

MODELOWANIE ZALEŻNOŚCI W PROCESIE SZLIFOWANIA KŁOWEGO WAŁKÓW Z WYKORZYSTANIEM METODY ANALIZY SKŁADOWYCH GŁÓWNYCH I DRZEW DECYZYJNYCH

Paweł LAJMERT¹, Bogdan KRUSZYŃSKI¹, Dariusz WRĄBEL¹

1. WPROWADZENIE

W procesie szlifowania możliwe jest uzyskanie pożądanych właściwości szlifowanych przedmiotów przez właściwe zaplanowanie przebiegu parametrów kinematycznych szlifowania w kolejnych fazach cyklu szlifowania. W trakcie realizacji samego procesu szlifowania konieczne jest ponadto monitorowanie wybranych cech sygnałów pomiarowych, w celu odpowiednio wczesnej detekcji niepożądanych stanów procesu, aby możliwa była ciągła lub stopniowa korekcja parametrów obróbki w celu utrzymania procesu w optymalnym obszarze szlifowania. Warunkiem wstępnym realizacji tych celów jest poszukiwanie możliwie najmniejszego zbioru cech dostępnych pomiarowo sygnałów, które dobrze charakteryzują proces szlifowania, są wzajemnie nieskorelowane (niezależne), natomiast są silnie skorelowane z jednym lub kilkoma parametrami wynikowymi procesu szlifowania. Zwykle w praktyce okazuje się, że analizowany zbiór cech sygnałów charakteryzuje się dużą wymiarowością. Mówiąc o dużej wymiarowości rozumiemy, że poszczególne grupy danych, np. związane z sygnałem drgań, siły szlifowania czy emisji akustycznej mają dużą liczbę atrybutów. Często okazuje się jednak, że wiele z tych atrybutów jest ze sobą dość mocno powiązanych (skorelowanych) i w związku z czym w celu otrzymania pełnego obrazu opisywanego zjawiska, czy zauważenia pewnych prawidłowości wystarczy uwzględnić jedynie niewielki ich podzbiór. W przypadku gdy liczba potencjalnie użytecznych zmiennych obserwowanych znacznie przekracza liczbę objaśnianych zjawisk, konwencjonalne metody

¹ Instytut Obrabiarek i TBM, Politechnika Łódzka, ul. Stefanowskiego 1/15, 90-924 Łódź

modelowania danych mogą być niewystarczające lub bardzo trudne do zastosowania. W takich przypadkach dużego znaczenia nabierają metody redukcji wymiaru wektora obserwacji do podprzestrzeni o znacznie mniejszym wymiarze, bez utraty informacji zawartej w oryginalnym zbiorze danych. Dzięki temu możliwa jest budowa znacznie prostszych i efektywniejszych modeli objaśnianych zjawisk. Jedną z metod umożliwiających taką redukcję i klasyfikację danych jest metoda analizy składowych głównych (PCA), zaliczana do statystycznych metod eksploracji danych (data mining) [1, 2]. Spośród zadań, które stawia się w zagadnieniach eksploracji danych należy wyróżnić metody zmierzające do redukcji wspomnianej dużej liczby zmiennych oraz metody grupowania danych w zredukowanej przestrzeni. Do pierwszej grupy można zaliczyć np. metodę PCA, a do drugiej metody klasyfikacji hierarchicznej, np. metodę *k*-średnich (*k*-Means Clustering) czy algorytmy drzew decyzyjnych [9]. W artykule przedstawiono zastosowanie nadzorowanej wersji analizy składowych głównych oraz metod indukcji drzew decyzyjnych do identyfikacji niepożądanych stanów procesu szlifowania i przewidywania parametrów wynikowych procesu szlifowania.

