjnych – należy je bowiem planować tak, aby nie kolidowały one z bieżącą realizacją procesu produkcyjnego. Predykcja czasów awarii znajduje zastosowanie w obszarze strategii *Time-Based Maintenance* (TBM), gdzie coraz częściej proponowane są narzędzia informatyczne wspierające tą strategię [5, 16, 37]. Istotne jest jednak, aby proponowane rozwiązania wykorzystywały efektywne algorytmy predykcji wykorzystujące rzetelne dane historyczne na podstawie których możliwa jest wiarygodna analiza występowania usterek, a w konsekwencji planowanie odpowiednich działań serwisowych [6, 13, 40].

W literaturze przedmiotu znaleźć można wiele opracowań podejmujących problematykę predykcji zakłóceń procesu produkcyjnego. W ogólnym ujęciu, w obszarze utrzymania ruchu prowadzi się badania w kierunku opracowywania efektywnych metod zapobiegania występowaniu usterek, a także niwelowania ich wpływu [3, 33]. Planowanie działań prewencyjnych przyjmuje zazwyczaj formę podejmowania działań określonych w czasie (ang. *Time-Based Maintenance*) [13, 25], a także działań opartych na monitorowaniu warunków pracy maszyn (ang. *Conditioned-Based Maintenance*) [1, 30]. Wyraźnym trendem jest także opracowywanie scenariuszy oraz strategii eksploatacyjnych [26, 27, 34, 35, 39].

Proponowane w literaturze metody predykcji awarii można podzielić na kilka grup, wśród których wyróżnia się:

- metody bazujące na wykorzystaniu rozkładów prawdopodobieństwa,
- metody wykorzystujące typowe wskaźniki efektywności,
- alternatywne metody predykcji awarii,
- metody bazujące na wykorzystaniu danych rzeczywistych.

Zdecydowana większość proponowanych w literaturze rozwiązań opiera się na analizach rozkładów prawdopodobieństwa [8, 15, 24, 2]. Rozpatrywane są zarówno typowe rozkłady, jak i ich kombinacje. Zastosowanie znajdują różnorodne rozwiązania – od wykorzystania rozkładu jednostajnego [17, 2], poprzez bazowanie na rozkładzie normalnym [8], aż po predykcję na podstawie rozkładu wykładniczego [24, 30]. Analiza rozkładów pozwala głównie zdefiniować czas wystąpienia awarii. W literaturze proponowane są także rozwiązania bazujące na kombinacjach typowych rozkładów. Przykładowo w pracy [15] autorzy do opisu problemu występowania awarii proponują użycie kombinacji rozkładów: normalnego, trójkątnego i wykładniczego. Większość z proponowanych rozwiązań ma jednak wciąż charakter rozważań teoretycznych. Pomijany jest przez to kluczowy aspekt wykorzystania historycznych danych dotyczących awaryjności wykorzystywanych maszyn. Ponadto badacze nie argumentują w dostateczny sposób doboru rozpatrywanych rozkładów.

Kolejnym, widocznym w literaturze trendem jest wykorzystywanie dla celów predykcji typowych wskaźników efektywności, stosowanych w obszarze utrzymania ruchu takich jak:

- średni czas do wystąpienia uszkodzenia MTTF (ang. *Mean Time To Failure*),
- średni czas bezawaryjnej pracy MTBF (ang. *Mean Time Between Failures*),
- średni czas naprawy MTTR (ang. *Mean Time To Repair*).

Wykorzystanie wspomnianych wskaźników prezentowane jest wielu w pracach [9, 12, 21, 20]. Są one zazwyczaj stosowane bezpośrednio, jednak zdarza się, iż służą w pośredni sposób do oszacowania parametrów rozkładu Weibulla [21]. W ramach realizowanych badań autorzy analizują odpowiednio opracowane scenariusze, zaś wartości wskaźników przyjmują wartości z uprzednio zdefiniowanych przedziałów – dobierane są tak, aby zdarzenia występowały często, czasami lub rzadko, a następnie analizowane są konsekwencje występowania awarii [12]. Niekiedy wykorzystanie wskaźników efektywności wspierane jest zastosowaniem odpowiednich metod statystycznych [30]. Metody mające na celu wykorzystanie typowych wskaźników efektywności stosowanych w obszarze utrzymania ruchu wydają się być zasadne, gdyż parametry te dostarczają wiele informacji nt. wykorzystywanych maszyn technologicznych. Wciąż jednak pozyskiwanie i wykorzystanie rozpatrywanych wielkości traktowane jest dość teoretycznie. W publikacjach, w których proponowane są metody wykorzystujące typowe wskaźniki efektywności, brak jest weryfikacji proponowanych rozwiązań z zastosowaniem rzeczywistych danych dotyczących awaryjności maszyn [9, 20].

W obszarze alternatywnych metod predykcji awarii znaleźć można także podejścia, które znacznie różnią się od typowych rozwiązań. Warto wyróżnić tutaj rozwiązania w których: awarie zostają skumulowane do jednej i opisywane są za pomocą parametru MTTR oraz stopnia awarii MBL (ang. *Machine Breakdown Level*) [18], awaryjność określana jest na podstawie analizy rozkładów czasów obciążenia maszyn [31], do predykcji awarii maszyn wykorzystane zostają sztuczne sieci neuronowe [4], czy dobrze znane modele szeregów czasowych [38]. Podczas weryfikacji proponowanych rozwiązań wykorzystywane są jednak zazwyczaj dane testowe, często przyjęte przez autorów na podstawie opracowanych założeń upraszczających.

W publikacjach [8, 19] autorzy zwracają uwagę, iż istotną kwestią jest bazowanie na zbiorach rzeczywistych danych dotyczących procesu. Jest to sugestia, która stanowi nowe podejście w procesie predykcji awarii. Determinuje ona potrzebę opracowywania metod zorientowanych na praktyczne wykorzystanie historycznych danych dotyczących awaryjności

maszyn technologicznych. W literaturze można spotkać takie rozwiązania, jednak ich liczba jest wciąż bardzo mała [33]. Jest to wyraźny trend w obszarze predykcji awarii.

Niestety mimo wielu proponowanych przez badaczy metod, brak jest rozwiązań zorientowanych na praktyczne wykorzystanie historycznych danych dotyczących awaryjności maszyn technologicznych. Ponadto w praktyce produkcyjnej proponuje się niejednokrotnie wdrażanie rozbudowanych i kosztownych systemów monitorowania, podczas gdy w zakresie działań związanych ze strategią TBM zastosowanie zależą mogą dane posiadane przez wszystkie działy utrzymania ruchu. Dlatego też, w niniejszej pracy zaproponowany został algorytm predykcji awarii maszyn w wielomaszynowych systemach wytwórczych, który poprzez wnikliwą analizę rzeczywistych danych produkcyjnych pozwala na wnioskowanie o przyszłych czasach występowania usterek oraz podejmowanie skutecznych działań prewencyjnych. Jest on rozwiązaniem alternatywnym w stosunku do metod już istniejących, które zostały scharakteryzowane powyżej. Proponowane rozwiązanie pozwala na wykorzystanie danych posiadanych przez służby utrzymania ruchu do osiągnięcia zamierzonego celu w postaci identyfikacji możliwego momentu powstania awarii. Nowatorskim elementem proponowanej metody jest wykorzystanie elementów teorii analizy przeżycia w obszarze analizy awaryjności maszyn technologicznych, umożliwiającej wnioskowanie na podstawie danych historycznych.

## **2. Predykcja awarii z wykorzystaniem elementów analizy czasu trwania**

### **2.1. Czas pracy maszyny jako czas trwania**

Problem predykcji awarii polega w znacznym uproszczeniu na wyznaczeniu czasu w którym może wystąpić potencjalna usterka danej maszyny technologicznej wraz z prawdopodobieństwem jej wystąpienia. Do tego celu wykorzystać można elementy Analizy Przeżycia, nazywanej także Analizą Czasu Trwania [11, 23].

