

Krzysztof JEMIELNIAK¹

AUTOMATYCZNA DIAGNOSTYKA OSTRZY NARZĘDZI SKRAWAJĄCYCH

W artykule przedstawiono zasady budowy układów diagnostyki stanu narzędzia i procesu skrawania poczynając od ich struktury logicznej przez omówienie wykorzystywanych wielkości fizycznych i czujników, obróbki sygnałów, do sposobów ich integracji w ostateczną diagnozę. Posłużono się przy tym przykładami zaczerpniętymi z budowanych w Zakładzie Automatykacji i Obróbki skrawaniem układów Automatycznej Diagnostyki Ostrzy Narzędzi Skrawających (ADONiS). W ten sposób przedstawiono główne elementy dorobku naukowego Zakładu w zakresie diagnostyki stanu narzędzia i procesu (DNiPS).

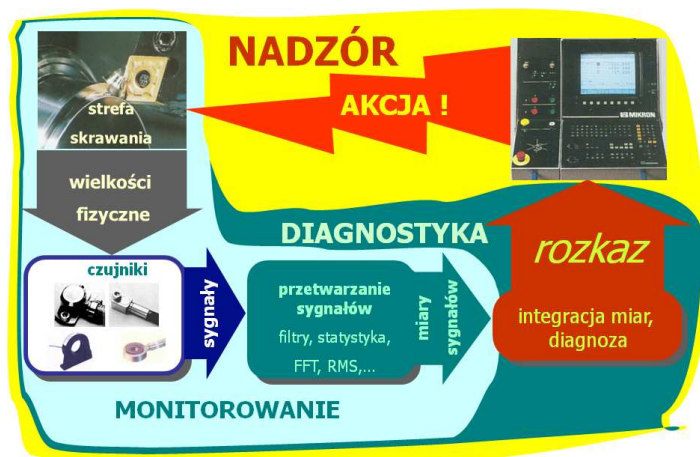
1. WPROWADZENIE

Automatyczna diagnostyka stanu narzędzia i procesu skrawania (DNiPS) stanowi jeden z nieodzownych warunków automatyzacji procesów obróbki, zmniejszenia nadzoru człowieka nad procesem, uzyskiwania lepszej jakości wyrobów i produktywności. Od lat stanowi ona przedmiot zainteresowania czołowych ośrodków naukowych na świecie [1],[2], a także zespołu (obecnie) Zakładu Automatykacji, Obrabiarek i Obróbki Skrawaniem [3]. Opis aktualnego stanu wiedzy w tym zakresie znaleźć można w [4]. Tu przedstawione zostanie wykorzystanie tej wiedzy w układach Automatycznej Diagnostyki Ostrzy Narzędzi Skrawających (ADONiS) budowanych w ZAOiOS.

Ogólną strukturę układu diagnostyki stanu narzędzia i procesu skrawania przedstawiono na rys. 1. W strefie skrawania występuje szereg wielkości fizycznych, z których niektóre są skorelowane ze stanem narzędzia. Odpowiednie czujniki przekształcają te wielkości na sygnały elektryczne, które są poddawane bardziej lub mniej złożonemu przetwarzaniu, poczynając od filtracji, przez konwersję na postać cyfrową, po wyznaczenie miar sygnałów przydatnych do diagnostyki. W oparciu o wybrane miary wypracowywana jest diagnoza stanu narzędzia, która może być przekazana do układu sterowania obrabiarki, podejmującego odpowiednie działanie. Monitorowaniem można nazwać część opisanej struktury od pomiaru wielkości fizycznych do wyznaczania miar sygnałów, które mogą być np. wyświetlane jako informacja dla operatora. Jeśli na podstawie mierzonych miar określany jest stan narzędzia, monitorowanie zamienia się w diagnostykę.

¹ Kierownik Zakładu Automatykacji, Obrabiarek i Obróbki Skrawaniem, Wydział Inżynierii Produkcji Politechniki Warszawskiej

Na podstawie tego stanu narzędzia może być wypracowany rozkaz, przekazywany automatycznie do układu sterowania obrabiarki. Wtedy mamy do czynienia z nadzorowaniem.



Rys. 1. Struktura logiczna układu nadzoru stanu narzędzia
Fig. 1. Logical scheme of tool condition monitoring system

2. WIELKOŚCI FIZYCZNE I CZUJNIKI WYKORZYSTYWANE W DNIPS


W diagnostyce stanu narzędzia i procesu skrawania dominują pomiary sił skrawania i wielkości pochodnych (moment, moc silnika), emisji akustycznej oraz drgań. Czujniki stosowane w takich układach są z reguły specjalnie do nich dedykowane, przystosowane do trudnych warunków panujących w strefie skrawania [4],[5]. Dotyczy to zarówno układów laboratoryjnych jak też dostępnych handlowo [6]. Takie też czujniki zastosowano w badaniach [7], które zostaną tu wykorzystane do zilustrowania omawianych zagadnień. Przeprowadzono je na centrum tokarskim TKX 50N wyposażonym w przemysłowe czujniki emisji akustycznej (Kistler 8152B121) i drgań (PCB PIEZOTRONICS 356A16), zainstalowane na głowicy rewolwerowej oraz czujnik sił skrawania (Kistler 9017B) umiejscowiony pod nią. Wykorzystano narzędzie CRSNL 3225P12 MN7 z ceramicznymi płytkami typu whiskers, RNGN 120700T01020 CC670. Kolejnymi przejściami prostopadłymi do osi obrotu obrabiano obudowy wirnika silnika lotniczego z Inconelu 625, od średnicy 406 do 268mm (rys. 2). Głębokość skrawania wynosiła 2.5mm, posuw 0.2mm/obr, a prędkość skrawania 220m/min. Duża ilość trudnoobrabialnego materiału obrabianego w każdej operacji sprawiała, że do wykonania jednej z nich (obróbki jednego przedmiotu) niezbędne było wykorzystanie kilku okresów trwałości ostrza, co nie jest rzadkością w przemyśle lotniczym. Ocenę stanu narzędzia prowadzi się w takim przypadku co przejście, a nie co operację (przedmiot obrabiany). Obrobiono trzy takie części, wykorzystując w pełni siedem ostrzy skrawających. Wszystkie próby prowadzono do czasu drastycznego spadku jakości powierzchni obrobionej lub powstawania zadziórów. Mierzono również zużycie wrębne. Wszystkie te trzy zjawiska występowały niezależnie, przez co

określanie końca trwałości ostrza było zadaniem trudnym, subiektywnym i zależnym od doświadczenia operatora obrabiarki.

