

# ANALIZA AWARYJNOŚCI PARKU MASZYNOWEGO WYBRANEGO PRZEDSIĘBIORSTWA PRODUKCYJNEGO Z WYKORZYSTANIEM NARZĘDZI PREDYKCJI

Łukasz SOBASZEK, Arkadiusz GOLA, Antoni ŚWIC

**Streszczenie:** W pracy zaprezentowano wykorzystanie analizy czasu trwania w celu zbadania awaryjności parku maszynowego wybranego przedsiębiorstwa produkcyjnego. Na wstępie omówiono ideę predykcji zakłóceń procesu produkcyjnego, głównie w celu pozyskania stabilnego harmonogramu. Następnie omówiono metody statystyczne wykorzystywane w ramach metody analizy przeżycia. Ponadto przedstawiono zastosowanie wybranych narzędzi w celu określenia prawdopodobieństwa wystąpienia awarii parku maszynowego oraz zbadania wybranych czynników wpływu.

**Słowa kluczowe:** analiza awaryjności, predykcja zdarzeń, harmonogramowanie predyktywne.

## 1. Wstęp

Tematyka predykcji zakłóceń procesu produkcyjnego jest dziś zagadnieniem bardzo popularnym. Zapewnienie stabilności realizowanych zadań jest istotnym zagadnieniem produkcji, dlatego też powinno odbywać się już na etapie jej planowania [2,16]. W literaturze coraz częściej poruszana jest tematyka harmonogramowania produkcji w warunkach niepewności. Opracowanie stabilnego uszeregowania związane jest jednak ze zbadaniem i poznaniem charakteru czynników niepewności.

W niniejszej pracy zostało przedstawione zastosowanie narzędzi i technik wykorzystywanych w ramach metody analizy przeżycia w celu zbadania awaryjności urządzeń parku maszynowego. Przedstawione analizy oparte są o koncepcję przedstawioną przez autorów w pracy [18]. Są one częścią badań mających na celu opracowanie metody predykcji przyszłych zdarzeń na podstawie dostępnych danych historycznych, a następnie wykorzystanie pozyskanej wiedzy w celu uodporniania harmonogramów produkcyjnych.

## 2. Predykcja zakłóceń procesu produkcyjnego

Pod pojęciem predykcji rozumie się „statystyczny proces wnioskowania o przyszłych wielkościach zmiennych losowych w określonym, przyszłym momencie (okresie), gdy nie jest znana wielkość wyjściowa” [5]. Predykcja daje zatem możliwość analizy procesów bieżących, jak i historycznych, a następnie na ich podstawie pozwala na formułowanie wniosków na przyszłość [14]. Predykcję zdarzeń prowadzi się zazwyczaj za pomocą różnorodnych metod, analiz i narzędzi statystycznych. Wykorzystywana jest ona w wielu obszarach nauki.

Z punktu widzenia dyscypliny jaką jest Inżynieria Produkcji predykcja przyszłych zdarzeń może znaleźć zastosowanie w szeregowaniu zadań produkcyjnych. Coraz częściej w literaturze rozpatrywane jest zagadnienie odpornego szeregowania procesów produkcyjnych (ang. *robust scheduling*) [4,10]. Polega ono na tworzeniu harmonogramów

produkcyjnych, które uwzględniają jednocześnie kompensację ewentualnych zakłóceń powodujących wzrost nerwowości i dezorganizacji.

W harmonogramowaniu odpornym wyróżnić można dwie fazy:


- fazę off-line (harmonogramowania predyktywnego),
- fazę on-line (harmonogramowania reaktywnego).

Podejście predyktywne charakteryzuje się uodparnianiem uszeregowania zadań już na etapie opracowywania harmonogramu. Podejście reaktywne polega natomiast na ciągłej analizie prowadzonego procesu i aktualizowaniu harmonogramu wówczas, gdy wystąpi zdarzenie negatywnie wpływające na realizowany proces [7]. Do najczęściej stosowanych technik uodparniania harmonogramów zalicza się: techniki nadmiarowości, harmonogramowanie warunkowe, budowanie częściowo uporządkowanych harmonogramów oraz analizę wrażliwości uszeregowania [13].

Podejście odporne do procesu harmonogramowania produkcji pozwala na kompensację możliwych zakłóceń. Każdy harmonogram już w chwili realizacji pierwszych zadań staje się nieaktualny, gdyż istnieje ryzyko wystąpienia zakłócenia. Dlatego też tworzenie stabilnych uszeregowania jest związane z predykcją czynników negatywnie wpływających na realizowany proces [18]. Wnioskowanie o przyszłości na podstawie danych historycznych może być kluczowym elementem tworzenia odpornych harmonogramów produkcyjnych.

### 3. Awarie maszyn i ich konsekwencje

Wśród wielu możliwych zakłóceń procesu produkcyjnego niewątpliwie szkodliwym zjawiskiem jest awaria maszyn realizujących procesy produkcyjne. Każdy defekt powoduje wykluczenie danego urządzenia na pewien czas. W przypadku niezbyt skomplikowanych uszkodzeń czas ten może wynosić od kilku do kilkunastu minut (naprawa przez pracowników działu Utrzymania Ruchu). Niemniej jednak w przypadku poważnej usterki czas przestoju maszyny może sięgać kilku, a nawet kilkunastu dni (potrzeba wezwania serwisu, zamówienia uszkodzonego podzespołu lub części). Usterka powoduje brak możliwości wykonania operacji technologicznej na danej maszynie, a także utratę płynności wykonywania kolejnych operacji wynikających z marszruty technologicznej. Taka sytuacja wpływa również na pozostałe zadania umieszczone w harmonogramie (rys. 1).



