

ZASTOSOWANIE METOD EKSPLOKACJI DANYCH DO NADZOROWANIA PROCESU SZLIFOWANIA KŁOWEGO WAŁKÓW

Paweł LAJMERT¹, Bogdan KRUSZYŃSKI²

Streszczenie: W pracy przedstawiono przegląd metod eksploracji danych w zastosowaniu do diagnostyki i optymalizacji procesu szlifowania kłowego wałków. Omówiono metody analizy sygnałów w dziedzinie czasu i częstotliwości w celu wyznaczenia różnych miar rejestrowanych sygnałów. Przeanalizowano różne metody wydobywania wiedzy w celu selekcji najbardziej istotnych miar z punktu widzenia identyfikacji niepożądanego stanu procesu i estymacji parametrów wynikowych procesu szlifowania.

Słowa kluczowe: szlifowanie, czynna powierzchnia ściernicy

Summary: This paper presents an overview of data mining methods in application to diagnostics and optimization of the cylindrical plunge grinding process. Time-frequency signal analysis methods are described to extract different features of measured signals. Different knowledge extraction methods are presented in order to determine the most important features for the purpose of estimation of grinding process state and part quality parameters.

Key words: grinding, grinding wheel topography

1. WSTĘP

Efektywny nadzór dowolnego procesu obróbczego wymaga analizy wielu sygnałów pomiarowych, w których zawarta jest informacja o stanie procesu i narzędzia. Sygnały te pochodzą z wielu czujników mierzących różne wielkości fizyczne towarzyszące procesowi szlifowania, takie jak moc szlifowania, siły szlifowania, drgania czy emisja akustyczna [3, 10, 13, 15, 19, 23]. W wyniku odpowiedniego przetwarzania tych sygnałów w dziedzinie czasu, częstotliwości lub czasu i częstotliwości możliwe jest uzyskanie dużej ilości miar, z których tylko część jest powiązana z analizowanym zjawiskiem. Ponadto wiele z tych miar może być skorelowanych z innymi miarami, prowadząc do nadmiarowości informacji zawartej w analizowanym zbiorze danych. Z tego powodu warunkiem wstępnym skutecznego nadzoru procesu szlifowania jest znalezienie wzajemnie niezależnych podgrup miar w analizowanym zbiorze danych, o wymiarze niekoniecznie minimalnym, które byłyby dobrze skorelowane z niepożądanymi stanami procesu szlifowania, stanem narzędzia, czy też parametrami wynikowymi procesu szlifowania [15, 16, 18, 23]. Dzięki właściwie wybranym miarom i zastosowaniu odpowiednich technik modelowania danych, układy sterujące obrabiarki mogą prawidłowo sklasyfikować stan procesu w celu podjęcia odpowiednich działań korygujących jego przebieg lub podjęcia decyzji o kondycjonowaniu ściernicy. Zadaniem wydobywania i ekstrakcji takich danych oraz pozyskiwania z nich wiedzy zajmują się szeroko rozumiane

¹ Politechnika Łódzka, Instytut Obrabiarek i TBM, ul. Stefanowskiego 1/15, 90-924 Łódź,
plajmert@p.lodz.pl,

² bogdan.kruszynski@p.lodz.pl


metody eksploracji danych (ang. *Data Mining*) [14], obejmujące analizę szeregów czasowych, selekcję istotnych zmiennych w zbiorach danych oraz metody analizy danych. W artykule przedstawiono przegląd metod eksploracji danych, z uwzględnieniem metod analizy sygnałów, w zastosowaniu do nadzoru procesów szlifowania.

2. METODY EKSTRAKЦИИ MIAR SYGNAŁÓW

Rejestrowane sygnały we współczesnych systemach akwizycji danych przyjmują postać dyskretnych szeregów czasowych i wymagają ich dalszego przetwarzania w celu wydobycia informacji powiązanej z analizowanym zjawiskiem. W procesie szlifowania analizie podlegać mogą między innymi zjawiska związane ze zużyciem się narzędzia, powstawaniem drgań samowzbudnych, czy też z wpływem warunków obróbki na parametry wynikowe procesu szlifowania. Analizowane sygnały (siła, moc szlifowania, drgania, emisja akustyczna (AE), itp.) zawierają ważne informacje w dziedzinie czasu, częstotliwości, jak również czasu i częstotliwości.

