

Joanna KOSSAKOWSKA<sup>1\*</sup>  
Sebastian BOMBIŃSKI<sup>1</sup>  
Krzysztof JEMIELNIAK<sup>1</sup>

## ZAAWANSOWANE METODY ANALIZY SYGNAŁÓW W DIAGNOSTYCE STANU NARZĘDZIA

Niniejszy artykuł przedstawia wyniki oceny przydatności poszczególnych metod analizy oraz miar sygnałów do diagnostyki stanu narzędzia. Do badań wytypowano szereg miar (różne miary statystyczne, miary przekroczeń progu etc.) oraz metod analizy sygnałów (FFT, PSD, transformata falkowa), których przydatność do diagnostyki stanu narzędzia przy określonym algorytmie szacowania zużycia ostrza przetestowano na wielu różnych eksperymentach (różne odmiany toczenia, frezowanie, wiercenie). Analiza przydatności danej miary polegała na określeniu błędu *RMSE* szacowanego zużycia ostrza w stosunku do rzeczywistego zużycia, uzyskanego w wyniku uczenia układu nadzoru na danej mierze. Ponadto wykonano analizę korelacji wzajemnej poszczególnych miar i na tej podstawie wytypowano miary, które statystycznie często są skorelowane wzajemnie ze sobą. W ramach badań przeprowadzono również analizę przydatności różnych czujników do diagnostyki stanu ostrza. W wyniku tej analizy stwierdzono, że najbardziej przydatne do stosowanej diagnostyki stanu ostrza są czujniki siły i emisji akustycznej.

### 1. WSTĘP

Jednym z warunków zwiększenia autonomii współczesnych obrabiarek skrawających jest zastosowanie w nich układu diagnostyki procesu skrawania. Układom diagnostycznym stawia się za zadanie wykrywanie skrawania, katastroficznego stopienia ostrza, zużycia ostrza, braku narzędzia, zmiany naddatku i innych. Jednak stosowane układy diagnostyczne nie dostarczają w pełni zadowalających wyników, zwłaszcza w zakresie diagnostyki naturalnego zużycia ostrza. Jak wykazano w wielu publikacjach, kluczową rolę w diagnostyce stanu narzędzi pełni odpowiedni dobór miar sygnałów diagnostycznych. Ze względu na złożoność zjawisk występujących podczas skrawania wybór jednej miary skorelowanej z jednym, nadzorowanym czynnikiem nie jest oczywisty, stąd powszechnie uznawana konieczność opierania tej diagnostyki na wielu miarach [1],[2]. Z kolei stosowanie zbyt wielu miar wydłuża czas obliczeń przez układ nadzoru. Dlatego miary należy wybierać z należytą starannością.

---

<sup>1</sup> Politechnika Warszawska, Instytut Technik Wytwarzania, Warszawa

\* E-mail: j.kossakowska@zaeios.pw.edu.pl

## 2. MIARY SYGNAŁÓW W DIAGNOSTYCE PROCESU SKRAWANIA

W badaniach laboratoryjnych najczęściej do wyznaczania miar stosuje się proste metody statystyczne do analizy sygnałów w dziedzinie czasu (46% publikacji). Jednak często okazują się one być niewystarczająco dobrze skorelowane ze zużyciem ostrza, stąd zachodzi potrzeba poszukiwania miar sygnałów poddanych przetworzeniu. Coraz częściej do wyznaczania miar stosuje się również analizę w dziedzinie częstotliwościowej (22% publikacji) oraz czasowo-częstotliwościowej (29% publikacji). W niektórych pracach stosuje się kilka metod analizy sygnałów jednocześnie, np. metody analizy sygnałów w dziedzinie czasu oraz w dziedzinie czasowo-częstotliwościowej zastosowano z sukcesem m.in. w [22],[23],[24]. W dziedzinie czasu jako miary korelacji sygnału ze stanem narzędzia stosowane są zazwyczaj miary statystyczne: wartość średnia [3],[7],[8], wartość skuteczna, [5], moc i energia sygnału [6], kurtoza i skośność [7],[8], odchylenie standardowe, wariancja, moment [8], czy współczynnik szczytu [9]. Proponowane są również miary zależności stosunku między składowymi siły skrawania, jako miary niezależnej od warunków skrawania [10],[11],[12]. Bardzo dobrą miarą do analizy stanu narzędzia na podstawie surowego sygnału emisji akustycznej okazuje się być również liczba przekroczeń progu lub czas przebywania sygnału ponad danym progom [15].

W dziedzinie częstotliwości najczęstszymi algorytmami wykorzystywanymi w diagnostyce procesu skrawania są Szybka Transformata Fouriera (FFT) oraz Gęstość Widmowa Mocy (PSD). Ale zdarzają się również inne metody, np. filtrowanie czy cepstrum. W większości publikacji podejmowane są próby wykazania miar widm sygnałów, skorelowanych ze zużyciem ostrza. W FFT i PSD wyznaczana jest najczęściej energia widma [18],[19]. W [16],[20] analizowana jest wartości amplitudy oraz częstotliwości dla kilku dominujących prążków. Niekiedy stosowane są miary statystyczne rozkładu widma, takie jak wartość średnia, odchylenie bezwzględne, kurtoza, skośność i inne [17] wyznaczane jest pole pod krzywą widma. Z kolei w [26] wyznaczana jest moc sygnału w poszczególnych pasmach częstotliwości.

W dziedzinie czas-częstotliwość wykorzystuje się obecnie najczęściej transformatę falkową (WT). Szeroko zakrojone studium na temat zastosowania WT do diagnostyki procesu skrawania przedstawiono w [22],[24]. Tamże zastosowano wiele miar sygnałów pasmowych, uzyskanych w wyniku WP (Pakietowa Transformata Falkowa) do diagnostyki stanu narzędzia podczas toczenia. Oprócz standardowych miar statystycznych, takich jak wartość średnia wartości bezwzględnej czy wariancja, z powodzeniem zastosowano energię oraz liczbę przekroczeń progu oraz procentowy udział czasu przebywania sygnału ponad progom dla trzech różnych progów.