Ważnym elementem wykorzystania Analizy Czasu Trwania jest dokładne ustalenie istoty badanego procesu, który powinien spełniać następujące warunki [11]:

1. Zmiany dotyczące jednostki objętej badaniem muszą dokonywać się pomiędzy stanami dyskretnymi.
2. Zmiany stanów mogą występować w dowolnym momencie i nie są z góry ograniczone ustalonymi punktami w czasie.
3. Zmiany mogą być odwracalne lub nieodwracalne (w zależności od formy procesu).
4. Zmiany są ustalone z góry przez stan, w jakim znajduje się proces.
5. Istnieją czynniki wpływające na proces, a analiza pozwala na ich wykrycie.

Analizując powyższe na tle procesu występowania awarii maszyn technologicznych, należy stwierdzić, iż proces ten spełnia te wymagania. Awaria maszyny może wystąpić w dowolnej chwili i jest zmianą zachodzącą pomiędzy dwoma stanami – sprawna i uszkodzona. Ponadto uszkodzenie maszyny jest zmianą odwracalną – naprawa powoduje powrót do pierwotnego stanu, który jest definiowany przez stan, w jakim znajduje się urządzenie. Istnieje także szereg czynników, które mogą wpływać na analizowany proces i mogą być identyfikowane dzięki wykorzystaniu Analizy Czasu Trwania [36]. Czas trwania w przypadku maszyny należy rozumieć jako czas jej sprawnej pracy, na podstawie którego możliwe jest również wnioskowanie o czasie wystąpienia awarii. W konsekwencji atutem tej techniki jest możliwość wyznaczania wzorców występowania awarii (charakterystyk występowania awarii w czasie) zwłaszcza wtedy, gdy posiadane dane historyczne nie pozwalają na zastosowanie typowych technik wnioskowania [33].

Niech zatem  $T$  będzie nieujemną zmienną losową reprezentującą czas wystąpienia awarii maszyny technologicznej, która przyjmuje wartości z przedziału  $(0; \infty)$ . Ponadto  $f(t)$


jest funkcją gęstości prawdopodobieństwa, gdzie  $t > 0$  oraz  $F(t)$  jest dystrybuantą zmiennej losowej  $T$  – funkcją niemalejącą określającą, iż obiekt doświadczy zdarzenia w czasie  $(0; t]$ :

$$F(t) = P(T < t). \quad (1)$$

Bazując na dystrybuancie  $F(t)$  zdefiniować można funkcję przeżycia  $S(t)$ :

$$S(t) = 1 - F(t) = P(T \geq t) = \int_t^{\infty} f(s) ds, \quad (2)$$

pozwalającą określić prawdopodobieństwo poprawnej pracy maszyny, aż do chwili  $t$ . Pozwala ona zatem określić także prawdopodobieństwo, iż awaria nie wystąpi do tego czasu. Wyznaczona funkcja jest doskonałym sposobem określania wzorców poprawnej pracy maszyny, a w konsekwencji także występowania jej awarii. Funkcja przeżycia oraz dystrybuanta zostały przedstawione na rysunku 1.



Rys. 1. Dystrybuanta  $F(t)$  oraz funkcja przeżycia  $S(t)$

W celu wyznaczenia poszczególnych funkcji zaprezentowanych powyżej, wykorzystając należy odpowiednie dane historyczne dotyczące awaryjności maszyny technologicznej. Ich analiza dostarcza bowiem wielu informacji, które mogą zostać wykorzystane w dalszym procesie predykcji.

## 2.2. Wykorzystanie danych historycznych

Do wyznaczenia charakterystyk występowania awarii, niezbędne jest zdefiniowanie odpowiedniego źródła danych. Takie informacje gromadzone są zazwyczaj przez działy utrzymania ruchu przedsiębiorstw produkcyjnych [3, 10]. Dokonując analizy rozwiązań dotyczących zapisu wiedzy z zakresu historii konserwacji i napraw maszyn technologicznych stosowanych w przedsiębiorstwach produkcyjnych należy stwierdzić, iż najczęściej stosowanymi rozwiązaniami są:

- prowadzenie papierowej dokumentacji serwisowej – najczęściej w formie Kart Obsługi oraz Książek Serwisowych,
- wykorzystanie w procesie gromadzenia informacji serwisowych oprogramowania komputerowego wraz z dedykowanymi arkuszami danych (rys. 2),
- gromadzenie danych bezpośrednio z maszyn technologicznych, z wykorzystaniem systemów klasy SCADA (ang. *Supervisory Control And Data Acquisition*) oraz MES (ang. *Manufacturing Execution Systems*).

Machine	Shift	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	
		br	Cz	Pt	So	Nd	Pn	Wt	Br	Cz	Pt	So	Nd	Pn	Wt	Br	Cz	Pt	So	Nd	Pn	Wt	Br	Cz	Pt	So	Nd	Pn	Wt	Br	Cz	
1	I	0,67	8	0,08						8					0,3	8	0,33							8	1					2,67	0,67	8
	II						0,5			3,5					1,17	0,92	2,33													2	3,8	
	III		2,33	0,17												0,42								0,33							1,08	0,3
2	I		8							4					0,33		8						8									8
	II	2,5	1,08												0,17																	
	III		1																						1,3					1,42		
3	I	8						8	1,3		0,3					8							8							0,5		8
	II	0,33	1	0,5				0,33		1,17	0,33			1		1,17														1		
	III			0,17						1,5	0,17																			2		0,8
4	I			1,17					6		0,58					8		0,5						8	1,83	1,92				8		
	II							0,3			1,17	0,3		1,67	1								0,33	1								
	III	0,8					2,33					0,33			0,5	0,58								1,8	1					0,67		

Rys. 2. Przykład danych serwisowych zapisanych z wykorzystaniem komputerowego arkusza danych

Wszystkie z przedstawionych powyżej metod gromadzenia danych łączy wspólna cecha – każda z nich dostarcza danych, które odpowiednio przetworzone mogą zostać wykorzystane w procesie predykcji awarii maszyn z zastosowaniem elementów Analizy Przeżycia.

Podstawową informację zawartą we wspomnianej dokumentacji są historyczne czasy występowania usterek. Dla danej maszyny technologicznej  $M_j$  można zapisać je jako zbiór danych  $T_{M_j}$ :

$$T_{M_j} = \{t_1, t_2, \dots, t_n\} \text{ [godz.],} \quad (3)$$

gdzie:  $t_i$  –  $i$ -ty czas wystąpienia awarii.

Przykładowy zbiór historycznych danych dotyczący czasów awarii dla maszyny  $M_1$  przyjmie postać:

$$T_{M_1} = \{4, 8, 20, 16, 10, 28, 43, 15, 24, 2, \dots\} \text{ [godz.].}$$

Wykorzystanie w procesie predykcji danych zawartych w odpowiednich zbiorach  $T_{M_j}$  pozwala na określenie potencjalnych czasów wystąpienia awarii danej maszyny, które zapisać można w zbiorze  $FT_{M_{ij}}$ :

$$FT_{M_j} = \{ft_{M_{j1}}, ft_{M_{j2}}, \dots, ft_{M_{jn}}\}, \quad (4)$$

gdzie:  $ft_{M_{ji}}$  – czas wystąpienia awarii maszyny  $j$ ,  
 $j$  – numer rozpatrywanej maszyny technologicznej.