2.1. ANALIZA W DZIEDZINIE CZASU

W przypadku przetwarzania w dziedzinie czasu wyznaczanie miar może odbywać się na podstawie miar statystycznych sygnałów, takich jak wartość średnia, wartość skuteczna, odchylenie standardowe, kurtoza, skośność, itp.. Tak wyznaczone miary sygnałów, choć częściowo skorelowane z analizowanym zjawiskiem, mogą jednak zawierać informację pochodzącą z wielu innych zjawisk, występujących w różnych zakresach częstotliwościowych analizowanych sygnałów. W nadzorze procesów szlifowania praktyczne zastosowanie znalazło monitorowanie amplitudy sygnału drgań (kontrola niewyważenia ściernicy) oraz monitorowanie wartości skutecznej sygnału AE. Ponadto monitorowaniu podlegać mogą wybrane miary tego sygnału, np. skośność czy kurtoza [15, 22]. Miary te są wykorzystywane do diagnostyki stanu narzędzia ściernego [4, 10], identyfikacji przypaleń przedmiotu, czy też do estymacji naprężeń własnych w warstwie wierzchniej szlifowanych przedmiotów [22, 23]. Na rys. 1 przedstawiono wybrane przebiegi wartości skutecznej sygnału AE dla pracy w strefie uszkodzeń cieplnych przedmiotu i w optymalnym obszarze szlifowania.



Rys. 1. Zmiany wartości skutecznej sygnału emisji akustycznej podczas szlifowania: a) w strefie uszkodzeń cieplnych przedmiotu ($Q'_w=1.9 \text{ mm}^3/\text{mm s}$, $v_w=0.1 \text{ m/s}$); b) w zakresie optymalnych warunków szlifowania ($Q'_w=1.9 \text{ mm}^3/\text{mm s}$, $v_w=0.6 \text{ m/s}$).

Widać, iż zarówno wartość skuteczna jak i wariancja tego sygnału znacząco wzrasta dla pracy w strefie uszkodzeń cieplnych przedmiotu.

Innymi metodami przetwarzania sygnałów w dziedzinie czasu są metody analizy składowych głównych PCA (ang. *Principal Component Analysis*) [12] i składowych niezależnych ICA (ang. *Independent Component Analysis*) [11]. W przypadku metody PCA, jak i nowo opracowanej metody ICA celem jest znalezienie liniowej reprezentacji oryginalnego sygnału, tak aby wyznaczone składowe sygnału były ze sobą nieskorelowane, albo w przypadku metody ICA dodatkowo statystycznie niezależne. Pozwala to na uchwycenie zasadniczej struktury sygnału i jego dekompozycję na niezależne składowe pochodzące z różnych źródeł informacji w analizowanym procesie. Reprezentatywnym, częstym zastosowaniem tej metody jest separacja dźwięków "na ślepo" pochodzących z różnych źródeł w nagraniach audio (ang. *Blind source separation*) [11].

2.2. ANALIZA W DZIEDZINIE CZĘSTOTLIWOŚCI ORAZ CZASU I CZĘSTOTLIWOŚCI

W diagnostyce procesu szlifowania podstawową metodą analizy sygnałów w dziedzinie częstotliwości jest szybka transformata Fouriera (FFT) [3, 7, 10, 23]. Wykorzystuje ona jako podstawę sinusoidalne funkcje okresowe, reprezentujące jedną częstotliwość. Powoduje to utratę informacji o czasie wystąpienia poszczególnych zdarzeń częstotliwościowych. Ponadto wartości amplitudy sygnału w dziedzinie częstotliwości są uśrednione, przez co występujące w sygnale krótkotrwałe zdarzenia, związane np. z wykruszaniem się ściernicy, mogą być niewidoczne w widmie FFT.

Aby pokonać tą wadę stosuje się krótko czasową transformatę Fouriera STFT (ang. *Short Time Fourier Transform*), w której wykonuje się transformatę Fouriera na sygnale okienkowanym w ramach analizowanego ciągu czasowego, przy czym okno jest przesuwane monotonicznie w czasie, przez co możliwe jest wychwycenie krótkotrwałych zmian widma sygnału w kolejnych chwilach czasu. O czułości tej metody decyduje głównie szerokość okna. Metoda ta ma jednak stałą rozdzielczość w dziedzinie czasu.


