

Wyznaczanie kluczowych wskaźników wydajności procesu produkcyjnego – część II: badania przemysłowe

Dariusz Król

Politechnika Wroclawska, Wydział Informatyki i Zarządzania, Katedra Informatyki Stosowanej, ul. Wybrzeże S. Wyspiańskiego 27, 50-370 Wrocław

Jan Skowroński

DSR S.A., ul. Legnicka 55F, 54-203 Wrocław,

Politechnika Wroclawska, Wydział Informatyki i Zarządzania, Katedra Informatyki Stosowanej, ul. Wybrzeże S. Wyspiańskiego 27, 50-370 Wrocław

Maciej Zaręba

DSR S.A., ul. Legnicka 55F, 54-203 Wrocław

Krzysztof Bartecki

Politechnika Opolska, Wydział Elektrotechniki, Automatyki i Informatyki, Katedra Automatyki, ul. Prószkowska 76, 45-758 Opole

Streszczenie: Zastosowanie nowych technologii w Przemysle 4.0 umożliwia lepszą organizację, monitorowanie, kontrolę oraz skuteczną optymalizację procesów produkcyjnych, szczególnie w zakresie wydajności. Prezentowane rozwiązanie opiera się na hierarchicznej analizie wskaźników efektywności, w tym głównie na kontroli wskaźnika ogólnej efektywności zasobów produkcyjnych OEE. Rosnąca liczba możliwych do uzyskania skwantyfikowanych sygnałów monitorujących pracę maszyn, temperaturę otoczenia czy częstotliwość drgań sprawia, że narzędzia wspomagające decyzje są coraz bardziej wyrafinowane i, poza prezentacją obecnego stanu zasobów, coraz częściej obejmują także analizę predykcyjną. Opisywane narzędzie PUPMT pozwala zidentyfikować kluczowe zdarzenia, które mają istotny wpływ na bieżącą lub przyszłą efektywność produkcji. Umożliwia także analizę typu *what-if*, dopuszczając symulację wpływu projektowanych zmian, a wyniki tej symulacji uzależnia od skutków podobnych zmian, które miały miejsce w przeszłości w danym przedsiębiorstwie. Dzięki automatycznej identyfikacji potencjalnych zależności rozwiązanie dostosowuje się do specyfiki firmy lub wybranej jednostki produkcyjnej. Początkowe rozdziały zawierają m.in. opis najważniejszych metod wykorzystywanych w rozwiązaniu PUPMT. W dalszej części przedstawiono wybrane wyniki badań przemysłowych, które przeprowadzono na kilkudziesięciu jednostkach produkcyjnych.

Słowa kluczowe: kluczowe wskaźniki wydajności, proces produkcyjny, pomiary, systemy wspomaganie decyzji, Przemysł 4.0

1. Wprowadzenie

Przedstawione w artykule koncepcje oraz wyniki badań przemysłowych, dotyczące narzędzia wyznaczania kluczowych wskaźników wydajności procesu produkcyjnego, zostały opracowane

Autor korespondujący:

Dariusz Król, dariusz.krol@pwr.edu.pl

Artykuł recenzowany

nadesłany 20.07.2020 r., przyjęty do druku 26.08.2020 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 3.0

w ramach projektu *Production Unit Performance Management Tool (PUPMT)*¹. Celem projektu było opracowanie, wykonanie prototypu i przetestowanie w warunkach przemysłowych narzędzia monitorującego diagnostycznego, umożliwiającego selekcję czynników mających istotny wpływ na wskaźniki efektywności jednostek produkcyjnych.

Przedmiotem wcześniej opublikowanej pierwszej części artykułu [1], opisującej wstępny etap realizacji wspomnianego projektu, było omówienie metodyki wyznaczania oraz analizy

¹ Production Unit Performance Management Tool (PUPMT) – opracowanie innowacyjnego narzędzia monitorująco-diagnostycznego w zakresie selekcji czynników mających istotny wpływ na wskaźnik efektywności wydzielonych jednostek produkcyjnych opierającego się na paradygmatach teorii sterowania w celu optymalizacji procesów produkcyjnych w przemyśle. Nr umowy POIR.01.01.01-00-0687/17-00.

wskaźników KPI pod kątem oceny efektywności typowego procesu produkcyjnego. Przedstawiono tam zarówno wybrane informacje dostępne w literaturze przedmiotu (w tym najważniejsze założenia normy ISO:22400), jak też oryginalne opracowania autorskie oceny efektywności procesu produkcyjnego z wykorzystaniem omawianych wskaźników.

Niniejsze opracowanie stanowi drugą część artykułu, która prezentuje opracowane metody analizy i selekcji sygnałów mających wpływ na wydajność procesu produkcyjnego. Przykładem takiego sygnału, zidentyfikowanego w trakcie prac badawczych, jest prędkość przesuwu taśmy oraz sygnał identyfikujący pracownika obsługującego daną maszynę. Analiza sygnałów i ich powiązań z wydajnością zasobów dzieli się na etap klasyfikacji sygnałów CLAM (ang. *CLAssification Method*), analizy korelacji między nimi CORM (ang. *CORrelation Method*), a także etap selekcji istotnych czynników determinujących przyszłą efektywność procesu produkcyjnego SELM (ang. *SELECTION Method*). Obecna część artykułu została poświęcona także badaniom przemysłowym, które pozwoliły empirycznie zweryfikować zaproponowane metody.

Bieżącą, drugą część artykułu podzielono na pięć rozdziałów. W rozdziale drugim dokonano przeglądu wybranych rozwiązań monitorowania i analizy kluczowych wskaźników wydajności procesu produkcyjnego. W trzecim rozdziale zaprezentowano architekturę rozwiązania PUPMT w zakresie metod klasyfikacji sygnałów (CLAM), analizy korelacyjnej sygnałów (CORM) i selekcji kluczowych czynników wpływających na efektywność procesu produkcyjnego (SELM). Rozdział czwarty poświęcono ewaluacji metod na przykładzie wybranej jednostki produkcyjnej. Ostatni rozdział stanowi podsumowanie obydwu części.

2. Przegląd literatury

Wzrost produktywności jest powszechnie rozumianym wyzwaniem, przed którym stoją przedsiębiorstwa produkcyjne działające w erze globalizacji rynków. W konsekwencji powstało wiele koncepcji zarządzania produktywnością przedsiębiorstwa, które dostarczyły użytecznych narzędzi do mierzenia produktywności, a następnie zostały wykorzystane do budowy systemów wspomagających zarządzanie produktywnością przedsiębiorstw produkcyjnych [3]. Konkurencja na rynku globalnym wymaga automatyzacji procesów produkcyjnych, ale także wspomaganie procesów decyzyjnych, które wpływają na przyszłą produktywność i pozwalają zoptymalizować stopień wykorzystania posiadanych zasobów [17]. Z pomocą przychodzi rewolucyjny rozwój technologii informacyjnych i komunikacyjnych, które spowodowały kolejną rewolucję w przemyśle [5].