2. WARUNKI BADAŃ

Badania procesu szlifowania zostały przeprowadzone na szlifierce kłowej do wałków SWF-25 [5, 8, 10] oraz na zmodernizowanej szlifierce kłowej do wałków Tacchella zaopatrzonej w odpowiednie karty sterujące i pomiarowe. Podczas prób wykorzystywano ściernice ceramiczne 38A80KVBE i 38A60KVBE ($v_s = 40$ m/s). Szlifowane próbki o średnicy około 100mm wykonano ze stali 38HMJ ulepszonej do twardości około 50HRC. Badania zostały przeprowadzone dla różnych obszarów szlifowania związanych z uszkodzeniami cieplnymi przedmiotu obrabianego oraz rozwojem drgań samowzbudnych [8]. Szlifowanie w cyklach prowadzone było aż do całkowitego zużycia ściernicy. W celu scharakteryzowania procesu szlifowania rejestrowano składowe siły szlifowania, drgania przedmiotu, sygnał RMS oraz surowy sygnał emisji akustycznej. Ponadto, rejestrowano błędy zarysu przedmiotu obrabianego z wykorzystaniem specjalnie opracowanego przyrządu do aktywnej kontroli wymiaru i kształtu [5]. Po każdej próbie szlifowania rejestrowano również falistość oraz zarys CPS ściernicy [7]. W celu rejestracji wszystkich sygnałów pomiarowych opracowano specjalne oprogramowanie kontrolno-pomiarowe pracujące pod kontrolą systemu operacyjnego Windows [5].

3. ANALIZA SKŁADOWYCH GŁÓWNYCH

Analiza składowych głównych jest stosunkowo znaną metodą przetwarzania danych, której podstawy teoretyczne zostały opracowane już w pierwszej połowie dwudziestego wieku. Jest ona szczególnie użyteczna do redukcji wektora zmiennych obserwowanych, pozwalając na wyodrębnienie z dużej liczby częściowo skorelowanych ze sobą zmiennych najbardziej istotnych niezależnych składników [2, 6].

W metodzie tej wprowadza się nowy układ niezależnych zmiennych (składowych głównych). Składowe te mają tę właściwość, iż pierwszych kilka składowych zawiera większość informacji o oryginalnym zbiorze danych. W artykule wykorzystano klasyczną wersję tej metody oraz jej nadzorowaną wersję (SPCA), zaproponowaną przez Bair'a [1], pozwalającą na modelowanie zależności pomiędzy zmiennymi obserwowanymi a zmienną objaśnianą z wykorzystaniem równań regresji liniowej. W dalszej części artykułu opisana zostanie metoda przewidywania zmiennej objaśnianej Y na podstawie wektorów obserwacji X_1, X_2, \dots, X_p . Indeks p oznacza obserwowane zmienne. Wymiar wektorów X_p ($p=1, \dots, P$) wynosi N i oznacza liczbę obserwacji dla wszystkich zmiennych. W typowych aplikacjach liczba pomiarów, tzn. zmiennych obserwowanych P może być znacznie większa niż N . W pierwszej kolejności, kolumny macierzy X (zmienne) muszą być wycentrowane, aby ich średnie były równe zero. Następnie wyznacza się wektor s , będący wektorem standardowych współczynników regresji, w celu ustalenia wpływu każdej zmiennej X_p na zmienną objaśnianą y . Następnie wyznacza się podmacierz X_θ macierzy X , której j -te kolumny spełniają warunek $|s_j| > \theta$, przy czym współczynnik θ ustala się doświadczalnie. Macierz X_θ rozkłada się następnie na iloczyn trzech specyficznych macierzy z wykorzystaniem algorytmu SVD rozkładu macierzy na wartości szczególne (singular value decomposition) [2]. Macierz X_θ może być przedstawiona następująco:

$$\mathbf{X}_\theta = \mathbf{U}_\theta \mathbf{D}_\theta \mathbf{V}_\theta^T \quad (1)$$


We wzorze 1 macierz \mathbf{U}_θ jest macierzą ortogonalną, której kolumny są składowymi głównymi macierzy \mathbf{X}_θ . Macierz \mathbf{U}_θ zawiera współrzędne poszczególnych obserwacji w nowej przestrzeni tzw. głównych składowych. Macierz \mathbf{D}_θ jest macierzą wartości własnych σ_m (szczególnych) uporządkowanych tak, że $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_M$ ($M = \min(N, P)$) będących miarą zmienności poszczególnych zmiennych. Natomiast macierz \mathbf{V}_θ jest macierzą ortogonalną o wymiarze $[M \times P]$ przekształcającą wektor obserwacji $X_{observed}$ do zredukowanej przestrzeni PC_θ , nazywanej przestrzenią składowych głównych o wymiarze P :

$$\mathbf{PC}_\theta = \mathbf{X}_{observed} \mathbf{V}_\theta^T = [\mathbf{PC}_1, \mathbf{PC}_2, \dots, \mathbf{PC}_P] \quad (2)$$