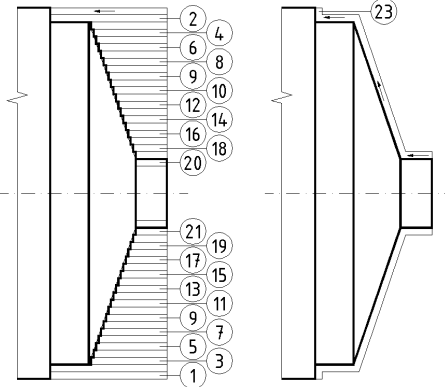
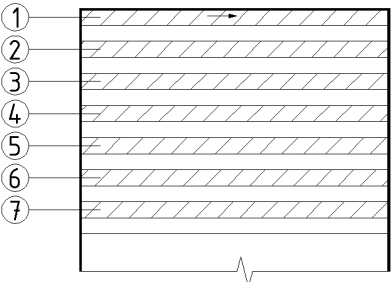
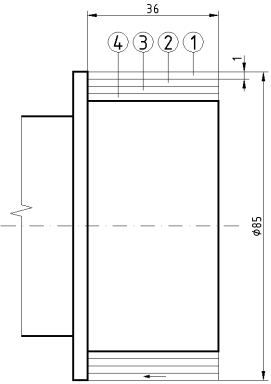
W większości prac miary sygnałów dobierane są arbitralnie bądź też na podstawie wnikliwej analizy charakteru sygnału podczas konkretnych warunków obróbki. Budując układ nadzoru, który ma charakteryzować się uniwersalnością i wszechstronnym zastosowaniem niezależnie od rodzaju prowadzonego procesu, nie należy zakładać, że dla każdego rodzaju procesu od początku analizowany będzie charakter sygnałów i na tej podstawie dobierane będą miary sygnałów diagnostycznych. Zatem należy zawczasu dobrać miary, które z dużym prawdopodobieństwem mają szansę być przydatnymi w układach

diagnostycznych. Jest to możliwe jedynie w wyniku badań przydatności poszczególnych miar do wielu różnych procesów.