Dla każdego czasu  $ft_{M_{ji}}$  wyznaczone zostanie ponadto prawdopodobieństwo wystąpienia awarii zapisane w zbiorze  $P_{M_j}$ .

$$P_{M_j} = \{p_{M_{j1}}, p_{M_{j2}}, \dots, p_{M_{jn}}\}, \quad (5)$$

gdzie:  $p_{M_{ji}}$  – wartość prawdopodobieństwa wystąpienia awarii maszyny  $j$ , przy czym:

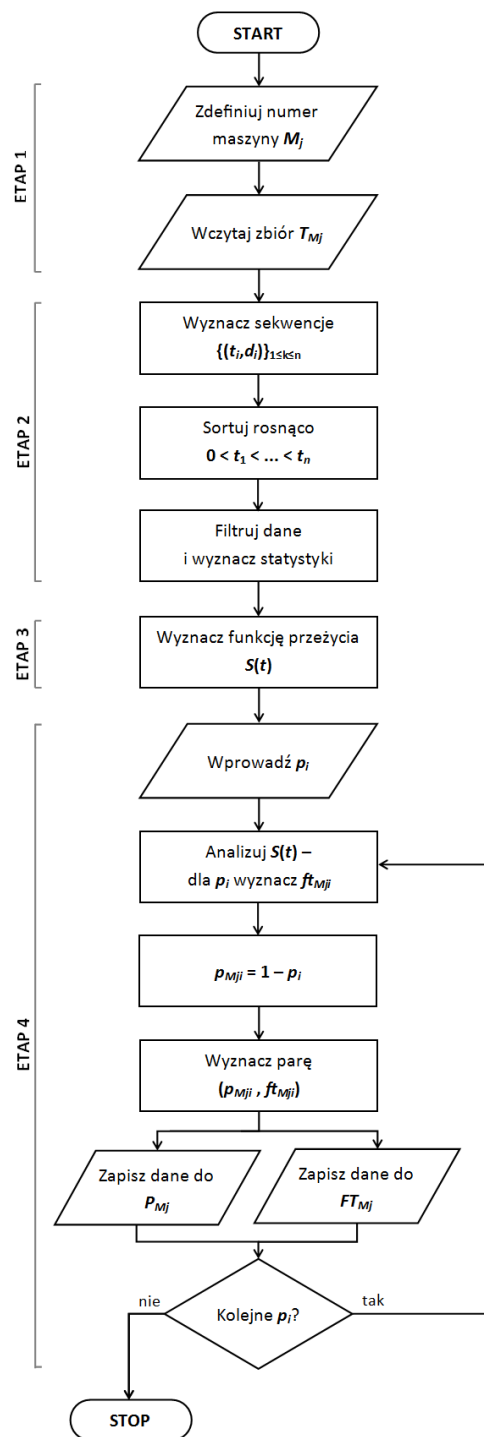
$$\bigwedge_{ft_{M_{ji}} \neq 0} p_{M_{ji}} \neq 0.$$

Zatem rezultatem procesu predykcji będzie wyznaczenie par  $(p_{M_{ji}}, ft_{M_{ji}})$  definiujących prawdopodobieństwo oraz czas wystąpienia awarii maszyny  $M_j$ .

### 2.3. Proponowany algorytm predykcji wspierający działania TBM

W celu predykcji szukanych wartości prawdopodobieństwa wystąpienia awarii oraz czasu usterki opracowano czteroetapowy algorytm umożliwiający analizę oraz odpowiednie wykorzystanie zgromadzonych danych dotyczących historii napraw (rys. 3).

Etap 1 proponowanego algorytmu polega na zdefiniowaniu maszyny dla której prowadzony będzie proces predykcji, a także zaimportowaniu danych historycznych zawartych w zbiorze  $T_{M_j}$ .



Rys. 3. Algorytm predykcji czasu wystąpienia awarii

W etapie 2 realizowany jest odpowiedni zapis zaimportowanych danych – czasy awarii wybranej maszyny technologicznej  $M_j$  zostają wówczas zapisane za pomocą odpowiedniej sekwencji:

$$\{(t_i, d_i)\}_{1 \leq k \leq n}, t_i \in T_{M_j}, \quad (6)$$


gdzie:  $t_i$  – czas pomiędzy kolejnymi awariami,

$d_i$  – liczba przypadków.

Ponadto na tym etapie realizowana jest operacja sortowania – sekwencje zostają uporządkowane według rosnących wartości  $\{t_i\}_{1 \leq k \leq n}$ :

$$0 < t_1 < t_2 < \dots < t_n, \quad (7)$$

po czym następuje filtracja zgromadzonych danych i usunięcie obserwacji odstających (wartości nietypowych) (rys. 4). Następnie wyznaczone zostają podstawowe statystyki dla zgromadzonych danych (wartość minimalna, maksymalna, średnia, rozstęp, kwartyle).



Rys. 4. Wykres pudełkowy dla przykładowych danych ( $Me$  – mediana,  $Q1$  i  $Q3$  – kwartyl 1 i 3,  $OUT$  – obserwacje odstające)


Etap 3 stanowi kluczowy element procesu wnioskowania, gdyż właśnie na tym etapie wyznaczana jest funkcja przeżycia charakteryzująca rozpatrywany proces awaryjności analizowanej maszyny. Uszeregowanie przypadków awarii według rosnących czasów ich wystąpienia, a także określenie liczby przypadków dla każdego z czasów pozwala na wyznaczenie funkcji przeżycia danego procesu. Wyznaczona postać funkcji przeżycia jest doskonałym sposobem określania wzorców występowania awarii – pozwala w przystępny sposób wyznaczyć charakterystyki awaryjności dla konkretnej maszyny technologicznej. Zastosowanie znajduje tu estymacja Kaplana-Meier’a – funkcja przeżycia wyznaczana jest wówczas na podstawie zależności:

$$\hat{S}(t) = \begin{cases} 1, & \text{dla } t < t_1, \\ \prod_{t_i \leq t} \frac{r_i - d_i}{r_i}, & \text{dla } t_1 \leq t, \end{cases} \quad (8)$$

gdzie:  $r_i$  – liczba wszystkich przypadków awarii określana jako:

$$r_i = \sum_{j=i}^k d_j. \quad (9)$$

Wówczas wyznaczona zostaje funkcja przeżycia na podstawie której (z określonym poziomem prawdopodobieństwa) określone są czasy sprawnej pracy maszyny (rys. 5).




Rys. 5. Przykładowa funkcja przeżycia wyznaczona za pomocą estymacji Kaplana-Meier'a

W konsekwencji wyznaczona funkcja przeżycia wykorzystana zostaje na etapie 4, gdzie bazując na uzyskanych wynikach można wyznaczyć elementy poszukiwanych zbiorów:

- potencjalnych czasów wystąpienia awarii rozpatrywanej maszyny  $FT_{Mj}$ ,
- prawdopodobieństwa wystąpienia awarii rozpatrywanej maszyny  $P_{Mj}$ .

Idea procesu wnioskowania na podstawie wyznaczonej postaci funkcji przeżycia została przedstawiona na rys. 6. Dla odpowiednich poziomów prawdopodobieństwa  $p_i$  wyznaczone zostają prognozowane czasy wystąpienia awarii  $ft_{Mji}$ .



Rys. 6. Określenie czasu wystąpienia awarii na podstawie przyjętej wartości prawdopodobieństwa przeżycia

Z uwagi, iż na podstawie funkcji przeżycia określone są prawdopodobieństwa sprawnej pracy maszyny ( $p_i$ ), zatem prawdopodobieństwo wystąpienia awarii  $p_{Mji}$  definiuje zależność:

$$p_{Mji} = 1 - p_i, \quad (10)$$

gdzie:  $p_{Mji}$  – prawdopodobieństwo doświadczenia usterki,  
 $p_i$  – prawdopodobieństwo sprawnej pracy maszyny.