Należy tutaj zaznaczyć, że do opisu wszystkich P obserwowanych zmiennych wystarczy $k \ll P$ składowych głównych PC . Zwykle pierwszych kilka składowych głównych zawiera większość informacji zawartej w oryginalnym zbiorze danych, co jest oczywiście założeniem analizy PCA. Omówioną metodę redukcji wektora obserwacji zastosowano do ustalenia najbardziej istotnych obserwowanych zmiennych. Można tego dokonać przez analizę wartości macierzy \mathbf{V}_θ . Duże wartości $v_{m,p}$ w tej macierzy oznaczają dużą wagę p -tej zmiennej obserwowanej dla m -tej składowej głównej PC .

4. ZASTOSOWANE METODY ANALIZY SYGNAŁÓW

Do analizy sygnałów drgań, emisji akustycznej oraz składowych siły szlifowania wykorzystano dwie metody przetwarzania sygnałów, tj. szybką transformatę Fouriera FFT oraz transformatę Hilberta-Huanga HHT [3, 6]. W przypadku transformaty FFT wynikiem przetwarzania jest widmo mocy lub amplitudy sygnału, w którym najbardziej istotne składowe sygnału występują w postaci impulsów. Zwykle podczas analizy widma parametry amplitudowe wyznacza się poprzez zsumowanie amplitud dla określonego pasma częstotliwości lub znalezienie maksymalnej wartości amplitudy w tym paśmie. W pierwszym przypadku rozwiązanie daje jednak wyniki zanizone, tj. uśrednione, a w drugim niejednoznaczne, często obarczone dużą zmiennością. W celu pokonania tych problemów opracowano algorytm do identyfikacji lokalnych wartości maksymalnych (szczytów impulsów) będących najistotniejszymi składowymi częstotliwościowymi sygnału. Wyznaczone szczyty impulsów sumowano dla wybranego pasma częstotliwości analizowanego widma. Parametry te oznaczono ΣA . Algorytm ten został również wykorzystany do identyfikacji krótkotrwałych skoków amplitudy sygnału emisji akustycznej wysokoczęstotliwościowych składowych transformaty HHT, które mogą być skorelowane z procesami wykruszenia się ściernicy lub przypaleniami przedmiotu [6]. Przykładowe wyniki dla sygnału drgań przedstawiono na rys. 1.



Rys. 1. Zidentyfikowane lokalne szczyty dla widma FFT mocy przykładowego sygnału drgań

Z wykorzystaniem omówionych metod analizy sygnałów wyznaczono cechy statystyczne sygnałów drgań, wartości skutecznej EA i surowego sygnału EA. Dla składowych sił szlifowania wyznaczono zdolność skrawną ściernicy dla składowej stycznej K_{zt} i normalnej K_{zn} oraz stosunek składowej stycznej do składowej normalnej μ . Ponadto dla sygnału RMS EA wyznaczono energie tych sygnałów $E_{RMS EA}$ oraz iloczyn mocy i częstotliwości $EF_{RMS EA}$ dla najistotniejszych składowych widma FFT oraz składowych częstotliwościowych transformaty HHT. Następnie z wykorzystaniem analizy SPCA wyznaczono najistotniejsze cechy sygnałów drgań i emisji akustycznej z punktu widzenia identyfikacji parametrów wynikowych procesu szlifowania, tj. chropowatości, błędów kształtu i falistości przedmiotu oraz stanu narzędzia, tj. falistości ściernicy i mikrogeometrii CPS. Przykładowe cechy staty-

styczne składowych HHT sygnału drgań oraz ich względną istotność dla pierwszych dwóch składowych głównych PC przedstawiono w tabeli 1. Jak widać duży zbiór cech statystycznych został zredukowany do tylko kilku wzajemnie nieskorelowanych cech.