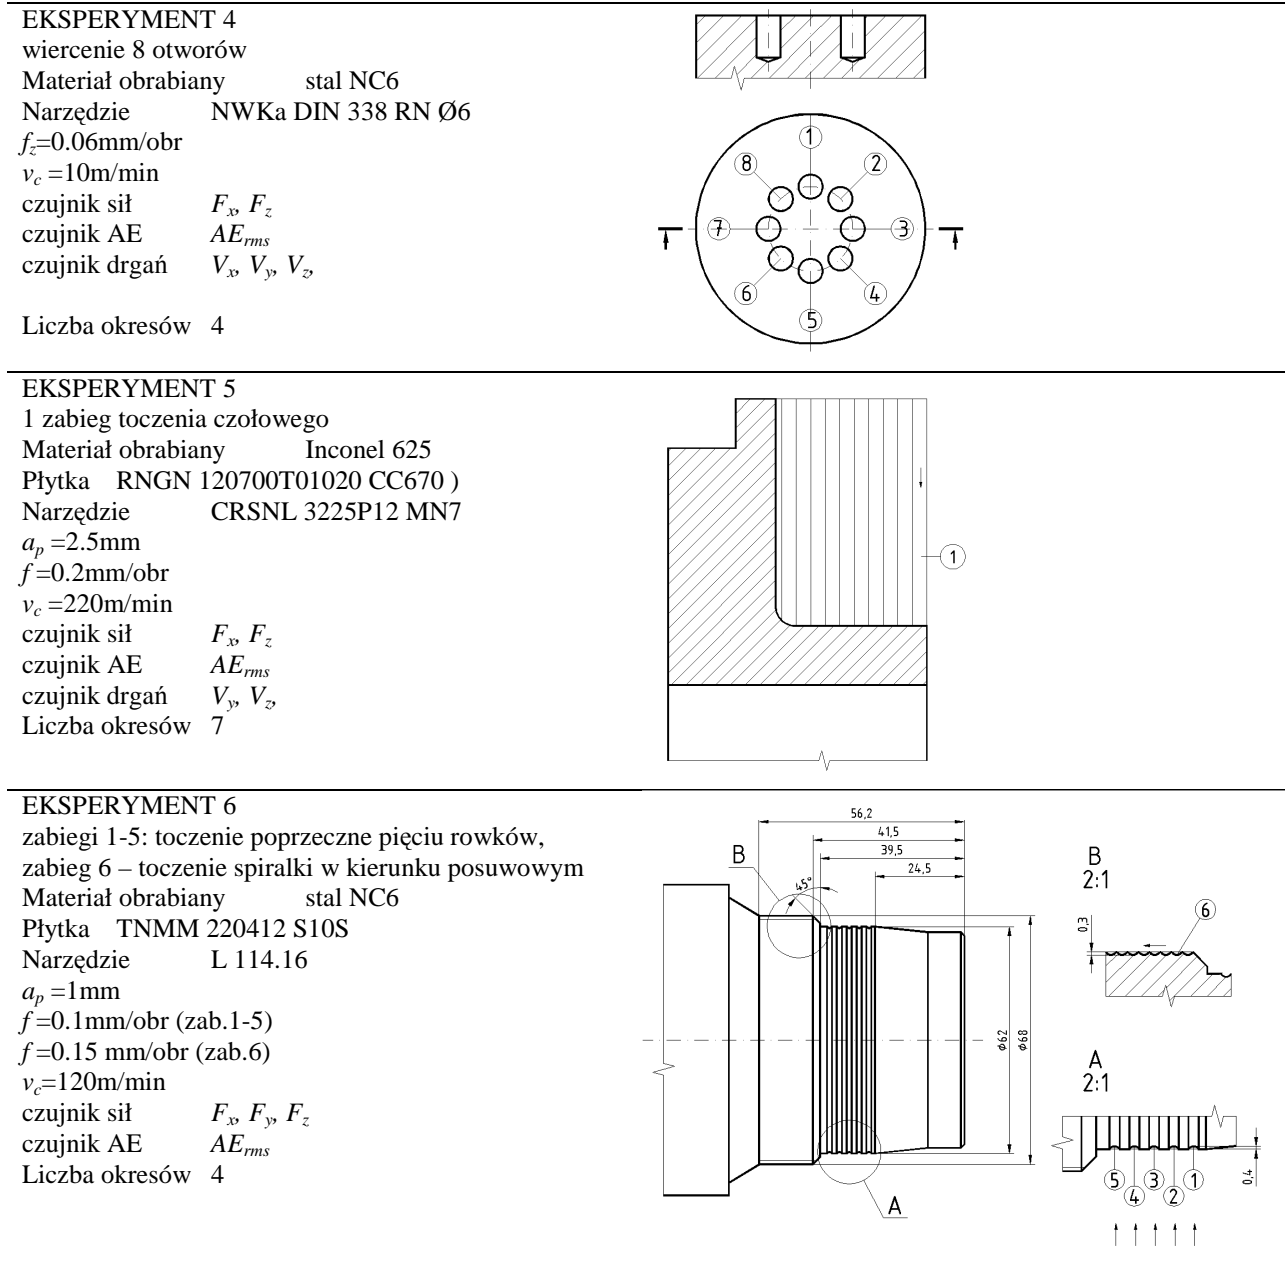
### 3. BADANIA PRZYDATNOŚCI MIAR SYGNAŁÓW DIAGNOSTYCZNYCH

#### 3.1. ZAKRES BADAŃ

Analizę przydatności miar sygnałów do diagnostyki stanu narzędzia postanowiono przeprowadzić na eksperymentach, reprezentujących możliwie różnorodne sposoby, odmiany i warunki obróbki. Opis eksperymentów przedstawiono na rys. 1 i rys. 2.

<p><b>EKSPERYMENT 1</b>            22 zabiegi toczenia wzdłużnego pod stożek, 1 zabieg wyrównywanie stożka            Materiał obrabiany stal 45            Płytką CNMG 120408 BP30A            Narzędzie PCLNR 3225P 12  <math>a_p=1.5\text{mm}/2\text{mm}</math>  <math>f=0.1\text{mm}/\text{obr}</math>  <math>v_c=150\text{m}/\text{min}</math>            czujnik sił <math>F_x, F_y, F_z</math>            czujnik AE <math>AE_{rms}</math>            Liczba okresów 9</p>	
<p><b>EKSPERYMENT 2</b>            7 zabiegów frezowania przeciwbieżnego            Materiał obrabiany płyta laminowana            Narzędzie 107 055 9 Ø12 mm  <math>a_p=6\text{mm}</math>,  <math>a_e=6\text{mm}</math>  <math>v_f=8\text{m}/\text{min}</math>  <math>v_c=680\text{m}/\text{min}</math>            czujnik drgań <math>V_y, V_{rms}</math>            mikr. elektretowy <math>CI</math>            Liczba okresów 4</p>	
<p><b>EKSPERYMENT 3</b>            4 zabiegi toczenia wzdłużnego            Materiał obrabiany stal NC6            Płytką CNMG 1204 08-WF; 4225            Narzędzie C3-DCLNL-22045-12  <math>a_p=1\text{mm}</math>  <math>f=0.1\text{mm}/\text{obr}</math>  <math>v_c=280\text{m}/\text{min}</math>            czujnik sił <math>F_x, F_y, F_z</math>            czujnik AE <math>AE_{rms}</math>            czujnik drgań <math>V_x, V_y, V_z</math>            mikr. elektretowy <math>CI</math>            mikr. dynamiczny <math>C2</math>            Liczba okresów 5</p>	

Rys. 1. Warunki obróbki, eksperymenty 1, 2, 3  
 Fig. 1. Cutting conditions, experiment 1, 2 and 3



Rys. 2. Warunki obróbki, eksperymenty 4, 5 i 6  
 Fig. 2. Cutting conditions, experiment 4, 5 and 6

Aby wyznaczyć miary sygnałów, należało wybrać odpowiednie fragmenty sygnału oryginalnego, zwane dalej segmentami. W ramach niniejszej pracy segmenty z poszczególnych sygnałów wycinano automatycznie, za pomocą procedury stosowanej obecnie w układzie ADONIS a opisaną szczegółowo w [25]. Liczbę segmentów w ramach pojedynczej operacji dla poszczególnych eksperymentów wraz z ich długością przedstawiono w tabeli 1. Każdy segment stanowił oddzielny sygnał diagnostyczny, poddawany wyznaczaniu miar.

Tabela 1. Długości segmentów i ich liczba w pojedynczej operacji dla poszczególnych eksperymentów  
 Table 1. The lengths of the segments and their number for individual experiments

Nr eksperymentu	1	2	3	4	5	6
długość segmentu [s]	1	1	1	1	1	0.5
liczba segmentów	5	7	4	5	4	3

### 3.2. ZASTOSOWANE MIARY

Wykorzystując wcześniejsze doświadczenie oraz bazując na informacjach opisanych w rozdziale 2, postanowiono dla każdego z eksperymentów wyznaczyć miary sygnałów w dziedzinie czasu, częstotliwości i czasowo-częstotliwościowej.