Metodą wolną od tej wady jest dyskretna DWT, bądź ciągła transformata falkowa CWT (ang. *Discrete and Continuous Wavelet Transform*). W metodach tych szerokość okien maleje wraz ze wzrostem analizowanych częstotliwości, przez co charakteryzują się one większą czułością niż transformata STFT. Obie metody są głównie wykorzystywane do analizy sygnałów niestacjonarnych, takich jak sygnał drgań oraz sygnał emisji akustycznej. Główny obszar zastosowania transformat STFT i DWT obejmuje analizę sygnału AE w celu identyfikacji przypaleń przedmiotu obrabianego, naprężeń własnych w warstwie wierzchniej przedmiotu, czy też identyfikacji zużycia narzędzia ściernego [3, 4, 17].

Kolejną metodą przetwarzania sygnałów w dziedzinie czasu i częstotliwości

stosowaną w diagnostyce procesu szlifowania, pozwalającą ponadto analizować sygnały nieliniowe, jest transformata Hilberta-Huanga HHT (ang. *Hilbert-Huang Transform*) [9]. Metoda ta pozwala analizować sygnały, które mogą się zmieniać nawet w ramach jednego okresu oscylacji sygnału. Wykorzystuje ona dwie techniki przetwarzania sygnałów:

- empiryczną dekompozycję sygnału na nieliniowe składowe modalne (ang. *Empirical mode decomposition*), przy czym w przeciwieństwie do typowych składowych harmonicznych funkcje te mogą posiadać zmienną amplitudę oraz częstotliwość w dziedzinie czasu,
- transformatę Hilberta, która wyznacza zmiany amplitudy i częstotliwości poszczególnych składowych modalnych w czasie.

Na rysunku 2 przedstawiono przykład zastosowania tej metody do rozkładu surowego sygnału AE na składowe modalne w celu identyfikacji symptomów uszkodzeń cieplnych przedmiotu. W przypadku pracy przy zbyt małych prędkościach obrotowych przedmiotu (rysunek 2c) widoczna jest duża liczba impulsów w pierwszej składowej modalnej świadcząca o uszkodzeniach cieplnych przedmiotu lub wykruszaniu się ściernicy z powodu zbyt dużego obciążenia cieplnego struktury ściernicy [15].



Rys. 2. Przykładowe spectrum HHT surowego sygnału AE a) oraz zmiany amplitudy pierwszej składowej modalnej sygnału AE dla: b) pracy w optymalnej strefie szlifowania; c) pracy w strefie uszkodzeń cieplnych przedmiotu ($v_w \approx 0.14$ m/s).

Inną, obiecującą metodą analizy sygnałów niestacjonarnych jest metoda dekompozycji sygnału z wykorzystaniem transformaty Hilberta HVD (ang. *Hilbert Vibration Decomposition*) [6]. Ta stosunkowo nowa metoda została opracowana w szczególności do analizy niestacjonarnych, szerokopasmowych sygnałów wibroakustycznych.

3. METODY EKSPLOKACJI DANYCH

W modelowaniu procesu szlifowania wykorzystywanych może być wiele technik modelowania danych, obejmujących metody statystyczne oraz metody z zakresu sztucznej inteligencji. Do pierwszych zaliczyć można metody regresji wielokrotnej, liniowej i nieliniowej [19], metody analizy korelacji, czy też metody analizy dyskryminacyjnej i czynnikowej [15]. Do drugiej grupy metod zaliczyć można sieci neuronowe [23], metody logiki rozmytej, metody indukcji drzew decyzyjnych [16], czy też metody zbiorów przybliżonych [2].