Jednym z najbardziej znanych podejść do utrzymania przedsiębiorstwa w najwyższej sprawności produkcyjnej jest podejście TPM (ang. *Total Productive Maintenance*), które zostało zapoczątkowane przez Seiichi Nakajimę z Japan Institute of Plant Maintenance² [14]. TPM dostarcza organizacjom zestaw dobrych praktyk, które ułatwiają reorganizację przedsiębiorstwa poprzez integrację kultury, procesów i technologii w celu zwiększenia jego produktywności [12]. Jest to także metodyka silnie ukierunkowana na ustawiczne doskonalenie zarządzania operacyjnego aktywami przedsiębiorstwa, co ma na celu zwiększenie niezawodności sprzętu produkcyjnego poprzez zmniejszenie takich zagrożeń ciągłości produkcji jak awarie czy nieplanowane przestoje [4].

Jednym z najmocniejszych punktów koncepcji TPM jest zhierarchizowany zestaw numerycznych miar produktywności zawierający m.in. wskaźnik Ogólnej Efektywności Wyposażenia OEE (ang. *Overall Equipment Efficiency*) [1, 18]. Do dziś OEE jest jednym z najpopularniejszych wskaźników produktywności,

który jest wykorzystywany w szerokim zakresie w wielu sektorach przemysłu [13]. Przykładów udanych wdrożeń systemów monitorujących OEE można najczęściej doszukać się w największych firmach z branży farmaceutycznej, telekomunikacyjnej, motoryzacyjnej, czy też wśród producentów elektroniki³ [2, 6, 7].

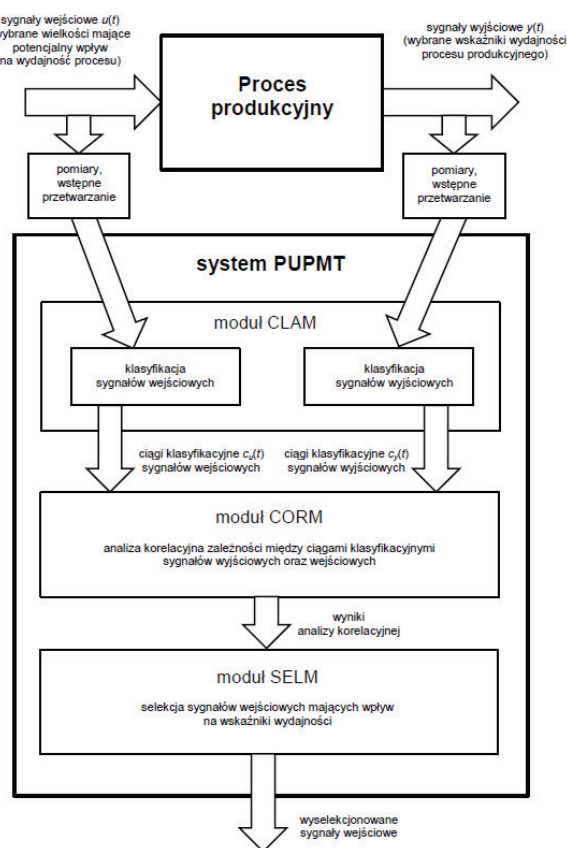
Koncepcja OEE oraz standardy dedykowane temu wskaźnikowi określone w normie ISO:22400 [8, 9] zostały wyczerpująco opisane w pierwszej części tego artykułu [1]. Hierarchiczna struktura OEE i innych wskaźników produktywności z rodziny TPM wpłynęła na ich dużą popularność wśród systemów wspomagających zarządzanie produktywnością przedsiębiorstw [2, 11, 17].

3. Architektura rozwiązania PUPMT

Zgodnie z koncepcją przedstawioną w raporcie [10], ze względu na złożony charakter problemu, strukturę systemu umożliwiającego wyznaczenie kluczowych czynników wpływających na efektywność wykorzystania zasobów przedsiębiorstwa produkcyjnego podzielono na trzy moduły (rys. 1).

W pierwszej fazie, realizowanej przez moduł CLAM, wykorzystywana jest metoda klasyfikacji sygnałów wejściowych, reprezentujących wielkości mające potencjalny wpływ na efektywność procesu produkcyjnego oraz sygnałów wyjściowych reprezentujących wybrane wskaźniki wydajności procesu (np. wskaźnik OEE lub jego wskaźniki składowe).

Druga faza skupia się na identyfikacji zależności pomiędzy wynikami klasyfikacji sygnałów wejściowych a wynikami klasyfikacji wskaźników. Do tego celu służy moduł CORM, w którym identyfikowane są istotne zdarzenia, czyli okresy, w których nastąpiła zmiana klasy, a następnie dokonywana jest analiza wpływu tychże zmian na produktywność wybranych zasobów.



Rys. 1. Architektura rozwiązania PUPMT

Fig. 1. PUPMT tool architecture

² Japan Institute for Plant Maintenance (JIPM). Strona domowa instytutu: <https://www.jipm.or.jp>.

³ Szczególną popularność koncepcja OEE zyskała wśród azjatyckich producentów półprzewodników [8].

W ostatnim etapie działania proponowanego narzędzia dokonuje się selekcji kluczowych zależności między zmianami klas sygnałów wejściowych, a zmianami klas wskaźników produktywności, za pomocą modułu SELM. Na wyjściu tego etapu uzyskuje się ranking par sygnałów o najwyższej sile zależności między nimi. W kolejnych rozdziałach opisano trzy wymienione moduły, które składają się na proponowane rozwiązanie PUPMT.

3.1. Opis modułu CLAM

CLAM służy do klasyfikacji zarówno sygnałów wejściowych, reprezentujących wybrane wielkości mające potencjalny wpływ na wydajność procesu, jak i sygnałów wyjściowych, reprezentujących wybrane wskaźniki efektywności procesu produkcyjnego, w sposób uwzględniający ich semantykę. Jest to metoda przetwarzania ciągu liczbowego reprezentującego zmiany mierzonej wartości sygnału wejściowego do postaci ciągu liczb reprezentujących wartości klas, do których należy badany sygnał w danym punkcie czasowym. W tym miejscu należy zwrócić uwagę, że nawet sygnały będące reprezentacją przebiegu zmienności tej samej wielkości mogą wymagać odmiennego podejścia w kontekście ich semantyki. Może to dotyczyć na przykład sygnału reprezentującego przebieg zmienności temperatury. Szczególnie istotne może być jego odchylenie od wartości pożądanej w danym procesie produkcyjnym. Z kolei dla innego sygnału, również odzwierciedlającego zmiany temperatury w czasie, kluczowy może być fakt nieprzekroczenia zadanej wartości maksymalnej, minimalnej albo przyjmowanie wartości z określonego przedziału wartości granicznych.