Rys. 1. Konsekwencje awarii maszyny *M12* biorącej udział w procesie produkcyjnym [18]

### 3. Predyktywne szeregowanie zadań

Przegląd literatury dotyczącej szeregowania zadań z uwzględnieniem czynników niepewności wskazuje, iż autorzy licznych publikacji skupiają się w dużym stopniu na wpływie awaryjności maszyn na możliwość realizacji harmonogramu.

Najczęściej prezentowane jest podejście opierające się na analizach rozkładów prawdopodobieństwa [3,9,23]. Analizowane są typowe rozkłady (normalny, trójkątny, wykładniczy), a także ich kombinacje. Autorzy jednak nie podają uzasadnienia, dlaczego właśnie takie rozkłady są brane pod uwagę, a przecież każdy czynnik niepewności w postaci awarii ma inny charakter i swoją zmienność. Dlatego też wielu badaczy stara się analizować awaryjność maszyn technologicznych pod kątem uodparniania uszeregowania z wykorzystaniem wskaźników MTTF (*Mean Time To Failure*), MTBR (*Mean Time Between Repair*) oraz MTTR (*Mean Time To Repair*) [4,7,10]. Niestety w znacznej części publikacji wykorzystywane są tylko i wyłącznie dane testowe, bądź przyjęte przez autorów na podstawie opracowanych założeń. Wówczas nie podana jest argumentacja takiego sposobu postępowania. W publikacjach [3,6,11] autorzy wskazują, iż istotną kwestią jest bazowanie na zbiorach rzeczywistych danych dotyczących procesu. Podkreślana jest także potrzeba szeregowania zadań w realnych środowiskach produkcyjnych, a więc z wykorzystaniem realnych danych. W publikacjach [12,17] poszukiwana jest metoda przewidywania awarii, które w negatywny sposób wpływają na realizację harmonogramu. Autorzy wykorzystują wskaźniki MTBF, MTTR, a także MTTF (*Mean Time To First Failure*). Ich wartości starają się wyznaczać w oparciu o teorię prawdopodobieństwa. Ponadto celem pracy jest znalezienie metody, która pozwoli na oszacowanie parametrów rozkładu Weibulla.

Jak można zauważyć, analiza awaryjności maszyn w celu uzyskania odpornego uszeregowania zadań jest popularnym i aktualnym zagadnieniem.

### 5. Metoda analizy przeżycia

Wśród wielu metod analizy danych na szczególną uwagę zasługuje analiza przeżycia. Metoda ta jest zwana także analizą czasu trwania [19]. Pozwala ona określić model przeżycia konkretnego obiektu czy zjawiska, a także wykorzystać analizowane dane w celu predykcji wzorców przeżywania [1].

#### 5.1. Informacje ogólne

Pod pojęciem „analiza przeżycia” rozumie się statystyczne techniki analizy danych. Termin ten jest tłumaczony wprost z języka angielskiego (*survival analysis*) i w takiej postaci przyjął się w języku polskim. Podstawą tej metody jest proces „trwania”, który charakteryzuje się pewną zależnością – występowaniem zdarzenia – początkowego oraz końcowego [19].

Analiza przeżycia znajduje zastosowanie w wielu dziedzinach – badaniach społecznych, ekonomii, zarządzaniu i marketingu, demografii, medycynie, a także technice. Analiza danych może dostarczyć badaczowi wiele interesujących informacji dotyczących badanych procesów oraz obiektów, które mogą być podstawą predykcji ich zachowań [1].

## 5.2. Podstawowe pojęcia

W celu poprawnego wykonywania analizy czasu trwania, istotna jest znajomość podstawowych pojęć i terminów stosowanych w ramach tej metody. Z punktu widzenia prowadzonych obserwacji definiuje się następujące pojęcia [20]:

- Zdarzenie – rozumiane jako przejście z jednego stanu w drugi (np. śmierć pacjenta, awaria maszyny),
- Czas przeżycia – czas pomiędzy stanem początkowym, a stanem końcowym,
- Obserwacja ucięta (ang. *censoring*) – oznacza utratę „obiektu obserwacji” z powodu innego, niż zdarzenie końcowe lub udział obiektu aż do końca obserwacji.


W analizie przeżycia czas wystąpienia zdarzenia (czas trwania) traktowany jest jako zmienna losowa  $T$  należąca do przedziału  $(0, \infty)$ , a zatem istotnym elementem tej metody będzie opis matematyczny w postaci odpowiednich funkcji probabilistycznych do których zalicza się [1]:

1. **Funkcję gęstości prawdopodobieństwa**  $f(t)$ , która jest funkcją nieujemną, reprezentującą prawdopodobieństwo wystąpienia zdarzenia –  $f(t)\Delta t$  można rozumieć jako przybliżenie prawdopodobieństwa, iż zdarzenie nastąpi w czasie  $t$ .
2. **Dystrybuantę**  $F(t)$  określającą prawdopodobieństwo, iż obiekt „nie przeżyje” czasu  $t$ , a więc zdarzenie wystąpi w czasie  $(0, t]$ :

$$F(t) = P(T \leq t) \quad (1)$$

3. **Funkcję trwania**  $S(t)$  nazywaną także funkcją dożycia lub przeżycia (rys. 2). Określa ona prawdopodobieństwo, iż obiekt będzie trwał dłużej niż do chwili  $t$ . W teorii niezawodności jest ona nazywana funkcją niezawodności i oznaczana  $R(t)$ . Jest kluczowym pojęciem analizy przeżycia.

$$S(t) = 1 - F(t) = P(T > t) \quad (2)$$



Rys. 2. Kształt funkcji przeżycia [15]

4. **Funkcję intensywności (funkcja hazardu)**  $\lambda(t)$  będącą warunkową funkcją gęstości wystąpienia wydarzenia w chwili  $t$ . Intensywność, to lokalna charakterystyka danego procesu, która określa jego niestabilność w sensie czasu doznania wydarzenia.

$$\lambda(t) = \frac{d \ln S(t)}{dt} \quad (3)$$

Opis matematyczny metody jest oczywiście bardziej rozbudowany, a pomiędzy poszczególnymi jego elementami zachodzi wiele zależności. Informacje te są przedstawione szczegółowo w publikacjach [1, 15].