Jednakże w procesie szlifowania liczba miar (tzw. zmiennych wejściowych) wyznaczonych z różnych sygnałów może być bardzo duża. Powszechnie wiadomo, że indukcja modeli analizowanych zjawisk z użyciem danych zawierających dużą liczbę, często skorelowanych ze sobą zmiennych wejściowych, nie gwarantuje uzyskania najwłaściwszych modeli, czyli modeli cechujących się wysokim stopniem uogólnienia [14]. Wynika to z tego, iż tylko część z tych miar jest skorelowana z analizowanym zjawiskiem, a ponadto wiele z analizowanych miar może być ze sobą skorelowana.

Jednym z etapów pozyskiwania wiedzy z analizowanych danych jest zatem etap selekcji zmiennych wejściowych, bądź transformacji zmiennych wejściowych do nowej podprzestrzeni o zredukowanym wymiarze, w której zmienne są wzajemnie niezależne. Ogólny podział metod selekcji i transformacji danych przedstawiono na rysunku 3 [5].

	Nadzorowane	Nienadzorowane
Transformacja	LDA SPCA	PCA K-PCA
Selekcja	Drzewa decyzyjne CFS Filtracja cech Z wykorzystaniem alg. indukcji wiedzy	NMF

Rys. 3. Metody selekcji i transformacji danych.

W przypadku metod selekcji zmiennych jednym z podejść może być metoda nazywana filtracją cech, bazująca na zastosowaniu pewnych miar (takich jak korelacja, entropia informacji, itp.), które dają statystyczną informację o istotności zależności występującej pomiędzy zmienną wyjściową a podzbiorem zmiennych wejściowych modelu, wybranym za pomocą algorytmu przeszukiwania [5, 14].

Inne podejście, znane jako selekcja z wykorzystaniem algorytmu indukcji wiedzy charakteryzuje się tym, że w procesie selekcji do oceny wybranego podzbioru

zmiennych wejściowych wykorzystywany jest algorytm indukcji wiedzy, np. algorytm sieci neuronowych, czy też algorytm wektorów wspomagających [14, 18]. Ocena aktualnie analizowanego podzbioru zmiennych wejściowych jest realizowana poprzez wyznaczenie wskaźników oceny jakości działania modelu. Metoda ta została wykorzystana w pracy [18] do selekcji najbardziej istotnych miar sygnału emisji akustycznej w celu identyfikacji stanu ściernicy.

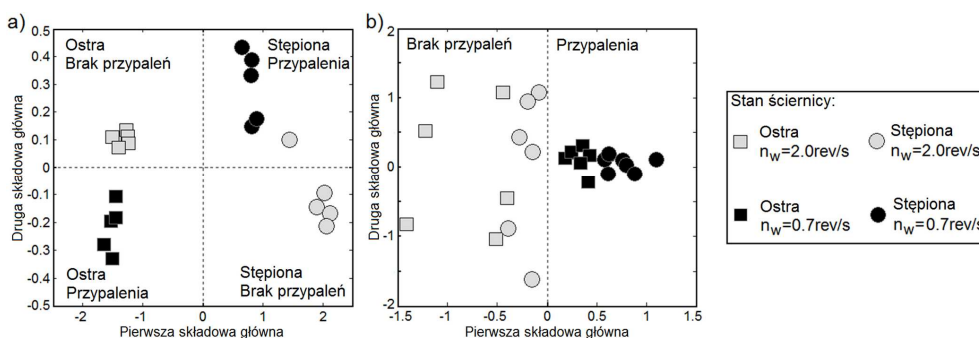
Kolejną metodą selekcji cech jest metoda wykorzystująca korelacje CFS (ang. *Correlation based Feature Selection*) [8]. Metoda wykorzystuje pewne miary, które dają statystyczną informację o istotności zależności pomiędzy zmiennymi wyjściowymi a podzbiorem zmiennych wejściowych wykorzystując funkcję heurystyczną opartą na pewnych miarach korelacyjnych [8, 14]. W omówionych metodach selekcja podzbiorów zmiennych wejściowych odbywa się najczęściej z wykorzystaniem algorytmów genetycznych, co czyni te metody niepraktycznymi z punktu widzenia budowy automatycznych systemów nadzoru procesu szlifowania.