Tabela 1. Wyselekcjonowane cechy sygnału drgań i ich względna istotność

Cechy składowych IMF sygnału drgań	Czwarta składowa IMF ₄ sygnału drgań		Piąta składowa IMF ₅ sygnału drgań	
	PC ₁	PC ₂	PC ₁	PC ₂
Wart. maksymalna amplitudy IMF	● 0.35	0.03	● 0.37	● -0.28
Wart. średnia amplitudy IMF	● 0.32	● 0.39	● 0.39	● -0.29
Wart. średnia chwilowej częstotliwości IMF	● -0.12	● -0.61	● -0.11	● -0.52
Odchylenie standardowe IMF	● 0.32	0.07	● 0.37	● -0.17
Odchylenie standardowe amplitudy IMF	● 0.33	-0.08	● 0.34	0.05

5. KLASYFIKACJA Z UŻYCIEM DRZEW DECYZYJNYCH

W celu klasyfikacji hierarchicznej w dziedzinie składowych głównych lub zredukowanego zbioru cech statystycznych analizowanych sygnałów można zastosować wiele algorytmów grupowania (klasyfikacji) danych. W przypadku drzew decyzyjnych klasyfikacja jest wykonywana poprzez rekursywne partycjonowanie danych na kategorie w kolejnych węzłach drzewa decyzyjnego. W każdym węźle drzewa pozostałe zmienne, z największą redukcją entropii lub najwyższym współczynnikiem informacji są wybierane i stosowane do kategoryzacji danych jako następny stopień partycjonowania w kolejnym węźle drzewa decyzyjnego. W ostatnim węźle następuje przyporządkowanie danych do jednej z kilku kategorii danych, które w przypadku procesu szlifowania odpowiadają różnym stanom procesu (wykruszanie, zalepianie ściernicy) lub parametrom wynikowym szlifowania. W przedstawionej pracy zastosowano jednak metodę hybrydową, zaproponowaną przez Quinlan'a [9], polegającą na połączeniu algorytmów drzew decyzyjnych z metodami liniowej regresji danych. W metodzie tej w ostatnim węźle drzewa wyznacza się równania liniowej regresji względem zmiennych partycjonowanych w danej gałęzi drzewa. Z zastosowaniem tego algorytmu wyznaczono równania regresji liniowej do estymacji wybranych parametrów wynikowych procesu szlifowania, tj. falistości i błędów kształtu szlifowanego przedmiotu, jego chropowatości, falistości ściernicy oraz zużycia ściernicy reprezentowanego przez wskaźnik zredukowanej wysokości wzniesień udziału nośnego CPS ściernicy. Reguły

diagnostyczne generowano dla różnych grup danych, obejmujących parametry kinematyczne szlifowania, parametry siły szlifowania oraz wyselekcjonowane z użyciem metody SPCA cechy sygnału drgań i emisji akustycznej. Poniżej przedstawiono wygenerowane reguły i wynikowe modele regresji dla błędów kształtu przedmiotu obrabianego A_{1-9} (zakres od 1 do 9 fal na obwodzie przedmiotu).

REGUŁA 1: JEŻELI v_w JEST ŚREDNIA LUB DUŻA TO

$$A_{1-9} = -1.1 + 0.91 Q'_w - 0.33 v_w + 4.3 K_{zt} - 0.039 \Sigma A_{RMS EA(10-250Hz)} - 0.28 \Sigma A_{RMS EA(120-250Hz)} + 0.15 E_{IMF3 RMS EA} + 0.3 EF_{IMF1 RMS EA}$$

REGUŁA 2: JEŻELI v_w JEST MAŁA TO

$$A_{1-9} = 4.493 + 0.43 Q'_w - 0.91 v_w - 0.11 \Sigma A_{RMS EA(10-250Hz)} + 0.4 E_{IMF3 RMS EA} + 0.82 EF_{IMF1 RMS EA}$$

Z przedstawionych reguł wynika, że podstawowymi parametrami decydującymi o błędach kształtu obrabianego przedmiotu, są wydajność obróbki i prędkość obwodowa przedmiotu, z której wzrostem maleją błędy kształtu. Ponadto, na wynikowe błędy kształtu przedmiotu mają wpływ zdolność skrawna ściernicy K_{zt} oraz wybrane cechy sygnału RMS emisji akustycznej. W celu zmniejszenia błędów kształtu przedmiotu należy zatem stosować odpowiednio wysokie prędkości obwodowe przedmiotu oraz monitorować wybrane cechy sygnału RMS emisji akustycznej, w szczególności parametry energetyczne składowych HHT sygnału RMS EA.