Z tego powodu zdefiniowano zbiór typów kryteriów semantycznych dla sygnałów zmiennych w czasie. Dla każdego badanego sygnału, na bazie znajomości jego semantyki, określany jest zbiór kryteriów. Następnie, dobierane są parametry poszczególnych kryteriów. Każdy z typów ograniczeń posiada klasyfikator, a parametry tego klasyfikatora są definiowane na podstawie znajomości semantyki danego sygnału. W wyniku działania klasyfikatorów dla poszczególnych typów ograniczeń powstają ciągi czasowe reprezentujące klasyfikację sygnałów dla punktu czasowego t (rys. 2).

Biorąc pod uwagę wybrany punkt czasowy t można określić n klas, które stanowią wektor wartości cech dla klasyfikatora sygnału. W rezultacie powstaje ciąg czasowy zawierający numery klas, do których należy dany sygnał w punkcie czasowym t . Każdy z rzeczywistych sygnałów można rozważać w kontekście jednego lub większej liczby kryteriów, które odnoszą się do semantyki tego sygnału.

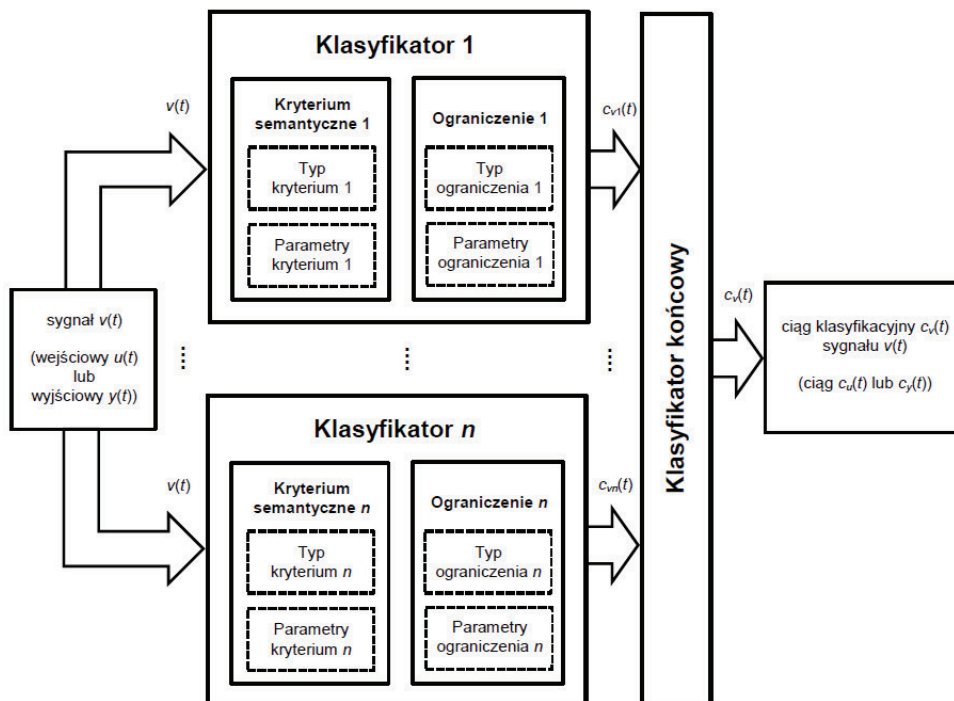
Typy kryteriów semantycznych bazują na powiązaniu dwóch elementów: typów kryteriów oraz typów ograniczeń. Z kolei kryterium semantyczne stanowi połączenie wybranego kryterium i określonego dla niego ograniczenia.

Dobór kryterium jest ściśle związany z typem jednostki produkcyjnej. Na podstawie raportu [10] zidentyfikowano cztery rodzaje kryteriów: wartość sygnału, czas trwania sygnału o określonej wartości, liczbę ekstremów lokalnych oraz średnią odległość między ekstremami lokalnymi. Dla wybranych rodzajów kryteriów zastosowano trzy typy ograniczeń: wartość pożądana DV , maksymalizacja wartości MAX oraz minimalizacja wartości MIN .

Wybór ograniczenia typu DV determinuje zbiór klas, który w tym przypadku określony jest przez dwie wielkości: liczbę klas i wartość graniczną. Liczba klas określa liczbę przedziałów dzielących przestrzeń wartości sygnału, a wartość graniczna wyznacza dolną granicę wartości dla klasy najbardziej odległej od wartości pożądanej (rys. 3).




Rys. 3. Graficzna prezentacja ograniczenia typu wartość pożądana DV na sześciostopniowej skali oceny sygnału
 Fig. 3. Graphic presentation of the desirable value DV limit on a six-level signal evaluation scale

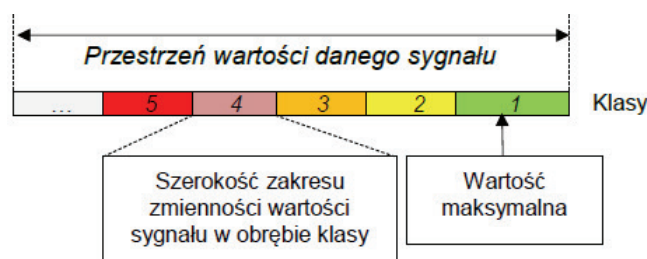


Rys. 2. Schemat blokowy działania metody klasyfikacji sygnałów CLAM dla wielu kryteriów semantycznych sygnału $v(t)$
 Fig. 2. Block diagram of the CLAM signal classification method using multiple semantic criteria of the signal $v(t)$

Ograniczenie typu *MAX* wymaga określenia zbioru klas przez dwie wielkości: minimalną wartość graniczną oraz szerokość zakresu zmienności sygnału w obrębie klasy. Dla niektórych sygnałów określenie granicznej wartości minimalnej sygnału może być zadaniem bardzo trudnym. Dlatego też należy przyjąć regułę, że jeżeli wartość danego sygnału spadnie poniżej minimalnej wartości granicznej, to zostanie on przypisany do najbliższej klasy (rys. 4).



Rys. 4. Graficzna prezentacja działania ograniczenia typu *MAX* na pięciostopniowej skali oceny sygnału
Fig. 4. Graphical presentation of the *MAX* type limit operation on a five-point signal evaluation scale



Rys. 5. Graficzna prezentacja działania ograniczenia typu *MIN* na pięciostopniowej skali oceny sygnału
Fig. 5. Graphical presentation of the *MIN* type limit operation on a five-point signal evaluation scale

Dla ograniczenia typu *MIN* zbiór klas określa się za pomocą następujących wielkości: maksymalnej wartości granicznej oraz szerokości zakresu zmienności sygnału w obrębie klasy. Przy określaniu granicznej wartości maksymalnej sygnału należy przyjąć regułę, że jeżeli wartość sygnału wzrośnie powyżej maksymalnej wartości granicznej, to analogicznie jak poprzednio zostanie on przypisany do najbliższej klasy (rys. 5).