Zupełnie inną metodą jest metoda selekcji zmiennych wejściowych z wykorzystaniem algorytmów drzew decyzyjnych [20]. W metodzie tej selekcja zmiennych wejściowych odbywa się na podstawie redukcji entropii, w celu ustalenia najbardziej znaczącego atrybutu w kolejnych węzłach drzewa (ze względu na test klasyfikacji) oraz na podstawie współczynnika informacji dla kolejnych partycjonowanych zmiennych [5, 16, 20]. Do metod nienadzorowanych selekcji zmiennych zaliczyć można metody klasteryzacji zmiennych wejściowych, np. metodę faktoryzacji nieujemnej macierzy (ang. *Non-negative matrix factorization*) [5].

W przypadku bardzo dużej liczby analizowanych zmiennych znacznie lepszym rozwiązaniem jest zastosowanie metod transformacji zmiennych wejściowych do nowej podprzestrzeni o zredukowanym wymiarze. Podstawowym algorytmem jest tutaj, wspomniana już, metoda analizy składowych głównych PCA, dokonująca liniowej transformacji zmiennych wejściowych do nowej przestrzeni o znacznie mniejszym wymiarze, nazywanej przestrzenią składowych głównych. Celem PCA jest taki obrót układu współrzędnych, aby maksymalizować w pierwszej kolejności wariancję pierwszej współrzędnej, następnie wariancję drugiej współrzędnej, itd. [12]. Istnieją również nadzorowane wersje tej metody SPCA (ang. *Supervised PCA*) wykorzystujące informację o przynależności danego wektora zmiennych wejściowych do poszczególnych rozróżnianych klas (stanów obiektu) [1, 16].

Inną powiązaną metodą, umożliwiającą nadzorowaną redukcję oryginalnego zbioru zmiennych wejściowych jest liniowa analiza dyskryminacyjna LDA (ang. *Linear discriminant analysis*) [5]. Metoda ta jest używana do znalezienia liniowej kombinacji cech, które najlepiej rozróżniają dwie lub więcej rozróżnianych klas (stanów obiektu). Użycie obu metod, tj. metody PCA i LDA wymaga, aby dane były liniowo separowalne. Jednakże metody te można zmienić w metody nieliniowe poprzez transformacje danych wejściowych do przestrzeni o większej liczbie wymiarów z wykorzystaniem tzw. "triku kernelowego" [21]. W nowej

zlinearyzowanej przestrzeni dokonuje się następnie redukcji wymiaru z wykorzystaniem metody PCA lub LDA. Na rysunku 4 przedstawiono wykresy rozkładu wyników klasyfikacji stanu procesu na podstawie pierwszych dwóch składowych głównych dla miar sygnału drgań oraz miar surowego sygnału emisji akustycznej. Jak można zauważyć prawie wszystkie przypadki zostały prawidłowo odseparowane i rozpoznane.



Rys. 4. Przykładowy rozkład analizowanych danych w dziedzinie pierwszych dwóch składowych głównych dla: a) zbioru miar sygnału drgań; b) zbioru miar surowego sygnału AE [15].

4. PODSUMOWANIE

W artykule porównano wybrane metody przetwarzania sygnałów i eksploracji danych w celu ekstrakcji i selekcji najbardziej istotnych miar z punktu widzenia diagnostyki procesu szlifowania. Z powodu bardzo dużej liczby miar analizowanych sygnałów, sięgającej nawet kilkuset, najkorzystniejszym podejściem do diagnostyki procesu szlifowania wydaje się być zastosowanie metod hybrydowych, łączących metody transformacji zbioru miar do nowej zredukowanej podprzestrzeni z metodami klasyfikacji i modelowania danych, takimi jak metody regresji, drzew decyzyjnych [16], czy sieci neuronowych. Zastosowanie takiego podejścia umożliwi budowę automatycznych systemów selekcji najbardziej istotnych miar sygnałów oraz efektywny nadzór procesu szlifowania.

Badania realizowane w ramach Projektu "Nowoczesne technologie materiałowe stosowane w przemyśle lotniczym", Nr POIG.01.01.02-00-015/08-00 w Programie Operacyjnym Innowacyjna Gospodarka (POIG). Projekt współfinansowany przez Unię Europejską ze środków Europejskiego Funduszu Rozwoju Regionalnego.