Dla falistości przedmiotu (zakres od 20 do 500 fal na obwodzie przedmiotu) reguły diagnostyczne zostały wygenerowane z użyciem wszystkich grup danych obejmujących parametry kinematyczne, parametry siły szlifowania, cechy sygnału drgań i emisji akustycznej. Wyznaczono następujące reguły:

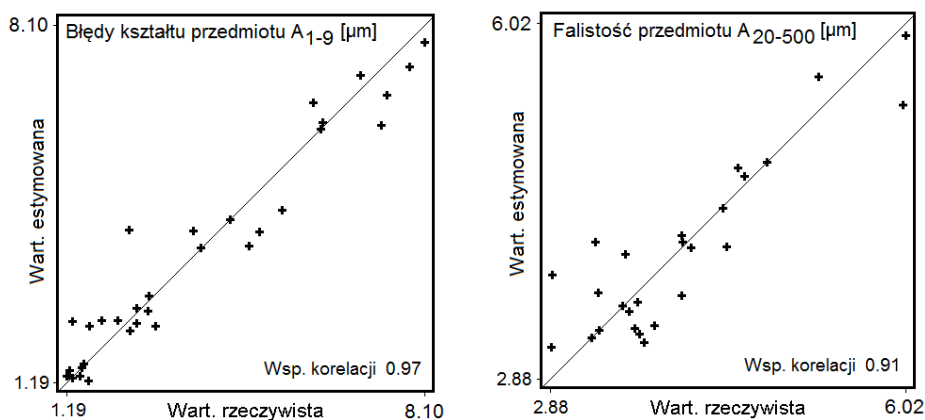
REGUŁA 1: JEŻELI ($\Sigma A_{VIB(600-1100Hz)} \leq 55$) TO

$$A_{20-500} = 6.45 - 0.52 Q'_w - 0.0026 v_w - 0.055 \Sigma A_{RMS EA(10-250Hz)} - 0.12 \Sigma A_{VIB(600-1100Hz)}$$

REGUŁA 2: JEŻELI ($\Sigma A_{VIB(600-1100Hz)} > 55$) TO

$$A_{20-500} = 1.84 + 0.0025 v_w + 0.33 \Sigma A_{VIB(600-1100Hz)} + 0.001 \Sigma A_{VIB(1100-2000Hz)}$$

Na rysunku 2 przedstawiono rozkład rzeczywistych i estymowanych wartości błędów kształtu i falistości powierzchni obrabianego przedmiotu.



Rys. 2. Rozkład rzeczywistych i estymowanych wartości dla:
a) błędów kształtu A_{1-9} i b) falistości przedmiotu A_{20-500}

Omawiany algorytm zastosowano również do określenia zależności pomiędzy wybranymi cechami sygnału drgań i parametrami obróbki a wynikową falistością ściernicy. W tym przypadku wygenerowana została tylko jedna reguła (współczynnik korelacji 0.9):

REGUŁA 1: $A_{\text{fal,CPS}} = 1.25 + 0.0215 * \Sigma A_{\text{vib,FFT}(1100-2000\text{Hz})} + 0.0042 v_w$

Wynika z niej, iż pomiędzy amplitudą falistości ściernicy a sumą szczytów składowych widma FFT sygnału drgań w oknie o średniej częstotliwości 1600Hz istnieje liniowa zależność dla całego zakresu stosowanych podczas prób parametrów kinematycznych szlifowania. W przypadku identyfikacji uszkodzeń cieplnych przedmiotu otrzymano tylko jedną regułę:

REGUŁA 1: JEŻELI ($E_{\text{HHTI,RMS-EA}} > 3.4$) **TO PRZYPALENIA**

Z użyciem powyższej reguły wyjaśniono wszystkie przypadki w zbiorze uczącym i testowym. Należy zaznaczyć, że poprzez usuwanie ze zbioru uczącego aktualnie wybranych, najbardziej istotnych zmiennych można wyznaczać kolejne coraz mniej istotne reguły klasyfikacyjne, aż do momentu gdy w zbiorze uczącym zabraknie zmiennych odpowiednich do rozróżnienia identyfikowanych kategorii.

