

## METODA ZARZĄDZANIA NIEZAWODNOŚCIĄ I PROCESAMI OBSŁUGI LINII PRODUKCYJNEJ WSPOMAGANA STATYSTYCZNĄ ANALIZĄ DANYCH

Jan PIESIK

Michelin Polska S.A., Olsztyn

tel: +48 89 531 46 47

e-mail: jan.piesik@michelin.com

**Streszczenie:** W referacie zostanie przedstawiona metoda zarządzania niezawodnością i procesem obsługi linii produkcyjnej wraz z implementacją wspomaganą komputerowo narzędzi statystycznych na linii produkcji półfabrykatów do produkcji opon. Referat ma na celu pokazanie skutecznych, relatywnie tanich oraz łatwych w implementacji w różnych środowiskach przemysłowych narzędzi do poprawy niezawodności maszyn, oraz pośrednio poprawy wyników jakościowych produkowanych wyrobów.

**Słowa kluczowe:** algorytm Apriori, predykcja uszkodzeń.

### 1. WIADOMOŚCI OGÓLNE


#### 1.1. Wprowadzenie

Stosowanie nowoczesnych rozwiązań w zakresie zarządzania niezawodnością i obsługą obiektów przemysłowych stosowanych w przemyśle znacząco poprawia uzyskiwane wyniki wydajności, jakości oraz zmniejszenia kosztów wytworzenia produktów [1]. Najbardziej popularnymi i szeroko opisanymi w literaturze narzędziami są metody Total Productive Maintenance (TPM) [2] oraz Reliability Centered Maintenance (RCM) [3]. Obie metody wdrożone w przedsiębiorstwie podnoszą również kulturę techniczną oraz poszerzają zakres aspektów zarządzanych w przedsiębiorstwie.

Na podstawie analiz autora oraz doświadczeniu, poprawnie wdrożone wyżej wymienione metody, pozwalają na wzrost dostępności linii produkcyjnych o 10%, oraz redukcję kosztów wchodzących w zakres utrzymania ruchu o 20%. Jednak po zakończeniu wdrożenia tych narzędzi i przejściu do etapu podtrzymania osiągniętego poziomu i zaawansowania tych technik, uzyskanie dalszych postępów staje się zdecydowanie bardziej kosztowne.

Poziom awaryjności maszyn na tym etapie może się kształtować w przedziale 1,5-5% w zależności od instalacji. Po analizie usterek nowoczesnych linii produkcyjnych z produkcją wsadową zauważono korelację pomiędzy uszkodzeniem a informacjami historycznymi zarejestrowanymi przez nadrzędny system kontrolujący proces produkcji. W następstwie przeprowadzonych badań i analiz zaobserwowano, iż omawiane problemy są aktualne i coraz szerzej zauważane przez przedsiębiorstwa. Brakuje jednak kompleksowego narzędzia, które mogłoby być łatwo implementowane do różnorodnych warunków występujących w przedsiębiorstwach, a stanowiłoby

uzupełnienie wdrożonych już narzędzi do zwiększenia dostępności urządzeń. Autor proponuje metodę zarządzania niezawodnością i procesami obsługi linii produkcyjnej bazującą na wdrożeniu znanych metod TPM oraz RCM uzupełnioną o narzędzie do statystycznej analizy danych z predykcją uszkodzeń (rys. 1).



Rys.1. Schemat metody zarządzania niezawodnością i procesami obsługi linii.

#### 1.2. Metody statystycznej obróbki danych

Patrząc przez pryzmat statystycznej analizy, można rozróżnić trzy rodzaje podejścia do zagadnienia niezawodności maszyn i urządzeń:

- analiza niezawodności
- analiza sekwencji zdarzeń
- predykcja zdarzeń.

Metody te zostały wymienione w sposób chronologiczny od najstarszego do najnowszego rodzaju analiz [4].

Analiza niezawodności nie będzie tutaj szerzej omawiana, gdyż jest szeroko opisywana w literaturze.

Analiza sekwencji zdarzeń to analiza mająca na celu znalezienie pośród występujących zdarzeń powtarzające się zależności w postaci reguł:

$$\text{jeżeli } A \text{ to } B \quad (1)$$

Analiza asocjacji inaczej analiza koszykowa bazuje na algorytmie Apriori. Algorytm Apriori to jeden z najpopularniejszych algorytmów analizy asocjacji. Metoda ta wykorzystuje wskaźniki odpowiadające za jakość reguł asocjacyjnych [5].