Z dziedziny czasu, a więc z sygnału surowego, nieprzetworzonego, postanowiono wyznaczyć szereg miar statystycznych: wartość skuteczną (rms), odchylenie standardowe (st\_dev), wartość średnią (mean), wartość modalną (moda), skośność (skew), kurtozę (kurt), moment trzeciego stopnia (mom3), moment czwartego stopnia (mom4), moc (pow), wartość międzyszczytową (PP), współczynnik szczytu (CF), percentyl 90% (Perc90), percentyl 50% (Perc50). Postanowiono zastosować również nową miarę Energii sygnału ITD. oraz entropię Shannona (Shan), definiowaną tutaj jako:

$$E = \frac{\sum_{i=0}^n \log x_i^2}{n} \quad (1)$$

$$Shan = \frac{\sum_{i=0}^n x_i^2 \log x_i^2}{n} \quad (2)$$

gdzie:  $x_i$  – wartość  $i$ -tej próbki w sygnale,  $n$  – liczba próbek w sygnale. Zastosowano również miarę przyrostu względnego miary (Incr):

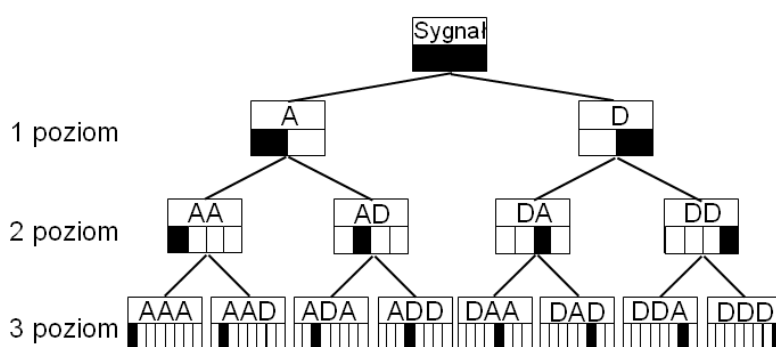
$$Incr = \frac{RMS_k - RMS_1}{RMS_1} \quad (3)$$

gdzie:  $RMS_{j,k}$  – wartość skuteczna sygnału w  $k$ -tej operacji,  $RMS_{j,1}$  – wartość skuteczna sygnału w 1-tej operacji. Ponadto postanowiono zastosować miary przekroczeń trzech ustalonych progów: liczbę przekroczeń progu 1, 2 i 3 (Count1, Count2, Count3), tj liczbę przekroczeń progu wynoszącego 30%, 50%, 70% wartości maksymalnej sygnału podczas pierwszej operacji oraz czas ponad progiem 1, 2 i 3 (Pulse1, Pulse2, Pulse3), tj.– procentowy udział czasu sygnału ponad progiem wynoszącym 30%, 50%, 70% wartości maksymalnej sygnału podczas pierwszej operacji.

W ramach analizy w dziedzinie częstotliwości wykonano FFT i PSD. Przyglądając się uzyskanym widmom dla ostrzy nowych i stępionych dla różnych sygnałów zauważono, że nie da się wyodrębnić określonych pasm częstotliwości, dla których następuje zmiana wartości sygnału – przeważnie taka zmiana wartości widma sygnały występuje dla kilku lub kilkunastu pasmach częstotliwości, różnych w zależności od analizowanego eksperymentu. Z kolei analiza wartości sygnału dla całego spektrum pasm częstotliwości wykonywana jest

za pomocą analizy falkowej (w dziedzinie czas-częstotliwość). Zatem zdecydowano przyjąć energię widma FFT bądź PSD jako miarę sygnałów w dziedzinie częstotliwości.

Do wyznaczenia miar w dziedzinie czas-częstotliwość postanowiono zastosować trójpoziomą pakietową transformatę falkową WP3 przy użyciu falki db02. W wyniku transformaty otrzymano 14 pakietów (sygnałów pasmowych). Zgodnie z przedstawionym na rys. 3 schematem, jeśli sygnał surowy zawiera informacje o częstotliwościach 0-1000Hz, to w wyniku dekompozycji na pierwszym poziomie otrzymujemy dwa sygnały pasmowe: Aproksymację A (zawierającą informację o częstotliwościach 0-500Hz) oraz Detal D (zawierające informacje o częstotliwościach 500-1000Hz). Na kolejnym poziomie otrzymujemy cztery sygnały pasmowe o szerokości pasma częstotliwości równym 250Hz itd.



Rys. 3. Schemat ideowy działania WP oraz zakresy częstotliwości sygnałów pasmowych dla kolejnych poziomów transformaty falkowej

Fig. 3. A schematic diagram of Wavelet Packet

Dla każdego sygnału pasmowego wyznaczono te same miary co dla sygnału surowego. Podsumowując ostatecznie otrzymujemy: 22 miary z dziedziny czasu, 2 miary z dziedziny częstotliwości oraz 308 miary z dziedziny czas-częstotliwość. Łącznie to daje 332 miary dla danego sygnału.

### 3.3. BADANIA PRZYDATNOŚCI MIAR DO DIAGNOSTYKI STANU NARZĘDZIA

W wyniku analizy sygnałów dla każdego z segmentów poszczególnych sygnałów diagnostycznych otrzymuje się 332 miary. Spośród tych wszystkich miar należy wyselekcjonować te przydatne w procesie diagnostyki stanu narzędzia. Przydatność danej miary do wykorzystania w danym układzie diagnostyki zużycia ostrza określona jest przez dwa czynniki: po pierwsza miara musi zawierać informację o stanie ostrza a po drugie algorytm diagnostyczny musi być w stanie wydobyć tę informację. Dlatego system selekcji miar musi uwzględniać możliwości algorytmu szacowania zużycia na podstawie danej miary. Dlatego na początku przedstawiony zostanie algorytm szacowania zużycia, rozwijany od lat w ITW.

Przebieg kolejnych ( $i$ -tych), wybranych ze zbioru „uczącego”, miar okresu trwałości zapisywany jest w tablicy  $M_i[\Delta T]$ . Tablica ta tworzona jest na podstawie przebiegu miary, aproksymowanego wielomianem trzeciego stopnia. Kolejne wartości w tablicy odpowiadają przyrostowi  $\Delta T$  równemu 1%. W oparciu o tak wyznaczoną tablicę oszacowywane jest zużycie ostrza i kolejnych ostrzy. W tablicy  $M_i[\Delta T]$  wyszukiwany jest element najbliższy, którego wartość jest najbliższa aktualnej wartości  $M_i$  dla diagnozowanego ostrza. Indeks tego elementu określa wykorzystaną część okresu trwałości w %. Przeszukiwanie ograniczone jest do obszaru tablicy otaczającego punkt, który odpowiada przyrostowi zużycia, spodziewanego na podstawie długości uczących okresów trwałości ostrza i zużycia ostrza oszacowanego przez układ w poprzednim kroku. Granice tego obszaru odpowiadają odpowiednio dwa razy wolniejszemu i dwa razy szybszemu przyrostowi zużycia niż średnia z okresów uczących. Ostateczną wartością zużycia oszacowaną przez układ jest średnia z oszacowań dla poszczególnych miar z odrzuceniem błędów grubych, czyli przekraczających  $3\sigma$ . Skuteczność takiego układu diagnostyki określana jest za pomocą błędu  $RMSE$ , obliczanego wg zależności:

$$RMSE = \frac{\sum_{l=1}^L \sqrt{\frac{\sum_{k=1}^K (T_{oszac,l,k} - T_{rzecz,k})^2}{K}}}{L} \quad (4)$$

gdzie:  $T_{oszac,l,k}$  – wartość oszacowanego zużycia ostrza dla  $l$ -tego okresu trwałości ostrza  $k$ -tego przyrostu  $\Delta T$ ,  $T_{rzecz,k}$  – wartość rzeczywistego zużycia ostrza  $k$ -tego przyrostu  $\Delta T$ ,  $L$  – liczba okresów trwałości ostrza wykorzystanych do uczenia.

Chcąc określić, czy dana miara jest przydatna w wyżej wymienionej metodzie diagnostyki stanu ostrza, należy określić skuteczność układu (błąd  $RMSE$ ), w przypadku uczenia na danej mierze. W przypadku wykorzystywania wskaźnika  $RMSE$  do określania przydatności danej miary do szacowania zużycia ostrza, wyznaczano na początku model miary z wykorzystaniem wszystkich okresów trwałości ostrza, a następnie prowadzono diagnostykę na wszystkich okresach trwałości ostrza z wykorzystaniem tego modelu. Tak uzyskaną wartość błędu oszacowania zużycia ostrza oznaczono jako  $RMSE(L)$  i stanowi on podstawę oceny danej miary. Miara jest tym bardziej przydatna do diagnostyki im błąd oszacowania zużycia w stosunku do zużycia rzeczywistego jest mniejszy.

#### 3.4. BADANIA KORELACJI WZAJEMNEJ MIAR SYGNAŁÓW DIAGNOSTYCZNYCH

Spośród wszystkich 332 miar wyznaczonych dla każdego segmentu i każdego z czujników należy spodziewać się miar, które mogą być ze sobą wzajemnie skorelowane. Choć każda z zastosowanych miar opisana jest inną zależnością, to w pewnych warunkach pewne miary mogą przyjmować te same wartości. Do badania korelacji wzajemnej postanowiono zastosować współczynnik korelacji Pearsons'a. Za wartość progową przyjęto, po wstępnym rozpoznaniu 0,99. Korelację wyznaczano dla każdego czujnika oddzielnie, dla sygnału surowego oraz dla sygnałów w dziedzinie częstotliwości.

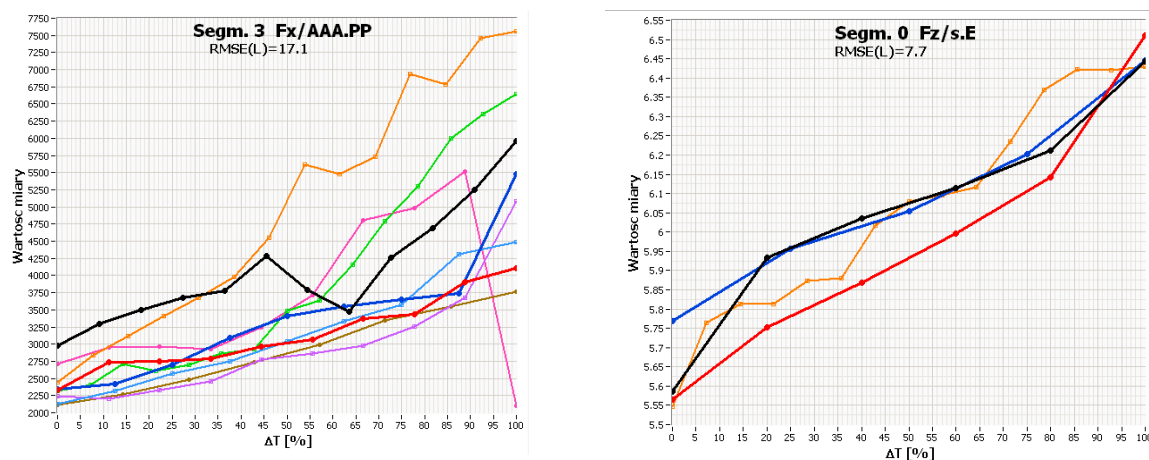
## 3.5. WERYFIKACJA BADAŃ

Przeprowadzenie analiz opisanych w punktach 3.3 oraz 3.4 miało na celu odrzucenie miar nieprzydatnych w diagnostyce, bądź skorelowanych z innymi przydatnymi miarami. Chcąc zweryfikować jaki skutek, na wynik diagnostyki zużycia ostrza, ma zmniejszenie liczby miar, należy porównać wyniki diagnostyki zużycia ostrza opartej na uczeniu na wszystkich miarach oraz na miarach pozostawionych w wyniku selekcji. W przypadku rzeczywistej diagnostyki, wykonywanej zgodnie z opisem przedstawionym w punkcie 3.3, procedura jest następująca: na podstawie pierwszego okresu trwałości wyznaczamy modele miar; w drugim okresie trwałości ostrza szacujemy zużycie na podstawie modeli miar wyznaczonych po pierwszym okresie trwałości ostrza, następnie wyznaczamy model w oparciu o pierwszy i drugi okres trwałości ostrza; w trzecim okresie trwałości postępujemy analogicznie jak w przypadku drugiego okresu, douczając układ. Od czwartego okresu trwałości ostrza diagnostyka prowadzona jest w oparciu o modele zbudowane w oparciu o pierwsze trzy okresy trwałości ostrza. Błąd  $RMSE$  tak prowadzonej diagnostyki stanu oznaczono jako  $RMSE(T)$ .