Omawiany algorytm zastosowano również do estymacji chropowatości przedmiotu oraz parametrów udziału nośnego mikrogeometrii CPS ściernicy [7]. Przykładowe reguły opisujące zmiany zredukowanej wysokości wzniesień przedstawiają się następująco (współczynnik korelacji 0.77):

REGUŁA 1: JEŻELI ($\mu > 0.46$) **TO**

$$R_{\text{pk}} = -32.8 + 76.4 K_{\text{zt}} - 148.2 K_{\text{zn}} + 73.1 \mu + 0.06 \Sigma A_{\text{RMS EA}(10-250\text{Hz})} + 0.3 \text{RMS}_{\text{EA}}$$

REGUŁA 2: JEŻELI ($\mu \leq 0.46$) TO

$$R_{pk} = -28.4 + 16.8 K_{zt} - 12.5 K_{zn} + 76.2 \mu + 0.002 \Sigma A_{RMS EA(10-250Hz)} + 0.03 RMS_{EA}$$

Z analizy powyższych złożonych zależności wynika, że wraz ze wzrostem zredukowanej wysokości wzniesień maleje składowa normalna siły szlifowania, co wydaje się być racjonalne, gdyż wtedy przeważają procesy samoostrzenia ściernicy. Ponadto wzrostowi zredukowanej wysokości wzniesień towarzyszy wzrost poziomu widma mocy sygnału RMS EA w zakresie od 10 do 250 Hz.

6. PODSUMOWANIE

Przedstawione w artykule metody analizy danych pozwalają na redukcję oryginalnego zbioru zmiennych obserwowanych do minimalnego zbioru wzajemnie nieskorelowanych zmiennych oraz na objaśnienie zależności pomiędzy parametrami kinematycznymi szlifowania, wybranymi cechami sygnałów pomiarowych a wynikami szlifowania lub niepożądanymi stanami procesu szlifowania. Dalsze prace koncentrować się będą na wykorzystaniu nieliniowych metod analizy składowych głównych do modelowania zależności w procesie szlifowania kłowego wałków.

LITERATURA

- [1] BAIR E., HASTIE T., PAUL D., TIBSHIRANI R., *Prediction by Supervised Principal Components*, Journal of the American Statistical Association, Vol. 101/473, 2006, 119–137.
- [2] JOLLIFFE, I.T., *Principal Component Analysis*, Springer Verlag, New York, 2002.
- [3] HUANG N., et al., *The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Nonstationary Time Series Analysis*. Proc. Roy. Soc. Lond., 1998.
- [4] KRUSZYŃSKI B., LAJMERT P., *An intelligent Supervision System for Cylindrical Traverse Grinding*. Annals of the CIRP, 54/1/2005.
- [5] LAJMERT P., *Wykorzystanie metod sztucznej inteligencji do sterowania i optymalizacji procesu szlifowania wzdłużnego wałków*, Praca doktorska-Politechnika Łódzka, Promotor Prof. Bogdan Kruszyński, 2003.
- [6] LAJMERT P., KRUSZYŃSKI B., *A Diagnostic System for Cylindrical Plunge Grinding Process based on Hilbert-Huang Transform and Principal Component Analysis*, Proceedings of the 5th International Conference on Advances in Production Engineering, Warszawa 2010, 117–126.
- [7] LEŻAŃSKI P., LAJMERT P., *Zastosowanie parametrów krzywej udziału materiałowego do oceny zużycia ściernicy*, Zeszyty Naukowe Wydz. Mechanicznego Politechniki Koszalińskiej Nr 36, XXVII Naukowa Szkoła Obróbki Ściernej, Sarbinowo 2004, 275–282.
- [8] LEŻAŃSKI P., LAJMERT P. i inni, *Hybrydowy system sztucznej inteligencji do optymalizacji warunków szlifowania kłowego wałków*, Projekt badawczy KBN - sprawozdanie, 2006.
- [9] QUINLAN R., *Induction of Decision Trees*, Machine Learning, Kluwer Academic Publishers, Hingham (MA), 2003, Vol. 1, 81–106.
- [10] WRĄBEL D., TEODORCZYK J., LAJMERT P. i inni, *Sterowany numerycznie napęd ruchów posuwowych w szlifierkach*, Projekt celowy KBN – sprawozdanie, 2000.