### 5.3. Stosowane techniki analityczne

Analiza przeżycia, jak zostało wspomniane na wstępie niniejszego rozdziału, jest zbiorem technik i metod analitycznych. Są te techniki stosowane także w innych procedurach, jednak metody zastosowane w analizie przeżycia mogą operować na danych uciętych. Do podstawowych metod należy zaliczyć [21]:

1. Analizę tablic trwania życia – szeregowanie przypadków wg czasów trwania i analiza ich parametrów.
2. Dopasowywanie rozkładu – adaptacja teoretycznego rozkładu awarii w czasie dla danych empirycznych.
3. Estymację Kaplana-Meiera – szacowaniu funkcji przeżycia bezpośrednio z ciągłych czasów przeżycia lub bezawaryjności.
4. Porównywanie prób – zestawienie czasów przeżycia lub bezawaryjności w dwóch lub więcej próbach z wykorzystaniem odpowiednich testów nieparametrycznych.
5. Zastosowanie modeli regresji – modelu proporcjonalnego Coxa, modelu regresji wykładniczej, normalnego modelu regresji liniowej czy Log-normalnego modelu regresji liniowej.

## 6. Analiza awaryjności maszyn technologicznych przedsiębiorstwa produkcyjnego

W celu zbadania efektywności przedstawionych w poprzednim rozdziale narzędzi predykcji wykonano analizę awaryjności parku maszynowego jednego z przedsiębiorstw produkcyjnych zajmującej się produkcją i modernizacją urządzeń stosowanych w przemyśle i energetyce.

### 6.1. Dane historyczne dotyczące maszyn technologicznych

W celu przeprowadzenia prezentowanych badań niezbędne było zgromadzenie danych historycznych dotyczących awarii oraz usterek. Źródłem tych danych były Książki Serwisowe maszyn technologicznych stanowiących część parku maszynowego przedsiębiorstwa. W książkach znajdowały się informacje dotyczące wszystkich działań prowadzonych na 14 obrabiarkach przez pracowników Działu Utrzymania Ruchu. Do badań jednak zostały wyselekcjonowane dane dotyczące awarii oraz przeprowadzony przeglądów (rocznych i okresowych) (rys. 3).

1 Maszyna	2 Awaria_1	3 Czas_1	4 Awaria_2	5 Czas_2	6 Czas_12	7 Kompletna_1	8 Kompletna_2	9 Poprzednia	10 Czas_przeglad < 90	11 Kolejne
Maszyna 1	0	365	0	365	0	0	0	0	0	0
Maszyna 2	1	10	1	74	64	1	1	0	0	1
Maszyna 3	1	199	0	365	166	1	0	0	1	0
Maszyna 4	0	365	0	365	0	0	0	0	0	0
Maszyna 5	1	77	1	246	169	1	1	0	0	0
Maszyna 6	1	170	1	212	42	1	1	0	0	1
Maszyna 7	1	247	1	266	19	1	1	0	1	1
Maszyna 8	1	73	1	231	158	1	1	0	0	0
Maszyna 9	0	365	0	365	0	0	0	0	0	0
Maszyna 10	1	220	0	365	145	1	0	1	0	0
Maszyna 11	1	67	1	260	193	1	1	0	0	0
Maszyna 12	1	3	1	45	42	1	1	0	0	1
Maszyna 13	1	8	1	9	1	1	1	0	0	1
Maszyna 14	1	183	1	298	115	1	1	0	1	0

Rys. 3. Zestawienie danych dotyczących awaryjności maszyn technologicznych w 2007 roku

Z uwagi na fakt, iż w latach 2007 i 2012 odnotowano najwięcej przypadków awarii, do analizy wykorzystano dane z tego okresu. Pozyskanie oraz odpowiednia obróbka danych historycznych pozwoliła na ich implementację w systemie STATISTICA.

Zebrane dane zostały zapisane w postaci tabeli za pomocą odpowiednich zmiennych:

- *Awaria\_1* oraz *Awaria\_2* – zmienne informujące o wystąpieniu awarii (wartość „1”) lub jej braku (wartość „0”),
- *Czas\_1* oraz *Czas\_2* – zmienne definiujące liczbę dni od początku obserwacji do chwili wystąpienia zdarzenia,
- *Czas\_12* – zmienna określająca czas pomiędzy pierwszą a drugą awarią,
- *Kompletna\_1* oraz *Kompletna\_2* – zmienne informujące od statusie obserwacji (kompletna – „1”, odcięta – „0”),
- *Poprzednia* – zmienna definiująca czy awaria była powiązana z poprzednią usterką („1” – tak, „0” – nie),
- *Czas\_przegląd < 90* – zmienna wskazująca czy usterka wystąpiła w czasie 90 dni od przeglądu („1” – tak, „0” – nie),
- *Kolejne* – zmienna informująca o kolejnych awariach („1” – kolejne awarie wystąpiły, „0” – brak kolejnych awarii).

W ten sposób zostały przedstawione dane dotyczące roku 2007 jak i roku 2012. Przedstawienie danych w takiej formie umożliwiło wykonanie badań za pomocą narzędzi dostępnych w module *Analiza przeżycia* pakietu STATISTICA (wersja 12).

## 6.2. Tablice wymieralności oraz funkcja przeżycia

Podstawowym narzędziem analizy czasu trwania są tablice wymieralności. Technika ta należy do grupy najstarszych metod analizy danych dotyczących czasu trwania. Dla każdego z przedziałów określa się liczbę obserwacji kompletnych oraz uciętych. W oparciu o te dane oblicza się liczbę przypadków zagrożonych, proporcje przypadków ulegających awarii lub przypadków przeżywających [22] (rys. 4, rys. 5).