## 4. WYNIKI BADAŃ

## 4.1. ANALIZA PRZYDATNOŚCI MIAR DO DIAGNOSTYKI STANU NARZĘDZIA

Na rys. 4. przedstawiono przykładowe przebiegi miar dla eksperymentu 1 (po lewej) oraz eksperymentu 6 (po prawej). Przebiegi miar przedstawione są w funkcji wykorzystanej części okresu trwałości ostrza ( $\Delta T$  [%]), dla kolejnych okresów trwałości – każdy oznaczony innym kolorem. Nad każdym przebiegiem miary przedstawiono nazwę tej miary, wartość  $RMSE(L)$  oraz numer segmentu, dla którego została wyznaczona dana miara.



Rys. 4. Przykładowe przebiegi miar uzyskane dla eksperymentu 1 (po lewej) oraz eksperymentu 6 (po prawej)  
Fig. 4. Sample courses of features obtained for the experiment 1 (left) and experiment 6 (right)



Przyglądając się przebiegom miar zauważono, że najlepsze, tj. najbardziej powtarzalne miary posiadają  $RMSE(L)$  poniżej 10. Z kolei miary o  $RMSE(L)$  powyżej 20 charakteryzują się już na tyle dużą niepewnością i rozrzutem, że można je uznać za nieprzydatne w diagnostyce stanu narzędzia. W tabeli 2 przedstawiono liczbę miar poniżej trzech progowych wartości  $RMSE(L)$ : 10, 15 i 20. Ponieważ jednak liczba miar dla poszczególnych eksperymentów była różna (ze względu na różną liczbę czujników i segmentów), zamieszczono również procentowy udział miar spełniających kryterium w stosunku do liczby wszystkich miar w danym eksperymencie.

Tabela 2. Liczba miar spełniających dane kryterium  $RMSE(L)$  dla poszczególnych eksperymentów  
Table 2. Number of measures that meet criterion  $RMSE(L)$  for individual experiment

Nr eksperymentu	$RMSE(L) \leq 10$		$RMSE(L) \leq 15$		$RMSE(L) \leq 20$	
	Liczba miar	[%]	Liczba miar	[%]	Liczba miar	[%]
1	0	0	5	0.1	276	4.0
2	0	0	31	0.4	408	5.9
3	0	0	305	4.4	2129	30.6
4	0	0	493	7.1	2493	35.8
5	4	0.1	182	2.6	2164	31.1
6	129	1.9	411	5.9	679	9.8

W większości eksperymentów nie osiągnięto ani jednej miary spełniającej kryterium  $RMSE(L) \leq 10$ . Dla eksperymentu nr 5 osiągnięto 4 takie miary, zaś dla eksperymentu 6 – 129 miar, co stanowiło niespełna 2% wszystkich miar. Dla kryterium  $RMSE(L) \leq 15$ , najwięcej korzystnych miar osiągnięto dla eksperymentu nr 3. Jednak dla eksperymentu nr 1 liczba miar wynosiła zaledwie 5. Po podniesieniu kryterium do 20, liczba korzystnych miar dla wszystkich eksperymentów wynosiła od kilkuset do prawie 2500, co z kolei może znacznie wydłużyć czas obliczeń. Należy się jednak liczyć z tym, że wśród korzystnych miar znajduje się również wiele miar, które są wzajemnie ze sobą skorelowane i liczba ta zostanie znacznie zredukowana po odrzuceniu miar podobnych.

W tabeli 3 przedstawiono minimalne wartości  $RMSE(L)$  uzyskane dla poszczególnych miar z podziałem na różne czujniki. Przyglądając się wynikom można zauważyć, że:

- najmniejsze minimalne wartości  $RMSE(L)$  uzyskano dla czujników sił i emisji akustycznej,
- największe wartości minimalne uzyskano dla czujników ciśnienia akustycznego,
- najmniejsze minimalne wartości  $RMSE(L)$  to energia, inkrement, wartość średnia, wartość średnia modalna, percentyle rzędu 50 i 90, moc, wartość skuteczna, oraz entropia Shannona dla czujnika sił oraz odchylenie standardowe dla czujnika emisji akustycznej,
- statystycznie najgorsze minimalne wartości  $RMSE(L)$  uzyskano dla: współczynnika szczytu, liczby przekroczeń progu 2, kurtozy, momentu czwartego rzędu,

- statystycznie najmniejsza wartość minimalna dla sygnałów drgań i ciśnienia akustycznego to liczba przekroczeń progu 1.

Tabela 3. Minimalne wartości  $RMSE(L)$  dla poszczególnych miar  
Table 3. The minimum value of  $RMSE(L)$  for individual features

	CF	Count1	Count2	Count3	E	Incr	Kurt	mean	moda	mom3	mom4	Perc50
F	12	12	12	11	8	8	11	8	8	12	13	9
AErms	11	11	12	13	8	9	11	8	9	14	12	8
V	12	11	13	12	13	12	13	16	14	12	16	13
C1	17	14	16	16	18	15	19	14	15	15	15	17
C2	16	14	17	13	18	22	17	20	16	14	16	18
	Perc90	Pow	PP	Pulse1	Pulse2	Pulse3	RMS	Shan	Skew	st_dev	PSD.E	FFT.E
F	9	9	12	13	11	12	8	9	12	11	13	13
AErms	9	9	12	10	10	13	9	10	14	9	15	15
V	13	12	13	12	13	11	12	12	12	12	15	15
C1	13	15	14	17	14	13	15	15	14	15	22	22
C2	19	21	21	14	18	13	16	22	20	16	26	26

#### 4.2. ANALIZA KORELACJI WZAJEMNEJ MIAR SYGNAŁÓW DIAGNOSTYCZNYCH

W wyniku badań korelacji wzajemnej miar sygnałów stwierdzono, że bez względu na typ czujnika w każdym eksperymencie uzyskano bardzo silną korelację między mocą a entropią Shannona. Z kolei miary, które w żadnym przypadku nie korelowały z innymi miarami to: energia, skośność, kurtoza, wartość międzyszczytowa oraz współczynnik szczytu. Miarami, które rzadko kiedy korelowały z innymi miarami były: moment trzeciego stopnia, moment czwartego stopnia, miary przekroczeń progów.