Zgodnie z rys. 2, w wyniku klasyfikacji sygnałów opartej o kryteria semantyczne najpierw otrzymujemy przekształcenie sygnału wejściowego w zbiór klas sygnałów dla poszczególnych kryteriów semantycznych. Kolejnym krokiem jest klasyfikacja sygnału polegająca na przekształceniu zbioru sygnałów klas dla poszczególnych kryteriów semantycznych w ciąg klasyfikacji sygnału. Stosując zapis formalny, klasyfikacja polega na przekształceniu dwuetapowym:

$$C: v(t) \rightarrow \{c_{i1}(t), c_{i2}(t), \dots, c_{im}(t)\} \rightarrow c_v(t) \quad (1)$$

gdzie $v(t)$ to przykładowy sygnał wejściowy lub wyjściowy, $c_{im}(t)$ to wynik wstępnej klasyfikacji sygnału $v(t)$ według określonego i -tego kryterium, a $c_v(t)$ to końcowy ciąg klasyfikacyjny sygnału $v(t)$.


Przekształcenie (1), stanowiące podstawę działania modułu CLAM, polega na wyznaczeniu numeru klasy dla poszczególnych sygnałów w wybranych punktach czasowych. Zadanie to jest realizowane cyklicznie, wraz z pojawianiem się kolejnych danych dostarczanych z systemu produkcyjnego. Pierwszym krokiem ustalania zależności między sygnałami jest konwersja ciągów wartości reprezentujących zmierzone lub obliczone wielkości wej-

ściowe u i wyjściowe y na ciągi numerów klas, do których należy sygnał w danej chwili t :


$$u(t) \rightarrow c_u(t) \quad (2)$$

$$y(t) \rightarrow c_y(t) \quad (3)$$

gdzie $c_u(t)$ oraz $c_y(t)$ przyjmują wartości z odpowiednich zbiorów numerów klas. Zależności (2) i (3) to szczególne przypadki przekształcenia (1). Graficzną prezentację przykładowego ciągu wejściowego $u(t)$ skonwertowanego do postaci ciągu klasyfikacyjnego $c_u(t)$ przedstawia rys. 6.



Rys. 6. Przykładowy ciąg klasyfikacyjny $c_u(t)$
Fig. 6. Sample classification sequence $c_u(t)$



Rys. 7. Przykładowy ciąg klasyfikacyjny $c_y(t)$
Fig. 7. Sample classification sequence $c_y(t)$

Dla ciągu wejściowego $u(t)$ przewidziano 5 stopniową skalę klasyfikacji. W analizowanym okresie przedstawiony na rys. 6 przykładowy sygnał $u(t)$ osiągał wartości pozwalające sklasyfikować go do każdej z 5 klas, a więc wykazał się stosunkowo dużą zmiennością.

Poza klasyfikacją sygnałów wejściowych, również do klasyfikacji sygnałów wyjściowych, reprezentujących wybrane wskaźniki wydajności procesu produkcyjnego. Przykład ciągu klasyfikacyjnego wskaźnika OEE dla jednej z badanych jednostek produkcyjnych przedstawia rys. 7. Również w tym przypadku przyjęto pięć klas na skali oceny wartości sygnału.

Uzyskanie ciągów klasyfikacji sygnałów jest jednym z kluczowych elementów opracowanej metody, gdyż pozwala przekształcać sygnały do postaci ciągów liczb reprezentujących klasę

sygnału w danym punkcie czasowym t . Wspomniana wyżej konwersja sygnału sprowadza się zarówno do jego dyskretyzacji, jak i kwantyzacji. Przyczynia się ona do znacznej redukcji danych oraz do wypuklenia istotnych semantycznie własności sygnału pierwotnego.

3.2. Opis modułu CORM

Zadanie identyfikacji zależności między wynikami klasyfikacji sygnałów wejściowych a wynikami klasyfikacji wskaźników uogólniono do postaci problemu zdefiniowania miary określającej poziom korelacji między dwoma sygnałami: wejściowym i wyjściowym. W wyniku działania klasyfikacji sygnałów metodą CLAM opisaną w rozdziale 3.1, uzyskuje się ciągi klas dla sygnałów wejściowych i wyjściowych (wskaźników). Działanie to pozwala uniknąć bezpośredniego porównania sygnałów, których zmienność może być bardzo różna i przez to praktycznie nieporównywalna. Uzyskane ciągi klasyfikacji sygnałów stanowią dane wejściowe dla metody identyfikacji zależności CORM opisanej w tym rozdziale.

Działanie modułu CORM polega na oszacowaniu siły korelacji między zmianą klasy sygnału wejściowego ze zmianą klasy sygnału wyjściowego, np. zależności zmian klasy prędkości przesuwu taśmy ze zmianą klasy wskaźnika jakości produktu.

Na potrzeby opracowania miary zależności między sygnałami oraz algorytmu prowadzącego do wykorzystania tej miary przyjęto szereg założeń, które zostały opisane w dalszej części tego rozdziału. Opisana metoda identyfikacji zależności między sygnałami polega na znalezieniu miary korelacji zmiany klasy sygnału wejściowego ze zmianą klasy sygnału wyjściowego. Dla wskazanego problemu kluczowe są zdarzenia stanowiące zmianę klasy sygnału oraz koincydencja zdarzeń zmian klas sygnału wejściowego i wyjściowego. Z kolei koincydencja zdarzeń zmian klas sygnałów ma związek z inercją układu, która określa przesunięcie w czasie zależności między zdarzeniami, a także z marginesem zmian inercji układu określającym przedział czasu, w którym dane zdarzenie ma wpływ na analizowany układ. Ostatnim kluczowym elementem badanego problemu jest zagadnienie miary poziomu koincydencji zdarzeń zmian klas sygnałów.

Spodziewanymi efektami wykorzystania metody identyfikacji zależności między dwoma sygnałami jest ustalenie poziomu zależności między nimi, a więc siły tej zależności i jej kierunku, stąd wartość wykorzystanej miary korelacji powinna określać wszystkie wymienione cechy zależności.

Algorytm opracowany dla modułu CORM można przedstawić jako ciąg następujących po sobie kroków:

1. Ciągi klasyfikacji sygnału wejściowego i wyjściowego zostają przekształcone na ciągi zmian klasy sygnału, którym nadano etykiety przedstawiające charakter zdarzenia. Przykładowo, zmiana klasy 2 na 1 przyjmuje etykietę [2-1], a zmiana klasy 2 na 3 etykietę [2-3] itd.
2. Tworzone są ciągi zmian klas sygnałów dla wszystkich typów zdarzeń.
3. Obliczana jest liczba współwystąpień wybranych zdarzeń na obu sygnałach, która to liczba stanowi miarę koincydencji dwóch sygnałów.