Najważniejszą rolę odgrywają w tej metodzie dwa wskaźniki:

- (a) wsparcie reguły (ang. support (supp))

$$\text{supp}(A \rightarrow B) = \frac{n(A \cap B)}{N} = P(A \cap B) \quad (2)$$

gdzie  $N$  – liczba wszystkich zdarzeń,  $n(A \cap B)$  – liczba zdarzeń zawierających jednocześnie elementy zdarzenia  $A$  i zdarzenia  $B$ ,  $P(A \cap B)$  – prawdopodobieństwo, że zdarzenie zawiera jednocześnie  $A$  i  $B$ .

(b) ufność reguły (ang. confidence (conf))

$$\text{conf}(A \rightarrow B) = \frac{n(A \cap B)}{n(A)} = P(B / A) \quad (3)$$

Regułami interesującymi są te, dla których zarówno wsparcie, jak i ufność przyjmują relatywnie duże wartości. Mówimy, że reguła asocjacyjna jest mocna, jeżeli jej wsparcie i ufność są większe niż pewne ustalone wartości minimalne:

$$\text{supp}(A \rightarrow B) > \text{minSupp}, \quad (4)$$


$$\text{conf}(A \rightarrow B) > \text{minConf}, \quad (5)$$

gdzie parametry  $\text{minSupp}$  i  $\text{minConf}$  są ustalone przez użytkownika.

Predykcja zdarzeń jest najnowocześniejszym i coraz szerzej stosowanym podejściem w poprawie niezawodności maszyn. W rozwiązaniach bazujących na dużych zbiorach danych i informacji wykorzystuje się podejście data mining.

## 2. PRZYGOTOWANIE DO WDROŻENIA SYSTEMU


Do pilotażowego wdrożenia zostały wybrane dwie nowoczesne linii produkcyjne wyposażone w szeroki zakres czujników monitorujących w trybie on-line stan zarówno procesu, jak i maszyn (rys. 2). Na liniach tych zostały wdrożone metody TPM oraz RCM. Dla realizacji projektu zebrano i przeanalizowano dane historyczne z okresu ponad trzech miesięcy. Po analizie stwierdzono, iż średnio dziennie w systemach generowanych jest 11830 komunikatów. Na podstawie tak dużej ilości danych możliwe było identyfikowanie zależności w postaci reguł.



Rys.2. Widok ekranu panelu operatorskiego operatora miksera z informacjami o przebiegu procesu [6]

Jednym z założeń projektu była dwutorowa możliwość pozyskiwania reguł. Pierwsza metoda to stworzenie reguł eksperckich bazujących na zdobytym doświadczeniu eksperta utrzymania ruchu.

Doświadczenie to może wynikać z analizy dotychczasowych awarii bądź też znajomości reguł występujących w programie sterowników PLC nadzorujących proces. Drugim źródłem reguł jest analiza statystyczna wykonana w trakcie wdrożenia. Dzięki analizie sekwencyjnej do wykrywania powtarzających się wzorców w ciągu zdarzeń, uzyskano 684 reguły przy zakładanych poziomach wskaźników: minimalne wsparcie = 0,1, oraz minimalne zaufanie = 0,5. Na rysunku 3 zamieszczono wykres, na którym zaznaczona jest każda z reguł, w funkcji uzyskanych poziomów wsparcia i zaufania. Wyszukiwano tylko proste reguły wg zasady, „jeśli poprzednik to następnik”.



Rys. 3. Wykres jakości uzyskanych reguł

Nie wyszukiwano reguł z sekwencją kilku zdarzeń poprzedzających. Taką opcję przewidziano w opracowanym edytorze (rys. 4), który daje szerokie możliwości rozbudowy reguł. Opracowano go, uwzględniając możliwość wystąpienia do pięciu zdarzeń poprzedzających uszkodzenie. Uwzględniono również dwie opcje wzajemnych relacji symptomów. Pierwsza, gdy kolejność wystąpienia symptomów jest bez znaczenia. Liczy się tylko fakt wystąpienia określonego zbioru symptomów w danym przedziale czasowym, co spowoduje wystąpienie uszkodzenia. Druga opcja, w której kolejność występowania symptomów ma wpływ na wystąpienie lub nie, uszkodzenia [7].