Dla czujników sił skrawania miarą, która nie korelowała z żadną inną miarą było odchylenie standardowe zaś w większości przypadków również następowała korelacja między miarami:

- rms, percentyl rzędu 50, percentyl rzędu 90,
- wartość średnia arytmetyczna i modalna,
- energia FFT i PSD.

Dla czujnika emisji akustycznej w większości przypadków następowała korelacja między miarami:

- rms, percentyl rzędu 50, wartość średnia arytmetyczna,
- energia FFT i PSD.

Dla czujników drgań i ciśnienia akustycznego, w większości przypadków następowała korelacja między miarami:


- rms, percentyl rzędu 90, odchylenie standardowe (w przypadku czujnika drgań z natury rzeczy),
- energia FFT i PSD.

## 4.3. WERYFIKACJA WYNIKÓW BADAŃ

Na podstawie analizy przedstawionej w rozdziałach 4.1 oraz 4.2 wyeliminowano miary, które statystycznie są mało przydatne do stosowanej diagnostyki stanu narzędzia bądź też skorelowane są z innymi, lepszymi miarami. Są to: energia FFT oraz 10 miar sygnału surowego i sygnałów pasmowych uzyskanych w wyniku WP, współczynnik szczytu, liczba przekroczeń progów 2 oraz 3, czas sygnału ponad progiem 2 oraz 3, kurtoza, moment czwartego stopnia, percentyle rzędu 50 i 90, entropia Shannona. Łączna liczba tych miar to 151 czyli ok. 46% wszystkich miar.

Celem zweryfikowania jaki wpływ na wyniki diagnostyki stanu narzędzia ma wyeliminowanie tych miar, porównano wyniki szacowania zużycia ostrza, przeprowadzone zgodnie z procedurą opisaną w 3.5, stosując jako zbiór uczący wszystkie miary oraz miary tylko wyselekcjonowane (po wyeliminowaniu miar uznanych za nieprzydatne). W obu przypadkach jako warunek dopuszczalności miary do szacowania zużycia zastosowano jako kryterium  $RMSE(L)$  wartość 20.

Na rys. 5 zamieszczono przebiegi szacowanego zużycia ostrza w funkcji rzeczywistego  $\Delta T$ , uzyskane w eksperymencie nr 5, dla kolejnych okresów trwałości. Wykresy po lewej stronie przedstawiają wyniki uzyskane dla uczenia na wszystkich miarach spełniających kryterium  $RMSE(L) \leq 20$ , zaś rysunki po prawej stronie wyniki uzyskane dla uczenia na wyselekcjonowanych miarach. Porównując przebiegi z prawej i z lewej strony rysunków można stwierdzić, że usunięcie niemal połowy miar uczących nie wpłynęło zasadniczo na wynik szacowania zużycia ostrza. Potwierdzają to również wyniki  $RMSE(T)$ , uzyskane dla wszystkich eksperymentów, przedstawione w tabeli 4. Świadczy to o poprawności przeprowadzonych badań w zakresie wytypowania przydatnych w diagnostyce miar sygnałów i wyeliminowania nieprzydatnych bądź redundantnych miar.



Rys. 5. Oszacowane zużycie ostrza w wyniku uczenia na wszystkich miarach (po lewej) oraz na wyselekcjonowanych miarach (po prawej), eksperyment 5

Fig. 5. Tool wear estimation as a result of learning on all features (left) and selected features (right), experiment 5

Tabela 4. Wartości  $RMSE(T)$  w wyniku uczenia na wszystkich oraz na wyselekcjonowanych miarach  
 Table 4.  $RMSE(T)$  values as a result of learning at all, and the selected features

Nr eksperymentu	1	2	3	4	5	6
wszystkie	7.83	14.13	9.79	16.84	12.64	13.80
wyselekcjonowane	7.74	13.23	9.72	17.49	12.41	14.10

## 5. PODSUMOWANIE

W ramach niniejszej pracy wykonano analizę przydatności różnych miar sygnałów oraz czujników do diagnostyki stanu ostrza dla stosowanej metody szacowania zużycia ostrza. W odróżnieniu od prezentowanych dotychczas w różnych publikacjach badań, niniejsza analiza przydatności poszczególnych miar jest kompleksowa, oparta na różnych procesach, co pozwala wnioskować o uniwersalności uzyskanych wyników badań.

W wyniku badań wykazano, iż:

- najlepsze czujniki do diagnostyki stanu narzędzia to czujniki sił i emisji akustycznej,
- najlepsze miary do stosowanego sposobu szacowania zużycia ostrza to: energia, inkrement, wartość średnia, wartość średnia modalna, moc oraz wartość skuteczna,
- dobrymi miarami z punktu widzenia diagnostyki mogą być też odchylenie standardowe, czy energia PSD,
- miara charakteryzująca liczbę przekroczeń progu dobrze sprawdza się dla sygnałów oscylujących wokół wartości zero o impulsowym charakterze,
- w celu optymalizacji procedur wyznaczania miar sygnałów, celowym wydaje się być stosowanie różnych miar do różnych czujników oraz do różnych sygnałów pasmowych.