Ponadto przyjęto, że jeżeli sygnał wejściowy ma wpływ na sygnał wyjściowy, to zmiana klasy sygnału wejściowego powinna pociągać za sobą zmianę klasy sygnału wyjściowego. Dlatego w module CORM pomiar stopnia koincydencji dwóch sygnałów poprzedza identyfikacja istotnych zdarzeń rozumianych jako zmiana klasy sygnału. Ciągi klas sygnałów $c_u(t)$ oraz $c_y(t)$ są na tym etapie przekształcane w ciągi zmian klas sygnałów $p_u(t)$ oraz $p_y(t)$:

$$c_u(t) \rightarrow p_u(t) \quad (4)$$

$$c_y(t) \rightarrow p_y(t) \quad (5)$$

gdzie $p_u(t)$ i $p_y(t)$ przyjmują wartości z odpowiednich zbiorów typów zmian klas P .

Ponieważ liczba klas sygnału jest ograniczona, to liczba możliwych typów zmian jest również ograniczona. Algorytmicznie rzecz ujmując, listę elementów zbioru P należy zbudować iterując po indeksach i, j nadając kolejnym typom zmian klasy sygnału odpowiednio symbole numeryczne zapewniając jednocześnie, że w przypadku, gdy nie następuje zmiana klasy sygnału ($i = j$), to odpowiedni element nie zostaje dodany do listy. Na rys. 6 przedstawiono graficzną prezentację ciągu klasyfikacyjnego $c_u(t)$, który jest następnie konwertowany do postaci ciągu zmian klas sygnałów $p_u(t)$.

Ciągi zmian klasy mogą zostać przedstawione w postaci wektora, którego indeks określa punkt czasowy, a wartość elementu o danym indeksie określa typ zmiany klasy (+1 lub -1). Dla sygnału klasyfikowanego wg skali sześciostopniowej, tak jak w przypadku przykładowych sygnałów: wejściowego $c_u(t)$ z rys. 6 i wyjściowego $c_y(t)$ z rys. 7, można zbudować macierz zdarzeń z nowymi etykietami ze zbioru P , której przykład zaprezentowano w tab. 1.

Tab. 1. Przykładowa macierz typów zdarzeń zmiany klasy sygnału do dwuelementowego zbioru P

Tab. 1. Sample matrix of event types of signal class change into a two-element P set

		Zmiana z klasy					
		1	2	3	4	5	6
Zmiana na klasę	1		+1	+1	+1	+1	+1
	2	-1		+1	+1	+1	+1
	3	-1	-1		+1	+1	+1
	4	-1	-1	-1		+1	+1
	5	-1	-1	-1	-1		+1
	6	-1	-1	-1	-1	-1	

Zgodność dwóch przebiegów czasowych $p_u(t)$ oraz $p_y(t)$ jest obliczana przez iterowanie o zadaną wartość wzajemnego przesunięcia tych przebiegów w osi czasu, a następnie obliczenia stopnia korelacji między dwoma ciągami ocen zdarzeń zmian sygnałów. W efekcie powstaje funkcja przyjmująca wartości stanowiące o poziomie zgodności analizowanych przebiegów, której dziedziną jest wzajemne ich przesunięcie w czasie, czyli inercja (i). Wartość przesunięcia, dla którego funkcja ta osiąga maksimum, określa o ile należy badane przebiegi wzajemnie przesunąć w czasie, aby uzyskać maksymalną ich zgodność. Maksimum tej funkcji określa poziom zgodności analizowanych przebiegów czasowych. Częstotliwości próbkowania sygnału wejściowego i wyjściowego mogą być różne, ale podczas badań zastosowano najpierw ciągi sygnałów o granulacji dziennej, a następnie godzinowej. Drugi przypadek okazał się trafniejszy z punktu widzenia dynamiki zjawisk zachodzących w procesie produkcyjnym.

Oprócz inercji, która ma za zadanie uchwylić przypadki, kiedy zmiana klasy sygnału wejściowego zwykle odzwierciedla się w wynikach produktywności (np. w odczycie wskaźnika OEE) z pewnym opóźnieniem, do analizy korelacji dodano również parametr określony jako margines (m). Wartość marginesu określa długość oddziaływania danego zdarzenia. Przykładowo margines równy zero ($m = 0$) oznacza, że zdarzenia zmiany klasy sygnałów wejściowego i wyjściowego muszą nastąpić w tym samym momencie, aby metoda CORM zidentyfikowała je jako skorelowane. Konsekwentnie margines równy 2 ($m = 2$) oznacza, że zdarzenie zmiany klasy sygnału wejściowego może być rozważane

jako potencjalna przyczyna zmiany klasy sygnału wyjściowego w tym samym okresie ($m = 0$), jeden okres wcześniej lub później ($m = 1$) lub nawet dwa okresy wstecz lub w przód ($m = 2$).

Wprowadzenie pojęć *inercji* i *marginisu* pozwala nie tylko na oszacowanie korelacji zdarzeń zmiany klasy sygnałów wejściowych i wyjściowych, ale także na określenie długości oddziaływania zdarzeń zmiany klasy sygnałów wejściowych oraz ewentualnego opóźnienia wpływu tych zdarzeń na produktywność zasobów. Dla każdej pary składającej się z sygnału wejściowego i sygnału wyjściowego, w module CORM konstruuje się nowe szeregi czasowe reprezentujące układy określane przez wartość marginisu i inerji.

3.3. Opis modułu SELM

SELM dokonuje selekcji sygnałów wejściowych procesu produkcyjnego mających wpływ na sygnały wyjściowe, reprezentujące określone wskaźniki jakości tego procesu (rys. 1). Jest to metoda, która korzysta z danych wyjściowych modułu CORM, a więc wyników analizy korelacji układów sygnał-sygnał. Tabela 2 przedstawia zestawienie 10 układów (marginisu, inercja) sygnałów wejściowych o najwyższym stopniu korelacji z sygnałem wyjściowym w postaci wskaźnika OEE w analizowanym okresie.

W kolumnie (a) przedstawiono symboliczne kody wybranych jednostek produkcyjnych, na których zidentyfikowało przypadki sygnałów wejściowych o szczególnie wysokiej korelacji lub szczególnie niskiej (dla korelacji ujemnej) ze wskaźnikiem OEE (e). W kolumnie (b) umieszczono kod sygnału wejściowego, natomiast w kolejnych dwóch kolumnach umieszczono wartości *marginisu* (c) i *inerji* (e), które pokazują dla jakiego układu uzyskano w tej parze (sygnał wejściowy – OEE) najwyższą-najniższą korelację. W ostatniej kolumnie (f) przedstawiono wartość bezwzględną korelacji, a więc szacunek faktycznej siły oddziaływania bez wskazania kierunku, która stanowi główne kryterium rankingu uzyskiwanego na wyjściu modułu SELM.

4. Ewaluacja rozwiązania

W rozdziale tym zawarto przykładowe wyniki weryfikacji empirycznej opisanych wyżej metod. Testy przeprowadzono na zbiorze danych rzeczywistych, uzyskanych dla kilkudziesięciu jednostek produkcyjnych z kilku przedsiębiorstw, dla których najpierw przeprowadzono wstępną analizę statystyczną zarejestrowanych danych.