Określenie szukanych wartości prawdopodobieństwa wystąpienia awarii  $p_{Mji}$  umożliwia wyznaczenie szukanych wartości  $ft_{Mji}$ , a w konsekwencji wyznaczenie par  $(p_{Mji}, ft_{Mji})$ . Wyznaczone dane gromadzone są w zbiorach  $P_{Mji}$  oraz  $FT_{Mji}$ . Etap 4 ma charakter iteracyjny,



a zatem jest powtarzany w zależności od decyzji użytkownika co do ilości rozpatrywanych poziomów prawdopodobieństwa. Realizację algorytmu należy powtórzyć dla kolejnych maszyn technologicznych, dla których analizowana będzie ich awaryjność.

### 3. Weryfikacja eksperymentalna proponowanego algorytmu

#### 3.1. Dane wykorzystane w procesie weryfikacji

Podstawą realizacji prezentowanej poniżej weryfikacji było pozyskanie i wykorzystanie odpowiednich danych, które dotyczyły zarówno procesów technologicznych, jak i awaryjności maszyn technologicznych. Przedstawione badania przeprowadzono w oparciu o rzeczywiste dane produkcyjne dotyczące realizacji 12 zadań produkcyjnych na 12 stanowiskach wytwórczych, zorganizowanych w postaci gniazd produkcyjnych. Wśród realizowanych procesów przeważa obróbka ubytkowa. Przykłady procesów technologicznych wybranych zadań produkcyjnych zostały przedstawione w tab. 1.

Tab. 1. Przykładowe procesy technologiczne zawarte w danych produkcyjnych

Nr wyrobu (zadania)	Nr operacji	Stanowisko	Nazwa operacji	$tpz_{ij}$ [godz.]	$to_{ij}$ [godz.]
1	10	Laser1	Cięcie blach	0,25	0,042
	20	Laser2	Cięcie rur i profili	0,20	0,017
	30	Prasa CNC	Gięcie krawędziowe	0,13	0,018
	40	Wiertarka	Wiercenie otworów	0,17	0,017
	50	Ślus.	Operacja ślusarska	0,08	0,017
	60	Spaw. – MIG	Spawanie MIG	0,13	0,092
3	10	Laser2	Cięcie laserem rur i profili	0,15	0,005
	20	Piła CNC	Cięcie na pile taśmowej	0,10	0,008
	30	Frezarka	Frezowanie	0,27	0,050
	40	Wiertarka	Wiercenie otworów	0,17	0,017
	50	Ślus.	Operacja ślusarska	0,08	0,033
	60	Spaw.– MIG	Spawanie MIG	0,13	0,033
	70	Tokarka	Toczenie	0,33	0,092
5	10	Laser1	Cięcie laserem blach	0,27	0,012
	20	Gilotyna	Cięcie na gilotynie	0,10	0,004
	30	Piła CNC	Cięcie na pile taśmowej	0,10	0,017
	40	Prasa CNC	Gięcie krawędziowe	0,17	0,025
	50	Wiertarka	Gwintowanie	0,13	0,100
	60	Ślus.	Operacja ślusarska	0,08	0,033
	70	Spaw.– TIG	Spawanie TIG	0,13	0,033
	80	Tokarka	Toczenie	0,33	0,108

Pozyskane dane rzeczywiste zostały wykorzystane w procesie weryfikacji w następującym zakresie:

- dane dotyczące awaryjności maszyn technologicznych posłużyły za dane wejściowe podczas weryfikacji opracowanego algorytmu,
- dane dotyczące realizowanych procesów wytwórczych zostały wykorzystane podczas badań symulacyjnych mających na celu ocenę skuteczności i zasadności wykorzystania proponowanego algorytmu w realnych warunkach produkcyjnych (z uwzględnieniem występowania awarii maszyn technologicznych).


### 3.2. Predykcja czasu wystąpienia awarii

W celu weryfikacji proponowanego algorytmu opracowano w języku R odpowiedni skrypt umożliwiający jego realizację. Następnie z wykorzystaniem pozyskanych danych historycznych przeprowadzono proces wnioskowania o potencjalnych czasach awarii maszyn znajdujących się na poszczególnych stanowiskach. Dla poszczególnych maszyn przyjęto odpowiednie oznaczenia:

- Laser 1 – maszyna  $M_1$ ,
- Laser 2 – maszyna  $M_2$ ,
- Prasa CNC – maszyna  $M_3$ ,
- Piła CNC – maszyna  $M_4$ ,
- Stanowisko ślusarskie – maszyna  $M_5$ ,
- Spawalnia – MIG – maszyna  $M_6$ ,
- Spawalnia – TIG – maszyna  $M_7$ ,
- Wiertarka – maszyna  $M_8$ ,
- Frezarka – maszyna  $M_9$ ,
- Tokarka – maszyna  $M_{10}$ ,
- Gilotyna – maszyna  $M_{11}$ ,
- Wykrawarka – maszyna  $M_{12}$ .

W dalszej części przedstawiono przykładową realizację procesu predykcji awarii dla maszyny  $M_6$ , w przypadku której dane historyczne liczyły 121 obserwacji

Przed rozpoczęciem procesu predykcji w skrypcie zawarto odpowiednie polecenia przygotowujące środowisko do pracy, po czym następuje zdefiniowanie numeru maszyny, oraz wczytanie danych zgromadzonych w pliku CSV. Import danych do zbioru  $T_{M_6}$  przechowywanej w przestrzeni roboczej umożliwił realizację procesu sortowania obserwacji rosnąco, a także filtrację danych w której zastosowanie znalazły wygenerowane wykresy pudełkowe (rys. 7). Dodatkowo wyznaczone zostały podstawowe statystyki (rys. 8).



Rys. 7. Wykresy pudełkowe – przed oraz po filtrowaniu danych

"Awaryjność maszyny M6 - zbiór TM6 - podstawowe statystyki:"					
Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
8.00	8.00	24.00	32.48	48.00	104.00

Rys. 8. Podstawowe statystyki wygenerowane w ramach opracowanego skryptu


Kluczowym etapem algorytmu predykcji awarii jest wyznaczenie funkcji przeżycia  $\hat{S}(t)$  z wykorzystaniem estymacji Kaplana-Meier'a. W opracowanym skrypcie była ona możliwa dzięki zastosowaniu biblioteki „SURVIVAL”. Kolejne różnice krzywej schodkowej obliczane zostały w sposób automatyczny na podstawie utworzonych sekwencji obserwacji. Rezultatem było wyznaczenie funkcji przeżycia w postaci krzywej schodkowej z 95% przedziałem ufności.

Wyznaczenie przebiegu szukanej funkcji  $\hat{S}(t)$ , umożliwiło rozpoczęcie kolejnego etapu algorytmu jakim jest predykcja wartości czasu wystąpienia awarii rozpatrywanej maszyny dla zdefiniowanych poziomów prawdopodobieństwa (rys. 9). Ponieważ na wykresie odczytać można prawdopodobieństwo sprawnej pracy maszyny, dodatkowo generowana była legenda pomocnicza z objaśnieniami. W przypadku obliczeń dla danych maszyny  $M_6$  (jak i pozostałych maszyn) rozpatrywano następujące poziomy prawdopodobieństwa:

$$p_1 = 0,75; \quad p_2 = 0,50; \quad p_3 = 0,25.$$

Wartości rozpatrywanych poziomów zostały zaś dobrane tak, aby wyznaczały: niski, średni oraz wysoki stopień ryzyka wystąpienia usterki rozpatrywanej maszyny. Stąd też:

$$p_{M61} = 1 - p_1 = 0,25; \quad p_{M62} = 1 - p_2 = 0,50; \quad p_{M63} = 1 - p_3 = 0,75.$$



Rys. 9. Predykcja awarii na podstawie wyznaczonej funkcji przeżycia

W ten sposób wyznaczone zostały szukane wartości prawdopodobieństw wystąpienia awarii oraz czasów potencjalnych usterek, które zapisać można jako pary:

$$(p_{M61}, ft_{M61}) = (0,25, 8 \text{ godz.}),$$

$$(p_{M62}, ft_{M62}) = (0,50, 24 \text{ godz.}),$$

$$(p_{M63}, ft_{M63}) = (0,75, 48 \text{ godz.}).$$

W konsekwencji wyznaczono zbiory  $P_{M61} = \{0,25, 0,50, 0,75\}$  oraz  $FT_{M61} = \{8, 24, 48\}$  [godz.].