Przedz.	Przedz. pocz.	Punkt środkowy	Przedz. Szerok.	Liczba wchodz.	Liczba ucięt.	Liczba zagroz.	Liczba zgonów	Proporc. zgonów	Proporc. przezyw.	Skum.pro przezyw.	Gęstość prawdop.	Stopa hazardu
L.pocz1	0,0000	13,0357	26,07143	14	0	14,00000	3	0,214286	0,785714	1,000000	0,008219	0,009205
L.pocz2	26,0714	39,1071	26,07143	11	0	11,00000	0	0,045455	0,954545	0,785714	0,001370	0,001784
L.pocz3	52,1429	65,1786	26,07143	11	0	11,00000	3	0,272727	0,727273	0,750000	0,007846	0,012112
L.pocz4	78,2143	91,2500	26,07143	8	0	8,00000	0	0,062500	0,937500	0,545455	0,001308	0,002475
L.pocz5	104,2857	117,3214	26,07143	8	0	8,00000	0	0,062500	0,937500	0,511364	0,001226	0,002475
L.pocz6	130,3571	143,3929	26,07143	8	0	8,00000	0	0,062500	0,937500	0,479403	0,001149	0,002475
L.pocz7	156,4286	169,4643	26,07143	8	0	8,00000	1	0,125000	0,875000	0,449441	0,002155	0,005114
L.pocz8	182,5000	195,5357	26,07143	7	0	7,00000	2	0,285714	0,714286	0,393261	0,004310	0,012785
L.pocz9	208,5714	221,6071	26,07143	5	0	5,00000	1	0,200000	0,800000	0,280900	0,002155	0,008524
L.pocz10	234,6429	247,6786	26,07143	4	0	4,00000	1	0,250000	0,750000	0,224720	0,002155	0,010959
L.pocz11	260,7143	273,7500	26,07143	3	0	3,00000	0	0,166667	0,833333	0,168540	0,001077	0,006974
L.pocz12	286,7857	299,8214	26,07143	3	0	3,00000	0	0,166667	0,833333	0,140450	0,000898	0,006974
L.pocz13	312,8571	325,8929	26,07143	3	0	3,00000	0	0,166667	0,833333	0,117042	0,000748	0,006974
L.pocz14	338,9286	351,9643	26,07143	3	0	3,00000	0	0,166667	0,833333	0,097535	0,000624	0,006974
L.pocz15	365,0000			3	3	1,50000	0	0,333333	0,666667	0,081279		

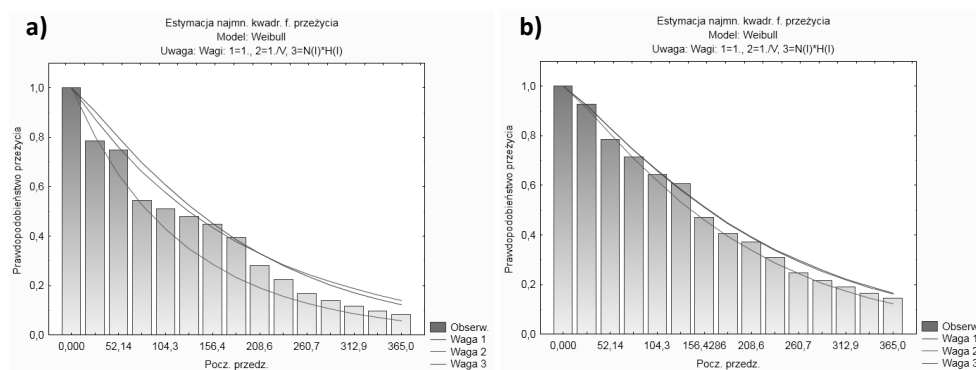
Rys. 4. Tablice przeżycia dla przypadków z roku 2007

Przedz.	Przedz. pocz.	Punkt środkowy	Przedz. Szerok.	Liczba wchodz.	Liczba ucięt.	Liczba zagroz.	Liczba zgonów	Proporc. zgonów	Proporc. przeżyw.	Skum. pro przeżyw.	Gęstość prawdop.	Stopa hazardu
L.pocz1	0,0000	13,0357	26,07143	14	0	14,00000	1	0,071429	0,928571	1,000000	0,002740	0,002841
L.pocz2	26,0714	39,1071	26,07143	13	0	13,00000	2	0,153846	0,846154	0,928571	0,005479	0,006393
L.pocz3	52,1429	65,1786	26,07143	11	0	11,00000	1	0,090909	0,909091	0,785714	0,002740	0,003653
L.pocz4	78,2143	91,2500	26,07143	10	0	10,00000	1	0,100000	0,900000	0,714286	0,002740	0,004037
L.pocz5	104,2857	117,3214	26,07143	9	0	9,00000	0	0,055556	0,944444	0,642857	0,001370	0,002192
L.pocz6	130,3571	143,3929	26,07143	9	0	9,00000	2	0,222222	0,777778	0,607143	0,005175	0,009589
L.pocz7	156,4286	169,4643	26,07143	7	0	7,00000	1	0,142857	0,857143	0,472222	0,002588	0,005901
L.pocz8	182,5000	195,5357	26,07143	6	0	6,00000	0	0,083333	0,916667	0,404762	0,001294	0,003335
L.pocz9	208,5714	221,6071	26,07143	6	0	6,00000	1	0,166667	0,833333	0,371032	0,002372	0,006974
L.pocz10	234,6429	247,6786	26,07143	5	0	5,00000	1	0,200000	0,800000	0,309193	0,002372	0,008524
L.pocz11	260,7143	273,7500	26,07143	4	0	4,00000	0	0,125000	0,875000	0,247355	0,001186	0,005114
L.pocz12	286,7857	299,8214	26,07143	4	0	4,00000	0	0,125000	0,875000	0,216435	0,001038	0,005114
L.pocz13	312,8571	325,8929	26,07143	4	0	4,00000	0	0,125000	0,875000	0,189381	0,000908	0,005114
L.pocz14	338,9286	351,9643	26,07143	4	0	4,00000	0	0,125000	0,875000	0,165708	0,000794	0,005114
L.pocz15	365,0000			4	4	2,00000	0	0,250000	0,750000	0,144995		