Wśród badanych sygnałów wejściowych znalazły się m.in. sygnały binarne określające, czy dana jednostka produkcyjna jest w stanie pracy, czy jest wyłączona. Kolejną grupą stanowią sygnały przyjmujące wartości z ograniczonego zbioru liczb (najczęściej całkowitych dodatnich), do których zaliczają się np. sygnały badające liczbę przestojów i mikroprzebojów lub sygnały określające liczbę pracowników. Na liście znajdują się również sygnały pochodzące ze specjalistycznych czujników, które mają o wiele liczniejszy zbiór możliwych wartości. Do nich zaliczają się sygnały monitorujące pobór mocy jednostki produkcyjnej, ale także sygnały reprezentujące takie warunki pracy jednostki produkcyjnej jak temperatura i wilgotność otoczenia. Listę sygnałów wejściowych pochodzących z wybranej jednostki produkcyjnej, które wykorzystano w badaniu przedstawiono w tab. 3.

Z kolei jako sygnały wyjściowe, badane w ramach testów metody identyfikacji zależności, wybrano następujące wskaźniki KPI:

- dostępność (A),
- efektywność (E),
- jakość (QR),
- całkowita efektywność wyposażenia (OEE).

Duża liczba sygnałów wejściowych i bogata reprezentacja jednostek produkcyjnych pozwoliły dokonać weryfikacji działania proponowanych metod.

Na początku, kolejnym próbkiem sygnałów zarejestrowanych dla badanych jednostek przyporządkowano klasy zgod-

Tab. 2. Zestawienie 10 układów sygnałów wejściowych o najwyższej korelacji z OEE

Tab. 2. List of 10 input signal systems with the highest correlation with OEE

Kod jednostki produkcyjnej	Sygnał	Margines	Inercja	Korelacja	Siła oddziaływania
a	b	c	d	e	f
S01	S01_Predkosc	1	3	0,82	0,82
T02	T02_Predkosc	1	2	-0,76	0,76
M02	M02_Predkosc	1	3	-0,63	0,63
P09	P09_WorkerCount	1	3	-0,60	0,60
M00	M00_Predkosc	1	3	-0,55	0,55
P01	P01_WorkerCount	1	0	0,54	0,54
M10	M00_Predkosc	1	0	0,50	0,50
P08	P08_WorkerCount	1	0	0,49	0,49
T04	T04_Predkosc	1	3	-0,43	0,43
P04	P04_WorkerCount	1	0	0,37	0,37

Tab. 3. Lista sygnałów monitorowanych w wybranej jednostce produkcyjnej

Tab. 3. List of monitored signals in the selected production unit

Sygnal	Opis
<i>Power</i>	Sygnal zasilania maszyny
<i>Work</i>	Sygnal pracy maszyny
<i>tempout</i>	Temperatura otoczenia maszyny [°C]
<i>humout</i>	Wilgotność otoczenia maszyny [%]
<i>tempin</i>	Temp. wewnątrz szafy sterowniczej [°C]
<i>TempIn_MAX</i>	Maksymalna temperatura zanotowana w czasie 1 godziny
<i>humin</i>	Wilgotność wewnątrz szafy sterującej [%]
<i>i1</i>	Natężenie prądu dla fazy 1 [A]
<i>i2</i>	Natężenie prądu dla fazy 2 [A]
<i>i3</i>	Natężenie prądu dla fazy 3 [A]
<i>u1</i>	Napięcie dla fazy 1 [V]
<i>u2</i>	Napięcie dla fazy 2 [V]
<i>u3</i>	Napięcie dla fazy 3 [V]
<i>e</i>	Chwilowe zużycie energii [W]
<i>vibration</i>	Wibracje na bloku maszyny [mm/s]
<i>Vibration_Max</i>	Maksymalna wartość wibracji zarejestrowana w ciągu 1 godziny
<i>ADETPAUBT</i>	Znormalizowany wskaźnik mikroprzestojów ADET/AUBT
<i>ADET_Count</i>	Liczba wystąpień mikroprzestojów w czasie 1 godziny

Tab. 4. Zestawienie ciągów zdarzeń i typów zdarzeń dla układu sygnał-wskaźnik o $m = 1$ i $i = 2$ Tab. 4. List of event sequences and event types for the signal-indicator system with $m = 1$ and $i = 2$

Zdarzenia sygnału wejściowego	Typ	Zdarzenia sygnału wyjściowego (OEE)	Typ
a	b	c	d
(5, 4)	1	(2, 4)	-1
(4, 5)	-1	(4, 3)	1
(4, 5)	-1	(3, 2)	1
(5, 1)	1	(2, 3)	-1
(4, 1)	1	(1, 5)	-1
(2, 1)	1	(1, 4)	-1
(1, 3)	-1	(4, 1)	1
(3, 1)	1	(1, 3)	-1
(4, 1)	1	(2, 5)	-1
(5, 4)	1	(5, 3)	1
(4, 1)	1	(2, 3)	-1
(4, 1)	1	(2, 1)	1
(1, 5)	-1	(5, 4)	1
(5, 3)	1	(3, 4)	-1
(1, 4)	-1	(5, 4)	1

nie z odpowiednią definicją. Ze względu na dużą ilość danych, w tej pracy, przedstawiono jedynie wyniki dla wybranej pary sygnałów z jednej jednostki produkcyjnej.

Rysunek 8 przedstawia przykładowy ciąg klasyfikacji wybranego sygnału wejściowego, uzyskany dla jednej z badanych jednostek produkcyjnych. Z kolei na rys. 9 przedstawiono analogiczny ciąg klasyfikacyjny, uzyskany dla sygnału wyjściowego reprezentującego złożony wskaźnik OEE.


Ciągi klasyfikacji sygnałów uzyskane na wyjściu modułu CLAM wprowadzono jako ciągi wejściowe do modułu CORM. Przekonwertowano je do postaci ciągów zdarzeń zmian klasy sygnałów, a następnie do postaci ciągów typów zdarzeń. Uzyskane ciągi poddano analizie korelacji zwiększając stopniowo margines oddziaływania danego zdarzenia oraz inercję układu sygnał-wskaźnik.

Tabela 4 prezentuje zestawienie ciągów zdarzeń sygnału wejściowego (a) i wskaźnika złożonego OEE (c), oraz ciągów typów zdarzeń w/w sygnałów (b i d), zestawione w układzie o pojedynczym marginesie ($m = 1$) i dwudniowej inercji ($i = 2$).