Edytor reguł - wersja pilotażowa										
Strefa*	Podział*	Awaria*	Czes.*	Z1*	L1	Z2	L2	K2	T2-T1	
ZB21	BH01	229	7	227	1					<input type="checkbox"/>
ZB21	BH01	230	7	228	1					<input type="checkbox"/>
ZB21	BH01	352	7	348	1					<input type="checkbox"/>
ZB21	BH01	499	7	495	1					<input type="checkbox"/>
ZB21	BH01	528	7	526	1					<input type="checkbox"/>
ZB22	BH01	223	7	227	1					<input type="checkbox"/>
ZB22	BH01	230	7	228	1					<input type="checkbox"/>
ZB22	BH01	352	7	348	1					<input type="checkbox"/>
ZB22	BH01	488	7	485	1					<input type="checkbox"/>
ZB22	BH01	528	7	526	1					<input type="checkbox"/>
ZB21	HF01	335	7	334	1					<input type="checkbox"/>
ZB21	HF01	393	7	392	1					<input type="checkbox"/>

Rys. 4. Narzędzie edytora reguł

## 3. WDROŻENIE SYSTEMU NA OBIEKCIE

W opisywanym przypadku mamy do czynienia z potrzebą zastosowania narzędzi statystycznych. Umożliwiających zidentyfikowanie zależności pomiędzy zdarzeniami zgromadzonymi w zbudowanej bazie danych. Narzędziem statystycznym stworzonym właśnie do tego celu

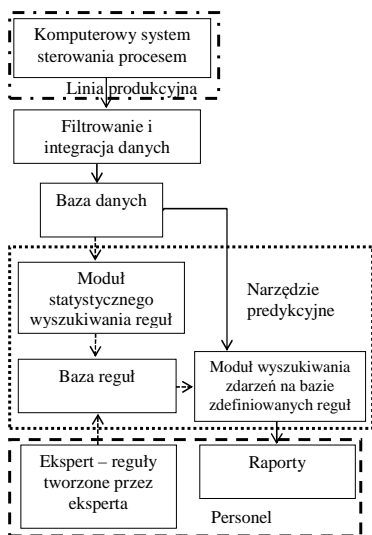
jest analiza asocjacji. Analiza asocjacji wraz z budowaniem reguł asocjacyjnych jest metodą zaliczaną do metod eksploracji danych (ang. Data Mining) [8]. Rozwiązaniem szeroko stosowanym do analiz statystycznych, w ostatnich latach wzbogaconym o pakiet umożliwiający jego zastosowanie w zakładach przemysłowych, jest pakiet oprogramowania Statistica.

Rozwiązanie zaimplementowane w oprogramowanie Statistica stanowi między innymi algorytm Apriori, jeden z najpopularniejszych algorytmów analizy asocjacji i budowy reguł asocjacyjnych, w sposób uporządkowany i logiczny realizujący wymagane działania.

Autor proponuje narzędzie predykcyjne bazujące na narzędziach statystycznych. Narzędzie to składa się z czterech modułów rozpatrywanych jako całościowe podejście do predykcji (rys. 5). Na pierwszy element systemu składają się dane wyjściowe z podstawowego systemu sterowania procesem. Dane te są z gromadzone w różnej postaci.

Kolejny moduł służy do przetwarzania danych poprzez ich wstępne filtrowanie oraz integrację danych do danych jednowymiarowych. Następnie dane są zbierane do wspólnej bazy danych.

Trzeci moduł to praca z zebranymi i wstępnie przygotowanymi danymi w celu uzyskania na ich podstawie użytecznych informacji i wniosków. W pierwszym etapie używany jest moduł statystycznego wyszukiwania reguł analizujący dane historyczne. Następnie zasila on gotowymi regułami bazę reguł. Drugi etap to analizowanie na bieżąco zebranych danych w określonych odstępach czasowych. Moduł filtruje dane przez określone wstępnie reguły i wyszukuje potencjalne zdarzenia.