## LITERATURA

- [1] BOMBIŃSKI S., 2006, *Automatyczna ocena zużycia ostrza oparta na wielu miarach sygnałów diagnostycznych*, Rozprawa doktorska, OWPW.
- [2] JEMIELNIAK K., KWIATKOWSKI L., WRZOSEK P., 1998, *Diagnosis of Tool Wear Based on Cutting Forces and Acoustic Emission Measurements as Inputs to a Neural Network*, Journal of Intelligent Manufacturing 9.
- [3] PANDA S.S., SINGH A.K., CHAKRABORTY D., PAL S.K., 2006, *Drill wear monitoring using back propagation neural network*, Journal of Materials Processing Technology, 172, 283–290.
- [4] CHOUDHURY S.K., JAIN V.K., RAMA RAO CH.V.V., 1999, *On-line monitoring of tool wear in turning using a neural network*, International Journal of Machine Tools & Manufacture, 39, 489–504.
- [5] PATRA K., PAL S.K., BHATTACHARYYA K., 2007, *Artificial neural network based prediction of drill flank wear from motor current signals*, Applied Soft Computing, 7, 929–935.
- [6] DIMLA Sr. D.E., LISTER P.M., 2000, *On-line metal cutting tool condition monitoring. I: force and vibration analyses*, International Journal of Machine Tools & Manufacture, 40, 739–768.
- [7] SILVA R.G., BAKER K.J., WILCOX S.J., 2000, *The adaptability of a tool wear monitoring system under changing cutting conditions*, Mechanical Systems and Signal Processing, 14/2, 287–298.
- [8] ABU-ZAHRA N.H., YU G., 2003, *Gradual wear monitoring of turning inserts using wavelet analysis of ultrasound waves*, International Journal of Machine Tools & Manufacture, 43, 2003.
- [9] SCHEFFER C., HEYNS P.S., 2001, *Wear monitoring in turning operations using vibration and strain measurements*, Mechanical Systems and Signal Processing 15.

- [10] LIU Q., ALTINTAS Y., 1999, *On-line monitoring of flank wear in turning with multilayered feed-forward neural network*, International Journal of Machine Tools & Manufacture, 39, 1945–1959.
- [11] CHOUDHURY S.K., KISHORE K.K., 2000, *Tool wear measurement in turning using force ratio*, International Journal of Machine Tools & Manufacture, 40, 899–909.
- [12] GHASEMPOOR A., JESWIET J., MOORE T.N., 1999, *Real time implementation of on-line tool condition monitoring in turning*, International Journal of Machine Tools & Manufacture, 39, 1883–1902.
- [13] ORABY S.E., HAYHURST D.R., 2004, *Tool life determination based on the measurement of wear and tool force ratio variation*, International Journal of Machine Tools & Manufacture, 44, 1261–1269.
- [14] LEE J.H., LEE S.J., 1999, *One-step-ahead prediction of flank wear using cutting force*, International Journal of Machine Tools & Manufacture, 39, 1747–1760.
- [15] SHARMA V.S., SHARMA S.K., SHARMA A.K., *An approach for condition monitoring of a turning tool*, Proc. IMechE Vol. 221 Part B: J. Engineering Manufacture.
- [16] KUO R.J., 2000, *Multi-sensor integration for on-line tool wear estimation through artificial neural networks and fuzzy neural network*, Engineering Applications of Artificial Intelligence, 13, 249–261.
- [17] LEZANSKI P., 2001, *An intelligent system for grinding wheel condition monitoring*, Journal of Materials Processing Technology, 109, 258–263.
- [18] ZHOU J.M., ANDERSSON M., STAHL J. E., 2003, *The monitoring of flank wear on the CBN tool in the hard turning process*, International Journal of Advanced Manufacturing Technology, 22.
- [19] SCHEFFER C., KRATZ H., HEYNS P.S., KLOCKE F., 2003, *Development of a tool wear-monitoring system for hard turning*, International Journal of Machine Tools & Manufacture, 43, 973–985.
- [20] ABU-MAHFOUZ I., 2005, *Drill flank wear estimation using supervised vector quantization neural networks*, Neural Comput & Applic, 14.
- [21] NOORI-KHAJAVI A., KOMANDURI R., 1995, *Frequency and time domain analyses of sensor signals in drilling-Part I*, International Journal of Machine Tools and Manufacture, 35/6, 775–793.
- [22] JEMIELNIAK K., KOSSAKOWSKA J., T URBAŃSKI., S. BOMBINŃSKI., 2012, *Tool condition monitoring based on numerous signal features*, Int J Adv Manuf Technol, 59, 73–81.
- [23] JEMIELNIAK K., KOSSAKOWSKA J., 2010, *Tool wear monitoring based on wavelet transform of raw acoustic emission signal*, Advances in Manufacturing Science and Technology, 34, 3, 5–16.
- [24] JEMIELNIAK K., KOSSAKOWSKA J., URBAŃSKI T., BOMBINŃSKI S., 2010, *Multi-feature fusion based tool condition monitoring in rough turning of Inconel 625*, Proceedings of 4th CIRP International Conference on High Performance Cutting, Gifu, Japan, 2, 285–290.
- [25] BŁAŻEJAK K., BOMBINŃSKI S., 2013, *Segmentacja sygnałów diagnostycznych i selekcja segmentów do wyznaczania miar*, Projekt kluczowy „Nowoczesne technologie materiałowe stosowane w przemyśle lotniczym” Warszawa.
- [26] CZARNIAK P., GÓRSKI J., NEJMAN M., WILKOWSKI J., 2005, *The acoustic noise signal as an indirect source of information about the tool wear during the milling of chipboard and MDF*, Annals of Warsaw Agricultural University – SGGW, Forestry and Wood Technology, 56, 123–125.

#### ADVANCED METHODS OF SIGNAL PROCESSING IN THE DIAGNOSIS OF TOOL STATE

This paper presents studies results of usefulness of different signal processing methods and signal features to the tool state diagnosis. There were various different features chosen (various statistical measures, measures of threshold crossings etc.) and the signal processing methods (FFT, PSD, wavelet transform). Their usefulness in the diagnosis of the tool state where a predetermined algorithm for estimating tool wear has been tested on a variety of experiments (different types of turning, milling, drilling). Analysis of the usefulness of the signal feature consisted of determine the error RMSE of the estimated tool wear in relation to actual wear, obtained as a result of learning the diagnostic system for a given signal feature. Furthermore, the cross-correlation analysis was performed, and particular signal features were chosen, which often are statistically correlated with each other. This paper also presents the usability of various sensors to tool state diagnosis. It was found that the most useful for tool state diagnosis are sensors of the forces and acoustic emission.

Keywords: *diagnostics, tool, wavelet transform, measure signals*