Proponowany algorytm wykorzystano w takim samym zakresie dla pozostałych maszyn technologicznych. Jedynie z uwagi na charakter stanowiska ślusarskiego ( $M_5$ ) proces predykcji w tym przypadku nie był realizowany. Uzyskane czasy wystąpienia awarii zostały zestawione w tab. 2.

Tab. 2. Czasy awarii maszyn technologicznych uzyskane w wyniku predykcji

Maszyna	Czas wystąpienia awarii [godz.]		
	$p_{Mj1} = 0,25$	$p_{Mj2} = 0,50$	$p_{Mj3} = 0,75$
$M_1$	8	16	40
$M_2$	8	24	32
$M_3$	8	16	24
$M_4$	8	24	104
$M_5$	–	–	–
$M_6$	8	24	48
$M_7$	8	16	40
$M_8$	8	24	48
$M_9$	8	16	40
$M_{10}$	8	24	40
$M_{11}$	8	16	40
$M_{12}$	8	16	32

Uzyskane rezultaty realizacji algorytmu zostały wykorzystane w dalszej części procesu weryfikacji polegającej na symulacji produkcji w warunkach występowania awarii maszyn technologicznych.

### 3.3. Symulacja produkcji z warunkach niepewności

W celu weryfikacji proponowanego algorytmu w realnych warunkach produkcyjnych, związanych z występowaniem niepewności dotyczącej awaryjności maszyn technologicznych, przeprowadzono dwuetapowy eksperyment w którym:

1. Dla rzeczywistych danych produkcyjnych zbudowano harmonogramy produkcji (harmonogramy nominalne), a następnie opracowano ich odpowiedniki z zaimplementowanymi buforami serwisowymi (harmonogramy odporne) w miejscach, na jakie wskazywały rezultaty zastosowania opracowanego algorytmu.
2. Przeprowadzono symulację produkcji zgodnie z opracowanymi harmonogramami, a następnie zbadano, które z harmonogramów wskazywały bliższy termin zakończenia produkcji w warunkach, gdy wystąpić mogą awarie maszyn.


#### 3.3.1. Opracowanie harmonogramów produkcji

W celu weryfikacji metody dla różnego uszeregowania zadań na poszczególnych stanowiskach produkcyjnych w procesie budowania harmonogramów wykorzystano 4 popularne reguły priorytetów:

1. Regułę FCFS (*First Come First Service – Pierwsza Przybyła Pierwsza Obsłużona*).
2. Regułę EDD (*Earliest Due Date – Najwcześniejszy Termin Dyrektywny*).
3. Regułę SPT (*Shortest Processing Time – Najkrótszy Czas Operacji*).
4. Regułę LPT (*Longest Processing Time – Najdłuższy Czas Operacji*).


Przyjęto, iż wyroby produkowane są w partiach po 50 sztuk, a kryterium celu był termin zakończenia wszystkich zadań produkcyjnych – wskaźnik  $C_{max}$ .

Narzędziem harmonogramowania zadań było oprogramowanie LiSA będące zbiorem powszechnie stosowanych algorytmów szeregowania zadań i umożliwiające budowanie harmonogramów w typowych środowiskach produkcyjnych (*flow-shop*, *job-shop* czy *open-shop*) wraz z uwzględnieniem wybranych ograniczeń i kryteriów oceny [7]. Na rys. 10 przedstawiono przykładowy harmonogram uzyskany w wyniku działania reguły LPT.



Rys. 10. Harmonogram nominalny – działanie reguły LPT

W celu uwzględnienia potencjalnych awarii maszyn technologicznych dokonano modyfikacji harmonogramów poprzez implementację buforów serwisowych o wielkości 0,5 godziny, mających charakter zabezpieczeń czasowych w przypadku wystąpienia awarii oraz czasu na dokonanie niezbędnej inspekcji, bądź działań serwisowych. Bufory implementowano zgodnie z czasami wyznaczonymi w wyniku realizacji algorytmu (tabela 2). Przyjęto, iż jest to wyłącznie czas pracy maszyny (realizacji zadań), po jakim może wystąpić usterka. Jeżeli w danym miejscu harmonogramu występowała operacja technologiczna – była ona przesuwana w prawo (zaraz za bufor) przy jednoczesnym zachowaniu kolejności zadań na jaki wskazywał harmonogram nominalny. Przykład harmonogramu odpornego z zaimplementowanymi buforami serwisowymi został przedstawiony na rysunku 11 (bufory oznaczono w postaci białych bloków).




Rys. 11. Harmonogram produkcji po implementacji buforów serwisowych

Uzyskane czasy zakończenia wszystkich zadań produkcyjnych w harmonogramach nominalnych oraz odpornych przedstawiono w tabeli 3.

Tab. 3. Uzyskane wartości wskaźnika  $C_{max}$

Reguła priorytetu	Termin zakończenia zadań produkcyjnych – wskaźnik $C_{max}$ [godz.]		
	harmonogram nominalny	harmonogram odporny	wydłużenie [%]
FCFS	43,68	52,44	16,7%
EDD	42,59	49,42	13,8%
SPT	48,92	55,75	12,3%
LPT	49,10	53,69	8,5%

Uzyskane podczas eksperymentu wartości terminów zakończenia wszystkich zleceń po implementacji buforów serwisowych spowodowały wydłużenie kryterium celu dla każdego z przypadków. Średnia różnica pomiędzy wskaźnikiem  $C_{max}$  harmonogramu nominalnego i odpornego wyniosła 6,75 godz. Można zatem stwierdzić, iż uwzględnienie aspektu występowania awarii maszyn powoduje, iż produkcja będzie realizowana o około jedną zmianę dłużej. Procentowe wydłużenia analizowanego wskaźnika były odmienne dla harmonogramów uzyskanych z wykorzystaniem różnych reguł priorytetu. Przyjmowały one wartości od 8,5% dla harmonogramu opracowanego zgodnie z regułą LPT do 16,7% dla harmonogramu opracowanego z wykorzystaniem reguły FCFS. Uzyskane wartości terminów realizacji wszystkich zadań dla poszczególnych harmonogramów zostały zestawione na rysunku 12.




Rys. 12. Wartości wskaźnika  $C_{max}$  – terminu zakończenia wszystkich zadań

W celu oceny zasadności implementacji buforów, a w konsekwencji wydłużenia harmonogramu produkcji przeprowadzono drugą część eksperymentu polegającą na symulacji produkcji w warunkach niepewności. Pozwolił on wskazać, który z harmonogramów – nominalny czy odporny (uzyskany z wykorzystaniem proponowanego algorytmu) – wskazuje bliższy realnemu termin zakończenia wszystkich zadań produkcyjnych.

### 3.3.2. Symulacja produkcji w warunkach występowania awarii maszyn

Drugi etap eksperymentu został zrealizowany w środowisku symulacyjnym Enterprise Dynamics, którego obszary zastosowań obejmują: produkcję, magazynowanie, zarządzanie łańcuchem dostaw, systemy transportu i inne. Umożliwia ono zarówno modelowanie, symulację, jak i wizualizację procesów, co czyni z niego narzędzie pomocne w procesie kontroli procesów dynamicznych [14, 16, 22]. Za pomocą dostępnych elementów środowiska wykonano model pozwalający analizować realizację produkcji w rozpatrywanym systemie wytwórczym (rys. 13).