Rys.5. Ogólny schemat działania wdrożonego narzędzia wspomagania statystycznego

Ostatni moduł to moduł interakcji człowieka z systemem. Występuje tu podział na eksperta oraz użytkownika. Rola eksperta, który również bazując na wiedzy, doświadczeniu, znajomości systemów sterowania i działających w nich mechanizmów, może zasilać bazę reguł. Druga ważna rola to usuwanie automatycznie wyszukanych reguł o znikomej wartości dla celów przedsiębiorstwa. Użytkownik jest natomiast klientem systemu otrzymującym gotowe raporty

z przewidywanymi zdarzeniami. Jego rolą jest analiza raportów i podjęcie kroków zapobiegawczych na obiekcie.


Aby poprawnie przeprowadzić analizy, dane wejściowe muszą być jednoznaczne, odpowiednio przetworzone. Pierwsza napotkana trudność to przesyłanie danych z systemu nadzoru do bazy danych oprogramowania Statistica. Wymagania bezpieczeństwa informatycznego przedsiębiorstwa nie pozwalają na integrację systemów zewnętrznych z bazami danych przedsiębiorstwa. Rozwiązaniem okazało się okresowe eksportowanie pliku z danymi, który mógł zasilić bazę danych, z której korzysta Statistica.

Druga niedogodność to generowanie raportów. Raporty powinny być w sposób łatwy dostarczone do odczytu dla odbiorcy. Zostało to rozwiązane za pośrednictwem raportu generowanego w postaci pliku o formacie stron WWW. Kolejną trudnością była częstotliwość, z jaką miałyby generować się raporty dla pracowników utrzymania ruchu. Na czas testu przyjęto częstotliwość dobową.

W zaimplementowanym rozwiązaniu przyjęto horyzont czasowy określany jako nadążna ramka czasowa, o wymiarze 48 godzin, w której analizowane są symptomy mogące w przyszłości powodować uszkodzenia.

#### 4. PREZENTACJA WYNIKÓW


Analizując uzyskane wyniki, zaskakujące w stosunku do przewidywań były proporcje, w jakich pojawiają się symptomy przed zaistnieniem uszkodzenia. W okresie 8 godzin przed uszkodzeniem pojawia się 80% symptomów. Rysunek 6 przedstawia wykres przyrostowy (linia ciągła) oraz procentowy (linia kropkowana) występowania symptomów w rozbiciu na przedziały czasowe dzielące wystąpienie symptomu od powstania uszkodzenia. Co skutkowało musi zwiększeniem częstotliwości generowania raportów dla utrzymania ruchu. Proponowana częstotliwość to sześć raportów na dobę. Alternatywą jest generowanie raportów on-line, co fizycznie skutkowało pojawianiem się nowych komunikatów, co kilka minut na laptopie pracowników utrzymania ruchu.



Rys. 6. Wykres powstania uszkodzenia w funkcji czasu wystąpienia symptomu

Zaobserwowano, iż blisko 7% wszystkich relacji pojawia się w czasie równoczesnym z zaistnieniem uszkodzenia. Rysunek 7 przedstawia wykres relacji pomiędzy procentową liczbą występień symptomów a przedziałami czasowymi liczonymi od wystąpienia symptomu do momentu powstania uszkodzenia. Wykonana weryfikacja tych zdarzeń wykazała, że niektóre reguły należy wyłączyć ze względu na ich

wynikowy charakter. Reguły te nie wnoszą wartości dodanej. Pojawiają się, gdyż są następstwem innej reguły. Zaimplementowane narzędzie statystyczne pozwala na dalsze zmniejszenie usterkowości linii produkcyjnej o 0,5%.



Rys. 7. Wykres relacji symptom-skutek z rozbiciem na przedziały czasowe

## 5. PODSUMOWANIE

W niniejszym referacie przedstawiono wdrożenie narzędzia do predykcyjnego wykrywania usterek. Wyniki osiągnięte podczas testowego rozwiązania pokazały, że możliwym jest równoczesne, zapewnienie wzrostu poziomu dostępności maszyn poprzez przewidywanie usterek na podstawie statystycznej analizy symptomów rejestrowanych przez system sterowania. Krótki czas przeprowadzania testowego wdrożenia oraz ograniczone zasoby nie pozwoliły na rozbudowę systemu. Jednakże uzyskane wyniki potwierdziły skuteczność i przydatność narzędzia.