Rys. 5. Tablica przeżycia dla przypadków z roku 2012

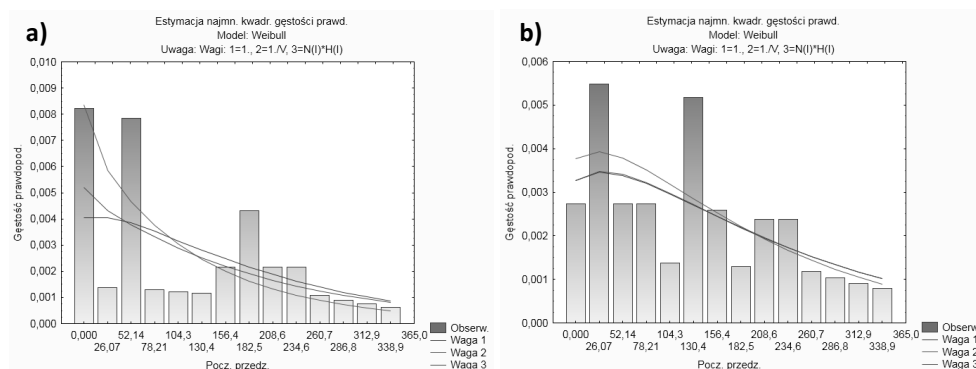
Zestawienie danych w powyższej formie umożliwia analizę awaryjności w konkretnych przedziałach czasu. Na uwagę zasługuje także parametr jakim jest *stopa hazardu*. Jest on określany jako prawdopodobieństwo na jednostkę czasu, że przypadek, który przeżył do początku danego przedziału ulegnie w tym przedziale awarii. Wskaźnik ten wyraźnie zwiększa swą wartość w przedziałach, gdzie liczba awarii zwiększa się, a zatem obserwacja jego zmienność może być dobrym elementem predykcji przyszłych zdarzeń.

Zestawienie danych w postaci tablic przeżycia jest bazowym elementem stworzenia wykresów prawdopodobieństwa. Proces ten polega na dopasowaniu teoretycznego rozkładu awarii w czasie dla danych empirycznych. W ten sposób uzyskać można wykresy funkcji dożycia (rys. 6) oraz rozkładu gęstości prawdopodobieństwa (rys. 7). Z uwagi na fakt, iż rozkład Weibulla [21,22] jest rozkładem dość często stosowanym podczas analiz związanych z awaryjnością, właśnie taki rozkład został wybrany podczas generowania wykresów. Estymacja odbywa się w oparciu o trzy różne procedury estymacyjne – najmniejszych kwadratów oraz dwóch metod ważonych najmniejszych kwadratów [19].



Rys. 6. Dopasowywanie rozkładu awarii w czasie do rozkładu empirycznego: a) rok 2007, b) rok 2012

Analizując uzyskane wyniki estymacji należy stwierdzić, iż zarówno w przypadku obserwacji z roku 2007, jak i roku 2012 przybliżone wykresy rozkładów pokrywają się w znacznym stopniu z rozkładami empirycznymi. W przypadku estymowanych rozkładów dla obserwacji z 2012 roku należy stwierdzić, iż zastosowane procedury dają bardzo zbliżone rezultaty. W przypadku danych z roku 2007 obserwujemy większą rozbieżność w uzyskanych wykresach. Mimo to, narzędzie dopasowywania rozkładu pozwala w pewnym stopniu zobrazować charakter analizowanych awarii.



Rys. 7. Wykresy gęstości prawdopodobieństwa dla lat: a) 2007, b) 2012

W przypadku estymowania przebiegów gęstości prawdopodobieństwa również obserwujemy, iż dla danych z 2007 roku różne metody przybliżania dają odmienne rezultaty. Jednak w przypadku danych z roku 2012 uzyskane wykresy funkcji przyjmują zbliżony kształt. W obu przypadkach należy stwierdzić, iż uzyskane wykresy mają typowy kształt funkcji gęstości prawdopodobieństwa rozkładu Weibulla. Na podstawie uzyskanych wykresów możemy chociażby określić parametr kształtu, który jest jednym z parametrów dopasowanego rozkładu.

### 6.3. Metoda Kaplana-Meiera

Metoda ta polega na szacowaniu funkcji przeżycia bezpośrednio z ciągłych czasów przeżycia. Każdy przedział zawiera wówczas dokładnie jeden przypadek zdarzenia. Funkcja przeżycia określana jest jako iloczyn kolejnych prawdopodobieństw z przedziałów [19]:

$$S_n(t) = \prod_{t_j \leq t} \left(1 - \frac{d_j}{r_j}\right) \quad (4)$$

gdzie:  $S_n(t)$  – oszacowana funkcja przeżycia,  
 $\Pi$  – symbol iloczynu,  
 $r_j$  – liczba narażonych w okresie  $t_j$ ,  
 $d_j$  – liczba zdarzeń w okresie  $t_j$ .

Rezultaty estymacji funkcji przeżycia dla badanych danych empirycznych zostały przedstawione na rysunku 8.