Rys. 13. Model systemu produkcyjnego opracowany w środowisku ED

W celu uwzględnienia awaryjności maszyn technologicznych dla każdej z nich (we właściwościach danego bloku) zdefiniowano wartości wskaźników MTTF oraz MTTR. Wartości parametru MTTF zostały zdefiniowane z wykorzystaniem jednostajnego rozkładu prawdopodobieństwa tak, aby awarie występowały w dowolnym czasie – od chwili rozpoczęcia pracy na danej maszynie, aż do chwili jej zakończenia. Parametr MTTR został określony z wykorzystaniem rozkładu gamma, gdyż właśnie taki rozkład został zidentyfikowany oraz dopasowany podczas analizy statystycznej posiadanych danych historycznych dotyczących czasów napraw maszyn. Przyjęte parametry wskaźników MTTF oraz MTTR dla poszczególnych maszyn zostały przedstawione w tabeli 4. Czas stanowiące parametry rozkładów zostały wyrażone w godzinach.

Tab. 4. Czasy awarii maszyn technologicznych uzyskane w wyniku predykcji

Maszyna	Parametry wskaźników efektywności	
	MTTF	MTTR
$M_1$	Uniform(0, 18,42)	Gamma(0,85, 1,62)
$M_2$	Uniform(0, 8,0)	Gamma(0,75, 2,07)
$M_3$	Uniform(0, 16,08)	Gamma(0,69, 2,79)
$M_4$	Uniform(0, 3,33)	Gamma(0,77, 1,88)
$M_5$	–	–
$M_6$	Uniform(0, 23,74)	Gamma(0,95, 2,43)
$M_7$	Uniform(0, 8,34)	Gamma(0,93, 1,96)
$M_8$	Uniform(0, 22,41)	Gamma(0,66, 2,45)
$M_9$	Uniform(0, 6,67)	Gamma(0,80, 1,64)
$M_{10}$	Uniform(0, 16,84)	Gamma(0,72, 1,85)
$M_{11}$	Uniform(0, 0,21)	Gamma(0,88, 2,16)
$M_{12}$	Uniform(0, 5,5)	Gamma(0,84, 1,78)

W opracowanym modelu modyfikowano także kolejność realizacji zadań na poszczególnych maszynach (tak, aby produkcja odbywała się zgodnie z harmonogramami opracowanymi z wykorzystaniem reguł: FCFS, EDD, SPT oraz LPT). W sumie badaniu poddano 4 modele, a w każdym z nich zrealizowano 25 symulacji produkcji.

Podczas oceny rezultatów przeprowadzonych badań symulacyjnych wykorzystano następujące wskaźniki stabilności:

- wskaźnik odchylenia terminu zakończenia wszystkich zadań  $\Delta C_{\max}$  określany jako:

$$\Delta C_{\max} = C_{\max} - C'_{\max}, \quad (11)$$

gdzie:  $\Delta C_{\max}$  – odchylenie terminu zakończenia wszystkich zadań,

$C_{\max}$  – długość harmonogramu bazowego,

$C'_{\max}$  – długość harmonogramu aktualnego (zrealizowanego).

- wskaźnik względnego wydłużenia terminu zakończenia wszystkich prac  $E_{C_{\max}}$ , określanego na podstawie zależności:

$$E_{C_{\max}} = \frac{C_{\max}}{C'_{\max}}, \quad (12)$$

gdzie:  $E_{C_{\max}}$  – wskaźnik względnego wydłużenia terminu zakończenia wszystkich prac.

W tabeli 5 przedstawiono wyniki symulacji dla przypadku, gdy zadania produkcyjne uszeregowane były zgodnie z działaniem reguły SPT. Dla każdej z symulacji uzyskane wartości wskaźników stabilności potwierdziły skuteczność oraz zasadność wykorzystania proponowanego algorytmu. Zarówno wartości odchylenia terminu zakończenia wszystkich zadań  $\Delta C_{\max}$ , jak i względnego wydłużenia terminu zakończenia wszystkich  $E_{C_{\max}}$  wykazały, iż harmonogram uwzględniający potencjalne awarie maszyn technologicznych wskazuje bliższy realnemu termin zakończenia wszystkich zadań produkcyjnych.



Tab. 5. Wartości wskaźników stabilności – kolejność zadań zgodnie z regułą SPT

Nr sym.	Harmonogram zrealizowany (symulacja) $C'_{\max}$ [godz.]	Odchylenie terminu zakończenia oraz względne wydłużenia terminu zakończenia					
		harmonogram nominalny			harmonogram odporny		
		$C_{\max}$ [godz.]	$\Delta C_{\max}$ [godz.]	$E_{C_{\max}}$ [-]	$C_{\max}$ [godz.]	$\Delta C_{\max}$ [godz.]	$E_{C_{\max}}$ [-]
1	56,10	48,92	-7,18	0,87	55,75	-0,35	0,99
2	53,88		-4,96	0,91		1,87	1,03
3	54,09		-5,17	0,90		1,66	1,03
4	56,91		-7,99	0,86		-1,16	0,98
5	52,60		-3,68	0,93		3,15	1,06
6	55,50		-6,58	0,88		0,25	1,00
7	56,43		-7,51	0,87		-0,68	0,99
8	55,88		-6,96	0,88		-0,13	1,00
9	53,48		-4,56	0,91		2,27	1,04
10	54,04		-5,12	0,91		1,71	1,03
11	58,31		-9,39	0,84		-2,56	0,96
12	52,97		-4,05	0,92		2,78	1,05
13	54,20		-5,28	0,90		1,55	1,03
14	55,33		-6,41	0,88		0,42	1,01
15	55,98		-7,06	0,87		-0,23	1,00
16	56,01		-7,09	0,87		-0,26	1,00
17	53,53		-4,61	0,91		2,22	1,04
18	56,51		-7,59	0,87		-0,76	0,99
19	55,18		-6,26	0,89		0,57	1,01
20	56,49		-7,57	0,87		-0,74	0,99
21	52,37		-3,45	0,93		3,38	1,06
22	57,52		-8,60	0,85		-1,77	0,97
23	54,86		-5,94	0,89		0,89	1,02
24	55,04		-6,12	0,89		0,71	1,01
25	54,83		-5,91	0,89		0,92	1,02


W przypadku pozostałych symulacji również została potwierdzona zasadność proponowanych w niniejszej publikacji rozwiązań. Świadczą o tym wartości średnie z poszczególnych symulacji zestawione w tabeli 6.

Tab. 6. Wartości średnie rozpatrywanych wskaźników stabilności

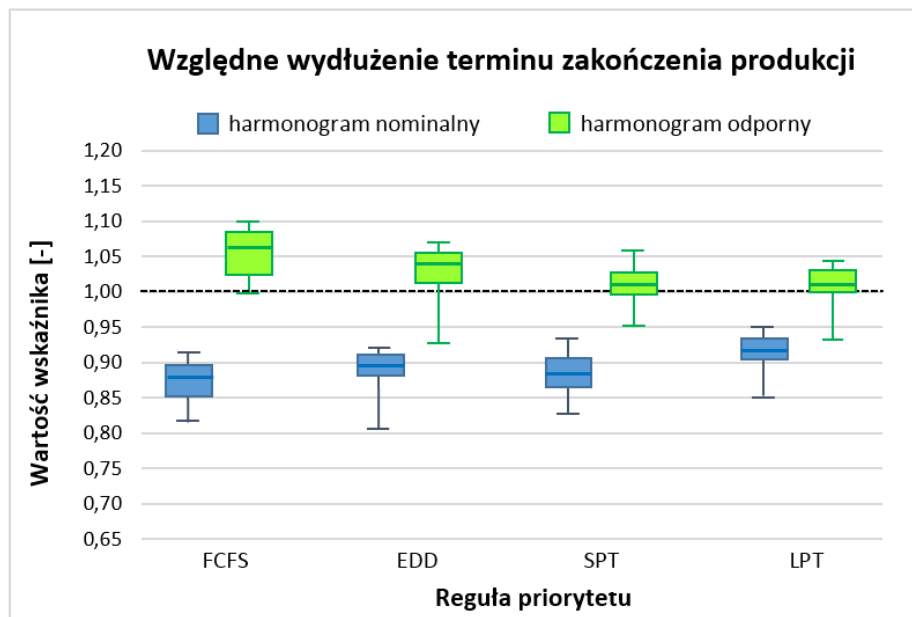
Reguła priorytetu	Harmonogram zrealizowany (symulacja) $\bar{C}'_{\max}$ [godz.]	Odchylenie terminu zakończenia oraz względne wydłużenia terminu zakończenia					
		harmonogram nominalny			harmonogram odporny		
		$C_{\max}$ [godz.]	$\Delta \bar{C}_{\max}$ [godz.]	$\bar{E}_{C_{\max}}$ [-]	$C_{\max}$ [godz.]	$\Delta \bar{C}_{\max}$ [godz.]	$\bar{E}_{C_{\max}}$ [-]
FCFS	49,87	43,68	-6,19	0,88	52,44	2,57	1,05
EDD	47,90	42,59	-5,31	0,89	49,42	1,52	1,03
SPT	55,12	48,92	-6,20	0,89	55,75	0,63	1,01
LPT	53,14	49,10	-4,04	0,92	53,69	0,55	1,01