Dla każdej pary sygnał-wskaźnik wybrano układy ich zdarzeń (sygnałów zmiany klasy) cechujące się największą korelacją. Ma to na celu identyfikację zdarzeń zmiany klasy sygnału wejściowego, które najczęściej poprzedzały wzrost wydajności reprezentowany przez zmianę klasy sygnału wyjściowego. Dla prezentowanej pary sygnałów (rys. 8 i rys. 9) układem o najwyższym stopniu korelacji był układ o pojedynczym marginesie ($m = 1$) i dwudniowej inercji ($i = 2$). Wartość korelacji wyniosła w tym przypadku $-0,67$, a więc okazała się stosunkowo silną korelacją ujemną. Badany sygnał wejściowy reprezentował prędkość przesuwu taśmy. Układ o pojedynczym marginesie i dwudniowej inercji wskazuje, że zmiana klasy prędkości taśmy może znaleźć pełne odzwierciedlenie w wynikach produktywności dopiero po dwóch dniach.

5. Podsumowanie

Metoda wyznaczania kluczowych wskaźników wydajności procesu



Rys. 8. Ciąg klasyfikacyjny sygnału wejściowego $u(t)$
Fig. 8. Class sequence of the input signal $u(t)$



Rys. 9. Ciąg klasyfikacyjny sygnału wyjściowego $y(t)$
Fig. 9. Class sequence of the output signal $y(t)$

produkcyjnego, zaprojektowana w ramach projektu PUPMT, została przedstawiona w dwóch częściach. Badania teoretyczne, które dotyczyły opracowania metodyki oceny efektywności procesu produkcyjnego opartej na hierarchicznej strukturze wskaźników wydajności, zostały opublikowane w pracy [1]. W niniejszym artykule zaprezentowane zostały wyniki badań przemysłowych, polegających na implementacji zaproponowanej metody w wybranych jednostkach produkcyjnych.

Ogólną skuteczność narzędzia PUPMT zbadano w dwóch przedsiębiorstwach produkcyjnych, w których przeprowadzono pilotażowe projekty wdrożeniowe. Pracownicy badanych firm wprowadzali zmiany w procesie produkcyjnym na podstawie otrzymanych wyników analiz tak, aby poprawić efektywność procesu produkcyjnego. Głównym obszarem zmian było lepsze wykorzystywanie maszyn, czyli poprawa ich produktywności. W szczególności, analizie poddano dostępność maszyn, kosztocłonność ich pracy oraz awaryjność. Po kilku tygodniach pracy z narzędziem PUPMT przeprowadzono ocenę przydatności uzyskanych rezultatów dla opracowanych metod i narzędzi, na którą złożyły się:

- analiza porównawcza efektywności działania procesu produkcyjnego bez wykorzystania zaproponowanego narzędzia i z jego zastosowaniem na bazie określonych wskaźników, w tym kosztocłonności, awaryjności i dostępności.
- ankieta wśród kadry kierowniczej w zakresie oceny przydatności zaproponowanych metod i narzędzia.

Wyniki ankiety wskazują, że narzędzie PUPMT spełniło oczekiwania użytkowników. Zastosowanie jego prototypu w krótkim czasie pozwoliło na identyfikację czynników, które mają istotny wpływ na efektywność produkcji. Podjęte decyzje związane z wyrównaniem obciążenia poszczególnych maszyn i eliminacją zdiagnozowanych negatywnych czynników, pozwoliły na poprawienie dostępności maszyn o ponad 2%, co w konse-

kwencji doprowadziło do dłuższej pracy maszyny w ciągu dnia. O przydatności zastosowania opracowanego narzędzia świadczy również fakt, że bardzo podobny wynik uzyskano u dwóch różnych producentów.

Proponowane rozwiązanie daje duże możliwości dalszego rozwoju [16]. Doskonale wpisuje się w potrzeby koncepcji Przemysłu 4.0, ale także umożliwia włączenie elementów znanych już z koncepcji Przemysłu 5.0, np. przez wykorzystanie narzędzi kognitywnych, takich jak aktywne rozpoznawanie otoczenia, interpretowanie mowy, odkrywanie preferencji użytkowników, przewidywanie uszkodzeń [15]. Ze względu na generyczny charakter przedstawionego rozwiązania, przyjęte założenia bazujące na standardzie ISO oraz modułową konstrukcję, narzędzie PUPMT potencjalnie może być stosowane w wielu problemach optymalizacji nierozważanych w pracy. Pełna automatyzacja tego rodzaju zadań, dotychczas zarezerwowanych wyłącznie dla ludzi, w niedalekiej przyszłości na stałe zagości w przedsiębiorstwach produkcyjnych [2].

Bibliografia

1. Bartecki K., Król D., Skowroński J., *Wyznaczanie kluczowych wskaźników wydajności procesu produkcyjnego - część I: badania teoretyczne*, „Pomiary Automatyka Robotyka”, R. 22, Nr 3/2018, 5-13, DOI: 10.14313/PAR_229/5.
2. Da Silva V.L., Kovaleski J.L., Pagani R.N., De Matos Silva J., Corsi A., *Implementation of Industry 4.0 concept in companies: empirical evidences*. “International Journal of Computer Integrated Manufacturing”, Vol. 33, No. 4, 2020, 325–342, DOI: 10.1080/0951192X.2019.1699258.
3. Felsberger A., Qaiser F.H., Choudhary A., Reiner G., *The impact of Industry 4.0 on the reconciliation of dynamic capabilities: evidence from the European manufacturing industries*. “Production Planning & Control”, 2020, 1–24, DOI: 10.1080/09537287.2020.1810765.
4. Ginder A., Robinson A., Robinson C.J., *Implementing TPM: The North American Experience*. CRC Press, 1995
5. Hoyer Ch., Gunawan I., Reaiche C.H., *The Implementation of Industry 4.0 – A Systematic Literature Review of the Key Factors*. “Systems Research and Behavioral Science”, Vol. 37, No. 4, 2020, 557–578, DOI: 10.1002/sres.2701.
6. Huang S.H., Dismukes J.P., Shi J., Su Q., Wang G., Razzak M.A., Robinson D.E., *Manufacturing system modeling for productivity improvement*. “Journal of Manufacturing Systems”, Vol. 21, No. 4, 2002, 249–259, DOI: 10.1016/S0278-6125(02)80165-0.
7. Iannone R., Nenni M.E., *Managing OEE to optimize factory performance*. Operations Management. InTech, 2013, DOI: 10.5772/55322.
8. International Standard ISO 22400-1. *Automation Systems and Integration – Key Performance Indicators (KPIs) for Manufacturing Operations Management – Part 1: Overview, Concepts and Terminology*. Geneva: International Standard Organization (ISO), 2014.
9. International Standard ISO 22400-2. *Automation Systems and Integration - Key Performance Indicators (KPIs) for Manufacturing Operations Management – Part 2: Definitions and Descriptions*. Geneva: International Standard Organization (ISO), 2014.
10. Jodłowiec M., Krótkiewicz M., Wojtkiewicz K., *Rezultaty prac wykonanych przez Politechnikę Wrocławską dla DSR S.A. w ramach projektu Production Unit Performance Management Tool (PUPMT)*, raport, 30 lipiec 2018.
11. Lycke L., *Team development when implementing TPM*. “Total Quality Management & Business Excellence”, Vol. 14, No. 2, 2003, 205–213, DOI: 10.1080/1478336032000051395.