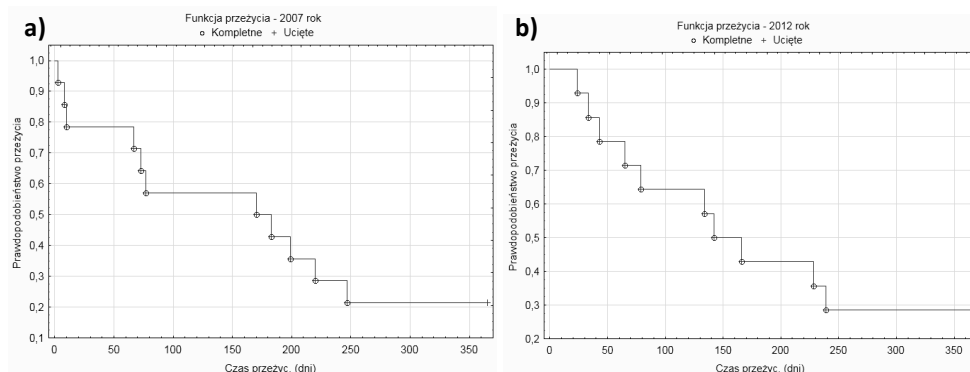


Przyp. Liczba	Analiza Kaplana-Meiera: 2007 (Ucięte obserwacje oznaczono +)		Przyp. Liczba	Analiza Kaplana-Meiera: 2012 (Ucięte obserwacje oznaczono +)	
	Czas	Skumul. Przeżyc.		Czas	Skumul. Przeżyc.
12	3,0000	0,928571	3	24,0000	0,928571
13	8,0000	0,857143	8	33,0000	0,857143
2	10,0000	0,785714	4	43,0000	0,785714
11	67,0000	0,714286	6	65,0000	0,714286
8	73,0000	0,642857	5	79,0000	0,642857
5	77,0000	0,571429	1	134,0000	0,571429
6	170,0000	0,500000	7	142,0000	0,500000
14	183,0000	0,428571	13	166,0000	0,428571
3	199,0000	0,357143	12	228,0000	0,357143
10	220,0000	0,285714	2	239,0000	0,285714
7	247,0000	0,214286	10+	365,0000	
4+	365,0000		11+	365,0000	
9+	365,0000		14+	365,0000	
1+	365,0000		9+	365,0000	

Rys. 8. Wartości funkcji przeżycia oszacowanych za pomocą metody Kaplana-Meiera dla 2007 roku i 2012 roku

Analizując powyższe dane możemy określić wartość funkcji przeżycia w konkretnym przedziale czasu. Przykładowo, w okolicach 140–170 dnia pracy przeżywalność wynosi 50% zarówno w roku 2007 jak i 2012. Zbliżone wartości funkcji przeżycia zaobserwować można także w pobliżu 65 czy 230 dnia roku.

Oprócz tabelarycznego przedstawienia danych zastosowana metoda umożliwia także prezentację danych za pomocą wykresu schodkowego. Ułatwia to wizualizację oraz późniejszą interpretację analizowanych danych (rys. 9).



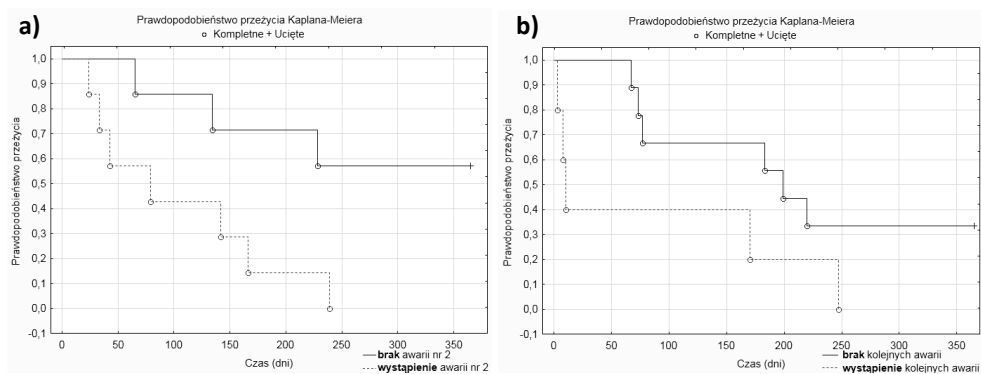
Rys. 9. Wykresy funkcji przeżycia: a) 2007 rok, b) 2012 rok

#### 6.4. Porównywanie badanych grup

Narzędzia analizy przeżycia umożliwiają także przeprowadzenie procesu porównywania czasów przeżycia w dwóch lub więcej próbach. Zastosowanie znajdują tu testy (najczęściej nieparametryczne) do których zalicza się: uogólnienia Gehana test Wilcozona, test Coxa-Mantela, test F Coxa, test log-rank, uogólnienie Peto i Peto test Wilcozona) [19].

W przypadku prezentowanych badań postanowiono sprawdzić jak zmienia się w czasie prawdopodobieństwo wystąpienia awarii dla maszyn, które doświadczyły tylko jednej awarii oraz maszyn na których pojawiła się także druga usterka (zarówno w 2007 jak i 2012 roku). Ponadto dla danych z 2007 roku zbadano jaki wpływ ma występowanie kolejnych

awarii (więcej niż 2 awarie) (rys. 10), zaś dla danych z 2012 roku – jaki wpływ ma fakt, iż awaria wystąpiła w czasie mniejszym niż 90 dni od ostatniego przeglądu maszyny (rys. 11).



Rys. 10. Porównywanie prób – dane z 2007 roku: a) maszyn na których wystąpiła i nie wystąpiła druga awaria, b) maszyn na których wystąpiły i nie wystąpiły kolejne awarie

Analizując wykresy badanych prób należy stwierdzić, iż fakt wystąpienia drugiej oraz kolejnych awarii w znaczący sposób wpływa na prawdopodobieństwo przeżycia. Jego wartość spada poniżej 0,5 już w trakcie 100 dni, gdy dla maszyn doświadczających tylko 1 awarii utrzymuje się na poziomie 0,7 nawet do 220 dnia. Jest to cenna informacja, która pozwala identyfikować maszyny potencjalnie zagrażające sprawnemu przeprowadzeniu procesu produkcyjnego.