Uzyskane wartości wskazują wyraźnie, iż harmonogram z zaimplementowanymi buforami serwisowymi wskazywał bliższy realnemu termin zakończenia produkcji.

Na rysunku 14 oraz 15 zestawiono uzyskane wartości rozpatrywanych wskaźników, które również potwierdzają zasadność wykorzystania proponowanego algorytmu.



Rys. 14. Wartość wskaźnika odchylenia terminu zakończenia wszystkich zadań  $\Delta C_{\max}$



Rys. 15. Wartości wskaźnika względnego wydłużenia terminu zakończenia wszystkich prac  $E_{C_{\max}}$

Wykorzystanie opracowanego algorytmu pozwala wskazać bliższy realnemu termin zakończenia produkcji w warunkach, gdy istnieje ryzyko wystąpienia awarii maszyn technologicznych. Świadczy o tym chociażby fakt, iż dla harmonogramu odpornego wartości wskaźnika  $E_{C_{\max}}$  koncentrują się w okolicy wartości 1, zaś wartość wskaźnika  $\Delta C_{\max}$  w okolicy 0 – oznacza to dużą zgodność terminów zakończenia produkcji w harmonogramach odpornych z terminami uzyskanymi w wyniku symulacji produkcji.

#### 4. Podsumowanie i wnioski końcowe

Predykcja awarii maszyn jest tematem wielu publikacji naukowych. Autorzy licznych prac starają się implementować różnorodne metody w celu wyznaczenia informacji dotyczących awaryjności maszyn technologicznych. Wiarygodne i dobrze opracowane plany prac prewencyjnych stanowią kluczowy element działań związanych z utrzymaniem ruchu, szczególnie w obszarze wykorzystania strategii *Time-Based Maintenance*.

W niniejszej pracy zaprezentowano algorytm predykcji zorientowany na wykorzystanie typowych danych historycznych, posiadane przez działy UR. Proponowany algorytm stanowi alternatywne podejście do problemu predykcji awarii, bowiem wykorzystanie estymacji Kaplana-Meier'a pozwala na wyznaczenie charakterystyk występowania awarii w czasie dla poszczególnych maszyn technologicznych systemu wytwórczego, co w konsekwencji wspomaga działania TBM. Zastosowanie elementów analizy czasu trwania powoduje, iż przedstawione rozwiązanie jest innowacyjnym oraz konkurencyjnym w zakresie wnioskowania na podstawie rzeczywistych danych historycznych. W konsekwencji kluczowym aspektem staje się zatem gromadzenie rzetelnych danych dotyczących awaryjności maszyn. Tylko odpowiednia ilość oraz jakość danych historycznych pozwala uzyskać wiarygodne i miarodajne rezultaty.

Opracowany algorytm wpisuje się w tendencję coraz szerszego wykorzystania narzędzi informatycznych w pracach działów UR. Dlatego też został on opracowany w taki sposób, aby możliwa była jego implementacja w postaci programu komputerowego, bądź dodatku do znanych już rozwiązań. Weryfikacja proponowanego algorytmu pozwoliła wyznaczyć potencjalne czasy występowania awarii maszyn technologicznych. Należy zauważyć, iż dla analizowanych maszyn czasy te były różne, co oznacza, iż każda z nich posiada własną charakterystykę występowania usterek. Potwierdza to słuszność oraz potrzebę wykorzystania strategii TBM w procesie utrzymywania ruchu obiektów technicznych. Uzyskane informacje są również niezwykle istotne w aspekcie realizacji produkcji w warunkach niepewności. Przeprowadzone w drugiej części publikacji badania symulacyjne dowodzą, iż wykorzystanie rezultatów proponowanego algorytmu w procesie planowania produkcji, pozwala uzyskać stabilność realizowanych procesów, a w konsekwencji wskazywać bliższe realnemu terminy zakończenia produkcji.

Zrealizowane badania potwierdzają skuteczność opracowanego algorytmu predykcji, a także wskazują na potrzebę realizacji działań prewencyjnych w kierunku zapobiegania występowaniu awarii maszyn w celu zapewnienia większej stabilności realizowanych procesów.

*Projekt/Badania zostały sfinansowane z Projektu Politechnika Lubelska – Regionalna Inicjatywa Doskonałości ze środków Ministerstwa Nauki i Szkolnictwa Wyższego na podstawie umowy nr 030/RID/2018/19.*

#### References

1. Albrice D, Branch M. A Deterioration Model for Establishing an Optimal Mix of Time-Based Maintenance (TbM) and Condition-Based Maintenance (CbM) for the Enclosure System. Fourth Building Enclosure Science & Technology Conference (BEST4), Kansas City, Missouri, April 13–15, 2015.
2. Al-Hinai N, ElMekkawy TY. Robust and Stable Flexible Job Shop Scheduling with Random Machine Breakdowns Using a Hybrid Genetic Algorithm. *International Journal of Production Economics* 2011, 132(2): 279–291, <http://dx.doi.org/10.1016/j.ijpe.2011.04.020>.