Zaproponowane narzędzie odpowiada wymaganiom obecnie formułowanym przez przemysł w zakresie zwiększenia niezawodności maszyn i urządzeń. Narzędzie przeznaczone jest dla nowoczesnych linii produkcyjnych, gdyż bazuje na informacjach zbieranych z wszystkich elementów wyposażenia jak i systemów nadzoru. Na instalacjach starszego typu, wdrożenie systemu byłoby nierentowne. Ze względu na potrzebę dodatkowych nakładów, związanych z instalacją systemu pomiarowego

urządzeń oraz zainstalowaniem systemu zbierania danych z maszyn, jak i ewidencjonowania czynności operatora. Zaprezentowany system wykorzystuje nowoczesne metody zbierania, przetwarzania i analizy danych zgodne z trendami przemysłu 4.0.

Po pełnej optymalizacji rozwiązania, system może być z łatwością kopiowany i implementowany na podobnych instalacjach w przedsiębiorstwie. Powoduje to bardzo szybki, niskonakładowy i niewymagający dużych zasobów ludzkich wzrost niezawodności i bezpieczeństwa maszyn co pośrednio wpływa również na poprawę jakości wytwarzanych produktów. Proponowane narzędzie jest stworzone z myślą o użytkowniku, który poprzez analizę generowanych automatycznie raportów po pierwsze wyeliminuje potencjalne zdarzenie anormalne (cel krótkoterminowy). Po drugie podejmie akcje w celu wyeliminowania przyczyn tej anomalii lub zmniejszenia jej wpływu (cel długoterminowy).

## 6. BIBLIOGRAFIA

1. Kosmowski K.T.: Podstawy bezpieczeństwa funkcjonalnego. Politechnika Gdańska, Gdańsk, 2015.
2. Suzuki T. :TPM in process Industries, Oregon: Productivity Press, Portland 1994.
3. Rausand M.: Reliability centered maintenance. Reliability Engineering and System Safety 60, str. 121-132, 1998.
4. Harańczyk G.: Przewidywanie awarii i problemów z jakością, Statsoft, Kraków 2013.
5. Agraval R., Srikant R.: Fast algorithms for Mining Association Rules, Proceedings of the 20th International Conference on Very Large Data Bases, Morgan Kaufmann Publishers Inc, str 487-499, San Francisco 1994.
6. <http://www.smartcontrols.in>; data odczytu: 15.05.2016.
7. Piesik J.: Zastosowanie narzędzi statystycznych do poprawy niezawodności i bezpieczeństwa maszyn poprzez predykcję awarii oraz poprawę pokrycia diagnostycznego maszyn, Zastosowanie statystyki i data mining w badaniach naukowych oraz doskonalenie procesów produkcyjnych z wykorzystaniem analizy danych, Statsoft, Kraków 2015, s. 191-203.
8. Moczko J.: Wybrane metody eksploracji danych i wspomaganie procesów decyzyjnych, Statsoft, Kraków 2003.

## METHOD FOR RELIABILITY AND PRODUCTION LINE PROCESSES MANAGEMENT AIDED BY STATISTICAL ANALYSIS OF RELIABILITY DATA

The paper presents the management method of reliability and service process of production line with the implementation of computer-aided statistical tool on the production line of semi-finished products for tire production. Author proposed the complex strategy of reliability management composed of three elements: Total Productive Maintenance (TPM), Reliability Centered Maintenance (RCM) and computer-aided statistical tool with prediction of potential defects and failures (CAST-P). Important issue is to obey the order of deployments of those techniques (TPM-RCM-CAST-P). CAST-P tool using Apriori algorithm analyze the historical data gathered by the supervising production system to find the rules. Created set of rules is used for filtering current data from the production line and find potential defects and failures. Rapport with potential defects is send at web page version to maintenance breakdown worker. The final step is the reaction of maintenance personnel for predicted symptoms. The paper aims to show effective, relatively cheap and easy to implement in a variety of industrial environments tools to improve machine reliability and indirectly improve the quality of produced goods.

**Key-words:** algorithm Apriori , defects prediction.