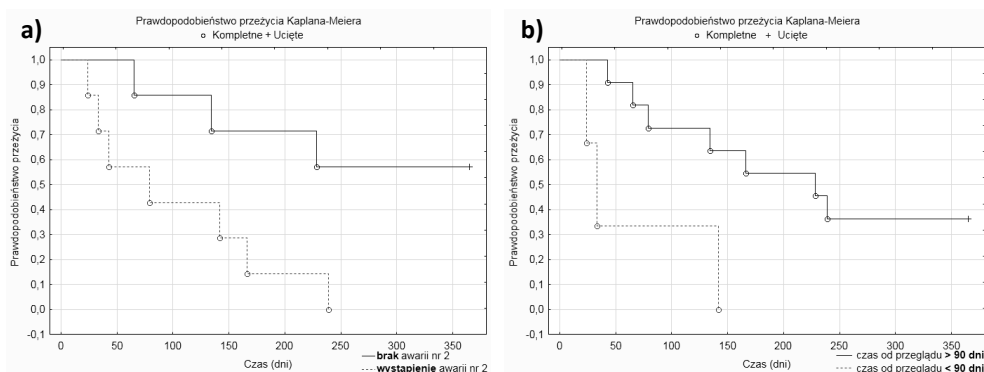
W celu zbadania istotności statystycznej analizowanych danych zostały wykorzystane wybrane testy statystyczne. Wyniki testów istotności zostały przedstawione w tabeli 1.

Tab. 1. Wyniki testów istotności – 2007 rok

<b>Porównywanie prób:</b> Występowanie lub brak awarii nr 2.	
<b>Nazwa testu</b>	<b>Poziom istotności <math>p</math></b>
F Coxa	0,001
T. Coxa-Mantela	0,004
log-rank	0,004
<b>Porównywanie prób:</b> Występowanie kolejnych awarii.	
<b>Nazwa testu</b>	<b>Poziom istotności <math>p</math></b>
F Coxa	0,04
T. Coxa-Mantela	0,07
log-rank	0,1

Analizując powyższe wyniki testów istotności należy stwierdzić, iż w przypadku porównywania prób dotyczących awarii nr 2 wszystkie testy wykazały, iż uzyskane wyniki są istotne statystycznie ( $p < 0,05$ ). Niestety w przypadku porównywania prób pod kątem kolejnych awarii poziom istotności w przypadku dwóch testów przyjmuje wartości powyżej  $p=0,05$  przez co nie można stwierdzić, iż przedstawione różnice są istotne statystycznie.

Rezultaty procesu porównywania prób dla danych z 2012 roku zostały przedstawione na rys. 11, zaś wyniki testów istotności w tabeli 2.



Rys. 11. Porównywanie prób – dane z 2012 roku: a) maszyn na których wystąpiła i nie wystąpiła druga awaria, b) maszyn na których awaria wystąpiła w czasie mniejszym lub większym niż 90 dni od ostatniego przeglądu

Rezultaty porównywania prób pozwalają wysnuć wniosek, iż zarówno występowanie drugiej awarii, jak i liczba dni jaka upływa od przeglądu do chwili wystąpienia awarii mają znaczący wpływ na przebieg funkcji przeżycia. Maszyny na których wystąpiła wyłącznie jedna awaria charakteryzują się większym prawdopodobieństwem przeżycia, niż te która uległy awarii kolejny raz. Podobnie maszyny, których czas wystąpienia usterki był większy niż 90 dni od ostatniego przeglądu charakteryzują się wyższymi wartościami funkcji przeżycia niż przypadki na których usterka wystąpiła w przeciągu 90 dni od przeglądu.

Tab. 2. Wyniki testów istotności – 2012 rok

<b>Porównywanie prób:</b> Występowanie lub brak awarii nr 2	
Nazwa testu	Poziom istotności $p$
F Coxa	0,006
T. Coxa-Mantela	0,02
log-rank	0,02
<b>Porównywanie prób:</b> Czas od przeglądu większy lub mniejszy niż 90 dni	
Nazwa testu	Poziom istotności $p$
F Coxa	0,02
T. Coxa-Mantela	0,008
log-rank	0,05

Wyniki zastosowanych testów istotności wskazują, iż uzyskane rezultaty analiz można uznać za istotne statystycznie. Co prawda w przypadku testu *log-rank* dla drugiego wariantu porównywania prób poziom istotności wynosi 0,5, jednak taka sytuacja jest akceptowalna.

Jak możemy zauważyć, narzędzie porównywania prób może dostarczyć badaczowi wiele informacji dotyczących potencjalnych czynników wpływu na prawdopodobieństwo doświadczenia awarii, a co za tym idzie – czas bezawaryjnej pracy maszyny.

## 7. Podsumowanie

Predykcja potencjalnych zakłóceń procesu produkcyjnego jest niewątpliwie zagadnieniem bardzo ważnym i aktualnym. Wnioskowanie o przyszłych zdarzeniach na podstawie danych historycznych może znaleźć zastosowanie nie tylko w działach Utrzymania Ruchu, ale także działach Planowania Produkcji. Znając dane dotyczące prawdopodobieństwa uszkodzenia maszyny oraz czynników mających wpływ na jej awaryjność można odpowiednio je wykorzystać – chociażby w procesie predyktywnego szeregowania zadań produkcyjnych. Istnieje jednak potrzeba stosowania odpowiednich narzędzi do których należy zaliczyć techniki i metody stosowane w ramach analizy przeżycia. Pozwalają one uzyskać wiele informacji dotyczących parku maszynowego, które mogą być źródłem wnioskowania i odpowiednich działań w przyszłości.