3. Antosz K, Stadnicka D. Evaluation measures of machine operation effectiveness in large enterprises: study results. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2015; 17(1): 107–117, <http://dx.doi.org/10.17531/ein.2015.1.15>.
4. Baptista M, Sankararaman S, de Medeiros IP, Nascimento C, Prendinger H, Henriques EMP. Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling, *Computers & Industrial Engineering* 2018, 115: 41–53, <https://doi.org/10.1016/j.cie.2017.10.033>.
5. Bartochowska D, Ferenc R. Instrumenty wsparcia utrzymania ruchu w małych i średnich przedsiębiorstwach. *Zeszyty naukowe Politechniki Śląskiej* 2015, 80: 21–50.
6. Bei XQ, Zhu XY, Coit DW. A risk-averse stochastic program for integrated system design and preventive maintenance planning. *European Journal Of Operational Research* 2019, 276(2): 536–548, <http://dx.doi.org/10.1016/j.ejor.2019.01.038>.
7. Bräsel H, Dornheim L, Kutz S, Mörig M, Rössling I. *LiSA – A Library of Scheduling Algorithms*. Magdeburg University, 2001.
8. Davenport A, Gefflot C, Beck C. Slack-based Techniques for Robust Schedules. Sixth European Conference on Planning, Toledo, Spain, September 12–14, 2001.
9. Deepu P. *Robust Schedules and Disruption Management for Job Shops*. Bozeman, Montana, 2008.
10. Fernandes M, Canito A, Bolon-Canedo V, Conceicao L, Praca I, Marreiros G. Data analysis and feature selection for predictive maintenance: A case-study in the metallurgic industry. *International Journal Of Information Management* 2019, 45: 252–262, <http://dx.doi.org/10.1016/j.ijinfomgt.2018.10.006>.
11. Frątczak E, Sienkiewicz U, Babiker H. *Analiza historii zdarzeń – Elementy teorii, wybrane przykłady zastosowań*. Oficyna Wydawnicza Szkoła Główna Handlowa w Warszawie, Warszawa 2014.
12. Gao H. *Bulding Robust Schedules using Temporal Potection – An Empirical Study of Constraint Based Scheduling Under Machine Failure Uncertainty*. Toronto, Ontario, 1996.
13. Gao Y, Feng Y, Zhang Z, Tan J. An optimal dynamic interval preventive maintenance scheduling for series systems. *Reliability Engineering & System Safety* 2015, 142: 19–30, <http://dx.doi.org/10.1016/j.ress.2015.03.032>.
14. Gola A. Reliability analysis of reconfigurable manufacturing structures using computer simulation methods. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2019; 21(1): 90–102, <http://dx.doi.org/10.17531/ein.2019.1.11>.
15. Gürel S, Körpeoğlu E, Aktürk MS. An Anticipative Scheduling Approach with Controllable Processing Times. *Computers & Operations Research* 2010, 37(6): 1002–1013, <http://dx.doi.org/10.1016/j.cor.2009.09.001>.
16. Jasiulewicz-Kaczmarek M, Bartkowiak T. Improving the performance of a filling line based on simulation, *ModTech International Conference – Modern Technologies in Industrial Engineering IV*, Romania, Iasi, June 15–18, IOP Conf. Series: Materials Science and Engineering 2016, 145(042024), <https://doi.org/10.1088/1757-899X/145/4/042024>.
17. Jensen MT. Improving robustness and flexibility of tardiness and total flow-time job shops using robustness measures. *Applied Soft Computing* 2001, 1: 35–52, [http://dx.doi.org/10.1016/S1568-4946\(01\)00005-9](http://dx.doi.org/10.1016/S1568-4946(01)00005-9).
18. Jian X, Li-Ning X, Ying-Wu Ch. Robust Scheduling for Multi-Objective Flexible Job-Shop Problems with Random Machine Breakdowns. *International Journal of Production Economics* 2013, 141(1): 112–126. <https://doi.org/10.1016/j.ijpe.2012.04.015>.

19. Kalinowski K, Krenczyk D, Grabowik C. Predictive-reactive strategy for real time scheduling of manufacturing systems. *Applied Mechanics and Materials* 2013, 307: 470–473, <https://doi.org/10.4028/www.scientific.net/AMM.307.470>.
20. Kempa W, Paprocka I, Kalinowski K, Grabowik C. Estimation of reliability characteristics in a production scheduling model with failures and time-changing parameters described by Gamma and exponential distributions. *Advanced Materials Research* 2014, 837: 116–121.
21. Kempa W, Wosik I, Skołod B. Estimation of Reliability Characteristics in a Production Scheduling Model with Time-Changing Parameters – First Part, Theory. *Management and Control of Manufacturing Processes*. Lublin, 2011: 7–18.
22. Kłós S, Patalas-Maliszewska J, Trebuna P. Improving manufacturing processes using simulation methods. *Applied Computer Science* 2016, 12(4): 7–17.
23. Lawless J. F. *Statistical Models and Methods for Lifetime Data*. John Wiley & Sons, 2003.
24. Leon VJ., Wu SD., Storer RH. Robustness Measures and Robust Scheduling for Job Shops. *IIE transactions* 1994, 26(5): 32–43, <https://doi.org/10.1080/07408179408966626>.
25. Liao W, Zhang X, Jiang M. An optimization model integrated production scheduling and preventive maintenance for group production. *IEEE International Conference on Industrial Engineering and Engineering Management* 2016, December, 936–940, <http://dx.doi.org/10.1109/IEEM.2016.7798015>.
26. Loska A. Scenario modeling exploitation decision-making process in technical network systems. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2017; 19 (2): 268–278, <http://dx.doi.org/10.17531/ein.2017.2.15>.
27. Lü Y, Zhang Y. Reliability Modeling and Maintenance Policy Optimization for Deteriorating System Under Random Shock. *Journal of Shanghai Jiaotong University (Science)* 2018, 23(6): 791–797, <http://dx.doi.org/10.1007/s12204-018-1985-y>.
28. Mehta SV., Uzsoy RM. Predictable Scheduling of a Job Shop Subject to Breakdowns. *IEEE Transactions on Robotics and Automation* 1998, 14(3): 365–378, <https://doi.org/10.1109/70.678447>.
29. Rawat M, Lad BK., Novel approach for machine tool maintenance modelling and optimization using fleet system architecture. *Computers & Industrial Engineering* 2018, 126: 47–62, <http://dx.doi.org/10.1016/j.cie.2018.09.006>.
30. Rosmaini A, Shahrul K. An overview of time-based and condition-based maintenance in industrial application. *Computers & Industrial Engineering* 2012; 63(1): 135–149, <http://dx.doi.org/10.1016/j.cie.2012.02.002>.
31. Sabuncuoğlu I, Bayoğ M. Analysis of reactive scheduling problems in a job shop environment. *European Journal of Operational Research* 2000, 126(3): 567–586, [https://doi.org/10.1016/S0377-2217\(99\)00311-2](https://doi.org/10.1016/S0377-2217(99)00311-2).
32. Skołod B., Wosik I., Immune Algorithms in Production Jobs Scheduling. *Zarządzanie Przedsiębiorstwem* 2008, 1: 47–48.
33. Sobaszek Ł, Gola A, Kozłowski E. Job-shop scheduling with machine breakdown prediction under completion time constraint. *Annals of Computer Science and Information Systems* 2018; 15: 437–440, <http://dx.doi.org/10.15439/2018F83>.
34. Szwedzka K, Szafer P, Wyczółkowski R. Structural analysis of factors affecting the effectiveness of complex technical systems. *Proceedings of the 30th International Business Information Management Association Conference, IBIMA 2017 – Vision 2020: Sustainable Economic development, Innovation Management, and Global Growth Volume* 2017, 4096–4105.

35. Timofiejczuk A, Brodny J, Loska A. Exploitation Policy in the Aspect of Industry 4.0 Concept – Overview of Selected Research. *Multidisciplinary Aspects of Production Engineering* 2018, 1(1): 353–359. <https://doi.org/10.2478/mape-2018-0045>.
36. Vonta F. Frailty or Transformation Models in Survival Analysis and Reliability. *Recent Advances In System Reliability: Signatures, Multi-State Systems And Statistical Inference* 2012, 237–251, [http://dx.doi.org/10.1007/978-1-4471-2207-4\\_17](http://dx.doi.org/10.1007/978-1-4471-2207-4_17).
37. Wei-Wei C, Zhiqiang L, Ershun P. Integrated Production Scheduling and Maintenance Policy for Robustness in a Single Machine. *Computers & Operations Research* 2014, 47: 81–91, <https://doi.org/10.1016/j.cor.2014.02.006>.
38. Yang BY, Liu RN, Zio E. Remaining Useful Life Prediction Based on a Double-Convolutional Neural Network Architecture. *IEEE Transactions On Industrial Electronics* 2019, 66(12): 9521–9530, <https://doi.org/10.1109/TIE.2019.2924605>.
39. Zhang F, Shen J, Ma Y. Optimal maintenance policy considering imperfect repairs and non-constant probabilities of inspection errors. *Reliability Engineering and System Safety* 2020, 193, <http://dx.doi.org/10.1016/j.ress.2019.106615>.
40. Zhao X, He S, He Z, Xie M. Optimal condition-based maintenance policy with delay for systems subject to competing failures under continuous monitoring. *Computers & Industrial Engineering* 2018, 124: 535–544, <http://dx.doi.org/10.1016/j.cie.2018.08.006>.