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] BI J., HE P., HE X., WANG H., *Research for on-line diagnostic system for intelligent roll*

- grinding*. IEEE Control and Decision Conference, 2008, 5248-5252.
- [3] CHEN X., GRIFFIN J., *Grinding acoustic emission classification in terms of mechanical behaviours*. Key Engineering Materials, Vol. 329, 2007, 15-20.
- [4] CHEN X., LIMCHIMCHOL T., *Monitoring grinding wheel redress-life using support vector machines*, International Journal of Automation and Computing, Vol. 1, 2006, 56-62.
- [5] CUNNINGHAM P., *Dimension reduction*. Tech. report: UCD-CSI-2007-7, 2007.
- [6] FELDMAN M., *Time-Varying Vibration Decomposition and Analysis Based on the Hilbert Transform*. Journal of Sound and Vibration. 2006, Vol 295/3-5 pp. 518-530.
- [7] GRIFFIN J., CHEN X., *Characteristics of the acoustic emission during horizontal single grit scratch tests: Part 2 classification and grinding tests*. Int. Journal of Abrasive Technology, Vol. 2/1, 2009, 43-59.
- [8] HALL M., *Correlation-based feature selection for machine learning*. Phd thesis, Department of Computer Science, Waikato University, Hamilton.
- [9] HUANG N., et al., *The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis*. Proc. Roy. Soc. Lond., 1998.
- [10] HUNDT W., LEUENBERGER D., REHSTEINER F., GYGAX P., *An approach to monitoring of the grinding process using acoustic emission (AE) technique*. Annals of the CIRP, Vol. 43/1, 1994, 295-298.
- [11] HYVÄRINEN A., OJA E., *Independent component analysis: algorithms and applications*. Neural Networks, Vol. 13, 2000, 411-430.
- [12] JOLLIFFE, I.T., *Principal Component Analysis*. Springer Verlag, New York, 2002.
- [13] KARPUSCHEWSKI B., WEHMEIER M., INASAKI I., *Grinding monitoring system based on power and acoustic emission sensors*. Annals of the CIRP, Vol. 49/1, 2000, 235-240.
- [14] KORBICZ J., KOŚCIELNY J.M., *Modelowanie, diagnostyka i sterowanie nadrzędne procesami*. Warszawa, WNT, 2009.
- [15] LAJMERT P., KRUSZYŃSKI B., *A diagnostic system for cylindrical plunge grinding process based on Hilbert Huang transform and principal component analysis*, Advances in Manufacturing Science and Technology, Vol. 34/3, 2010, 19-35.
- [16] LAJMERT P., KRUSZYŃSKI B., WRĄBEL D., *Modelowanie zależności w procesie szlifowania kłowego wałków z wykorzystaniem metody analizy składowych głównych i drzew decyzyjnych*. Mechanik nr 8-9, 2012.
- [17] LIAO T. W. TING C., QU J., BLAU P.J., *A wavelet-based methodology for grinding wheel condition monitoring*. International Journal of Machine Tools & Manufacture, Vol.47, 2007, 580-592.
- [18] LIAO T., *Feature extraction and selection from acoustic emission signals with an application in grinding wheel condition monitoring*. Journal Engineering Applications of Artificial Intelligence, Vol. 23/1, 2010, 74-84.
- [19] LIU Q., CHEN X., WANG Y., GINDY N., *Empirical modelling of grinding force based on multivariate analysis*. Journal of Material Processing Technology, Vol. 203, 2008, 420-430.
- [20] QUINLAN R., *Induction of decision trees*, Machine Learning, Kluwer Academic Publishers, Hingham (MA), 2003, Vol. 1, 81-106.
- [21] SCHÖLKOPF B., SMOLA A.J., *Learning with kernels: support vector machines*. Regularization, Optimization, and Beyond, MIT Press, Cambridge, MA.
- [22] WEBSTER J., MARINESCU I., *Acoustic emission for process control and monitoring of surface integrity during grinding*. Annals of the CIRP, Vol. 43/1, 1994, 299-304.
- [23] WEGENER K., HOFFMEISTER H.-W., KARPUSCHEWSKI B., KUSTER F., HAHMANN W.-C., RABIEY M., *Conditioning and monitoring of grinding wheels*. Annals of the CIRP, Vol. 60/2, 2011, 757-777.