## Literatura

1. Balicki A.: Analiza przeżycia i tablice wymieralności. PWE, Warszawa, 2006.
2. Bulak Muhammet Enis, Turkyilmaz Ali: Performance assessment of manufacturing SMEs: a frontier approach. *Industrial Management & Data Systems*, Vol. 114, Issue 5, p. 797-816.
3. Davenport A. J., Gefflot Ch., Beck J. Ch.: Slack-Based Techniques for Robust Schedules. *Proceedings of the Sixth European Conference on Planning*, 2014, p. 43-49.
4. Deepu P.: *Robust Schedules and Disruption Management for Job Shops*. Bozeman, Montana, 2008.
5. Encyklopedia PWN: <http://encyklopedia.pwn.pl/haslo/predykcja;3962016.html> [10 styczeń 2016 r.]
6. Fox M. S., Smith S. F.: ISIS – A Knowledge-Based System for Factory Scheduling. *Expert Systems*, Vol. 1, No. 1, 1984.
7. Gao Hong: *Bulding Robust Schedules using Temporal Protection – An Empirical Study of Constraint Based Scheduling Under Machine Failure Uncertainty*. Toronto, Ontario, 1996.
8. Gola A., Sobaszek Ł., Świć A.: Selected Problems of Modern Manufacturing Systems Design and Operation. *Robotics and Manufacturing Systems*, [eds.:] Koukolová L., Świć A., Lublin, 2014, p. 56-68.
9. Gürel S., Körpeoğlu E., Aktürk M. S.: An anticipative scheduling approach with controllable processing times. *Computers & Operations Research*, Vol. 37, No. 6, 2010, p. 1002-1013.
10. Jian Xiong, Li-ning Xing, Ying-Wu Chen: Robust Scheduling for Multi-Objective Flexible Job-Shop Problems with Random Machine Breakdowns. *International Journal of Production Economics*, Vol. 141, Issue 1, 2013, p. 112-126.
11. Kalinowski K., Krenczyk D., Grabowik C.: Predictive-Reactive Strategy for Real Time Scheduling of Manufacturing Systems. *Applied Mechanics and Materials*, Vol. 307, 2013, p. 470-473.
12. Kempa W. M., 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*, [eds.:] Świć A., Lipski J., Lublin, 2011, p. 7-18.

13. Klimek M., Łebkowski P.: Harmonogramowanie odporne procesu technologicznego montażu. Przegląd Mechaniczny, nr 12, 2008, s. 37-40.
14. Kosicka E., Kozłowski E., Mazurkiewicz D.: The Use of Stationary Tests for Analysis of Monitored Residual Processes. Eksploatacja i Niezawodność – Maintenance and Reliability – 2015, No. 4, Vol. 17, p. 604-609.
15. Magiera R., Jokiel-Rokita A., Wilczyński M.: Metody analizy funkcji przeżycia. Strona internetowa Koła Naukowego Statystyki Matematycznej GAUSS: <http://prac.im.pwr.wroc.pl/~gauss/o-specjalnosci/statystyka-jako-klucz-do-wyboru-optimalnych-strategii/metody-analizy-funkcji-przezycia> [04 styczeń 2016 r.]
16. Patalas J., Krupa T.: ERP Systems Implementation Efficiency Modeling in Small and Medium Size Enterprises (SMEs). Applied Computer Science, Vol. 2, No. 1, 2006, p. 46-63.
17. Skołod B., Wosik I., Kempa W. M., Kalinowski K.: Estimation of Reliability Characteristics in a Production Scheduling Model with Time-Changing Parameters – Second Part, Numerical Example. Management and Control of Manufacturing Processes, [eds.:] Świć A., Lipski J., Lublin, 2011, p. 19-29.
18. Sobaszek Ł., Gola A.: Koncepcja zastosowania metody analizy przeżycia dla potrzeb predykcji zakłóceń procesu produkcyjnego. Innowacje w zarządzaniu i inżynierii produkcji. T. 1, [red:] Knosala R., Opole, Towarzystwo Zarządzania Produkcją, 2015, s. 622-634.
19. Sokołowski A.: Jak rozumieć i wykonać analizę przeżycia. Materiały Internetowej Czytelni StatSoft, s. 33-38.
20. Stanisław A.: Analiza przeżycia. Medycyna praktyczna dla lekarzy, <http://www.mp.pl/artykuly/12470> [04 grudzień 2014 r.]
21. STATISTICA PL dla Windows: Statystyki II, tom III, 1997.
22. StatSoft (2006). Elektroniczny Podręcznik Statystyki PL, Kraków, WEB: <http://www.statsoft.pl/textbook/stathome.html> [05 styczeń 2016 r.]
23. Vorge L. V., David W. S., Storer R. H.: Robustness Measures and Robust Scheduling for Job Shops. IIE Transactions, 1994, Vol. 26, No. 5, p. 32-43.

Mgr inż. Łukasz SOBASZEK<sup>\*)</sup>

Dr inż. Arkadiusz GOLA<sup>\*\*)</sup>

Prof. dr hab. inż. Antoni ŚWIĆ<sup>\*)</sup>

<sup>\*)</sup> Instytut Technologicznych Systemów Informacyjnych, Wydział Mechaniczny

<sup>\*\*)</sup> Katedra Organizacji Przedsiębiorstwa, Wydział Zarządzania

Politechnika Lubelska

20-618 Lublin, ul. Nadbystrzycka 36

tel.: (81) 538 42 76; (81) 538 44 83

e-mail: [l.sobaszek@pollub.pl](mailto:l.sobaszek@pollub.pl)

[a.gola@pollub.pl](mailto:a.gola@pollub.pl)

[a.swic@pollub.pl](mailto:a.swic@pollub.pl)