12. Moore R., *Combining TPM and reliability-focused maintenance*. "Plant Engineering", Vol. 51, No. 6, 1997, 88–90.
13. Muchiri P., Pintelon L., *Performance measurement using over all equipment effectiveness (OEE): literature review and practical application discussion*. "International Journal of Production Research", Vol. 46, No. 13, 2008, 3517–3535, DOI: 10.1080/00207540601142645.
14. Nakajima S., *Introduction to TPM: Total Productive Maintenance* (Preventative Maintenance Series). 1998. ISBN 0-91529-923-2.
15. Shi Z., Xie Y., Xue W., Chen Y., Fu L., Xu X., *Smart factory in Industry 4.0*, "Systems Research and Behavioral Science", Vol. 37, No. 4, 2020, 607–617, DOI: 10.1002/sres.2704.
16. Trotta D., Garengo P., *Assessing Industry 4.0 Maturity: An Essential Scale for SMEs*. 8th International Conference on Industrial Technology and Management (ICITM), 2019, 69–74, DOI: 10.1109/ICITM.2019.8710716.
17. Viswanadham N., Narahari Y., *Performance modeling of automated manufacturing systems* (497–508). Englewood Cliffs, NJ: Prentice Hall 1992.
18. Wireman T., *Total productive maintenance*. Industrial Press Inc. 2004.

Key Performance Indicators as a Tool for Production Process Assessment – Part II: Industrial Research

Abstract: The use of new technologies in Industry 4.0 enables better organization, monitoring, control and effective optimization of production processes, especially in terms of efficiency. The solution is based on a hierarchical analysis of key performance indicators, including mainly the control of Overall Equipment Effectiveness (OEE). The growing number of quantifiable signals monitoring machine operation, ambient temperature or even the frequency of vibrations makes decision support tools more and more sophisticated. Moreover, they also include predictive analysis in addition to presentations of the current state of resources. PUPMT tool allows identifying key events that have a significant impact on current or future production efficiency. It also allows the *what-if* type analysis, running the simulation of the impact of the proposed changes, and the results of this simulation depend on the effects of similar changes that occurred in the past in a given enterprise. Thanks to the automatic identification of potential dependencies, the proposed solution adapts to the specifics of a given company or even a selected production unit. The paper in the first part contains a description of the essential methods used in the PUPMT tool. The second part presents selected results of industrial research, which were carried out on several dozen production units.

Keywords: key performance indicators, production process, measurements, decision support systems, Industry 4.0

dr hab. inż. Dariusz Król, prof. PWRdariusz.krol@pwr.edu.pl
ORCID: 0000-0002-2715-6000

Kierownik Pracowni Inżynierii Wiedzy w Katedrze Informatyki Stosowanej na Wydziale Informatyki i Zarządzania Politechniki Wrocławskiej. W ramach działalności naukowo-badawczej brał udział w kilkunastu projektach, m.in. był kierownikiem grantów Ministerstwa Nauki i Szkolnictwa Wyższego, Niemieckiej Centrali Wymiany Akademickiej i Komisji Europejskiej. Jest autorem ponad 150 publikacji naukowych. Brał udział w pracach komitetów naukowych i organizacyjnych w ponad 100 konferencjach w kraju i za granicą. Jest ekspertem Komisji Europejskiej, Narodowego Centrum Badań i Rozwoju, Narodowej Agencji Wymiany Akademickiej, Fundacji na rzecz Nauki Polskiej oraz kilku zagranicznych programów stypendialnych. Jego zainteresowania naukowe i aplikacyjne są związane z metodami inżynierii wiedzy, w tym zagadnieniami integracji i jakości danych, analizy predykcyjnej, technik kognitywnych, uczenia głębokiego, w szczególności w zastosowaniach przemysłowych.

**mgr inż. Jan Skowroński**jan.skowronski@dss.com.pl
ORCID: 0000-0003-3291-1741

Kierownik Działu Badań i Rozwoju w firmie DSR S.A. W 2014 r. ukończył studia magisterskie o specjalności Inteligentne Systemy Informatyczne na Wydziale Informatyki i Zarządzania Politechniki Wrocławskiej. W ramach przewodu doktorskiego prowadzi badania w zakresie zastosowania metod rekomendacji w obszarze optymalizacji procesów produkcyjnych. Brał udział w licznych projektach badawczo-rozwojowych, w tym Inżynieria Internetu Przyszłości, Production Unit Performance Management Tool oraz Production Management Smart Advisor. Jego zainteresowania dotyczą zastosowania metod uczenia maszynowego oraz Internetu Rzeczy w celu poprawy efektywności procesów produkcyjnych. Współautor gry strategiczno-ekonomicznej 4FACTORY Manager, w której gracz rozwiązuje rzeczywiste problemy optymalizacji procesów produkcyjnych w polskich firmach produkcyjnych.

**dr Maciej Zaręba**maciej.zareba@dss.com.pl
ORCID: 0000-0003-4605-8024

W 2011 r. ukończył studia magisterskie o specjalności Analiza Finansowa na Wydziale Informatyki i Zarządzania Politechniki Wrocławskiej. Na tym samym wydziale w 2018 r. obronił pracę doktorską i uzyskał stopień doktora nauk o zarządzaniu w zakresie badań operacyjnych. Od ponad 8 lat pracuje jako konsultant ds. wdrożeń systemów ERP, głównie w zakresie modułu finansowego. Zawodowo zajmuje się analizami giełdowymi spółek produkcyjnych w ramach projektu Giełdowy Indeks Produkcji, jest pomysłodawcą wskaźnika GIP60. Jego zainteresowania dotyczą zagadnień związanych z zarządzaniem portfelem inwestycyjnym, analizą prognostyczną, makroekonomią, historią myśli gospodarczej i wybranymi aspektami wdrożeń systemów ERP.

**dr hab. inż. Krzysztof Bartecki, prof. PO**k.bartecki@po.edu.pl
ORCID: 0000-0002-5744-808X

W 1996 r. ukończył studia magisterskie o specjalności Automatyka i Metrologia Elektryczna w Wyższej Szkole Inżynierskiej w Opolu. Stopień naukowy doktora nauk technicznych w dyscyplinie elektrotechnika uzyskał w 2004 r. w Politechnice Opolskiej. W 2016 r. otrzymał stopień doktora habilitowanego w dyscyplinie automatyka i robotyka; główne osiągnięcie naukowe stanowiła monografia „Modeling and Analysis of Linear Hyperbolic Systems of Balance Laws”, wydana w wydawnictwie Springer. Obecnie pracuje w Katedrze Automatyki Politechniki Opolskiej na stanowisku profesora uczelni. Jego zainteresowania naukowe dotyczą głównie modelowania matematycznego układów z czasoprzestrzenną dynamiką, a także zastosowania tzw. metod sztucznej inteligencji w zagadnieniach modelowania oraz sterowania obiektami dynamicznymi.