Komercyjne układy do diagnostyki stanu narzędzia oparte są na założeniu o wzroście miar sygnałów diagnostycznych. Operator dostaje informacje o ich początkowych wartościach (SF_0), wartości aktualnej (SF_i) oraz wartości progowej (SF_k), oznaczającej stopień ostrza [5], [6]. Może na ich podstawie oszacować wykorzystaną część okresu trwałości ostrza:

$$\Delta T = \frac{t}{T} = \frac{SF_i - SF_0}{SF_k - SF_0} \quad (1)$$

gdzie: ΔT – wykorzystana część okresu trwałości ostrza, czyli stosunek dotychczasowego czasu skrawania (t) do pełnego okresu trwałości ostrza (T). Taka informacja a nie wartości miar, jest operatorowi potrzebna i taką postanowiono określać w układach ADONiS już od pierwszej wersji [5]. W tejże wersji wykorzystywano bezpośrednio zależność (1), co oznaczało założenie o liniowym przebiegu miary w funkcji postępującego zużycia ostrza i było oczywiście uproszczeniem.

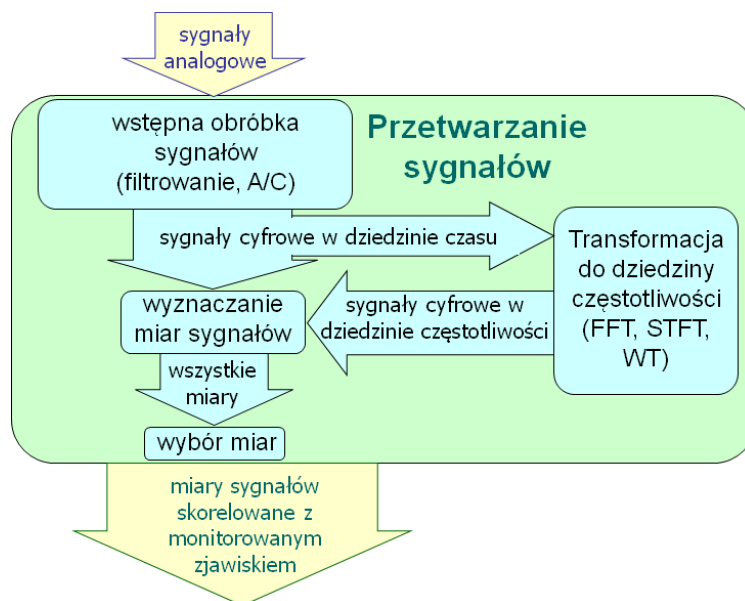


Rys. 2. Przedmiot obrabiany i narzędzie (a), wskaźniki stopienia: zadziory na powierzchni przejściowej (b), zużycie wrębne (c), chropowatość powierzchni obrabianej (d) [7]

Fig. 2. Workpiece and tool (a), tool life criteria burrs (b), tool wear (c), surface roughness (d) [7]

3. PRZETWARZANIE SYGNAŁÓW W DNIPS

Powszechnie uznaje się, iż w ogólnym przypadku nie jest możliwe wiarygodne monitorowanie stanu narzędzia i procesu skrawania w oparciu o pojedynczą miarę sygnału. Stąd wyznaczanie odpowiednio dużej liczby miar jest kluczowym zagadnieniem w każdym układzie DNIPS. Przetwarzanie sygnałów odbywa się w kilku etapach: obróbka wstępna, wyznaczanie miar, wreszcie selekcja miar przydatnych do diagnozowanego procesu. Wyznaczone i wyselekcjonowane w ten sposób miary sygnałów stanowią podstawę do oceny stanu narzędzia i procesu skrawania. Schemat logiczny tego przetwarzania przedstawiono na rys. 3.



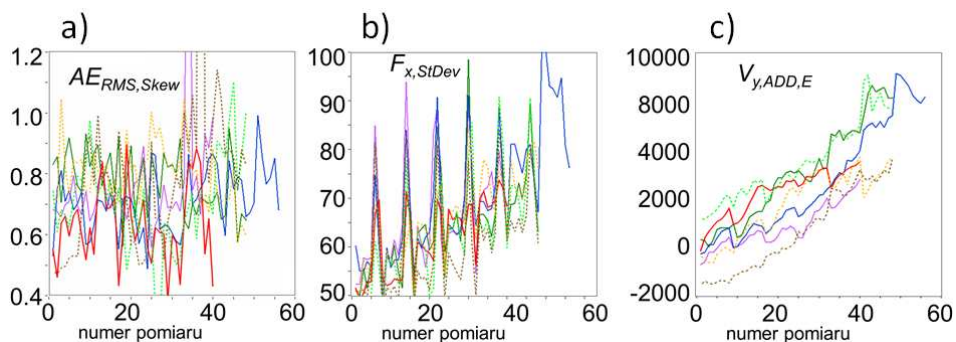
Rys. 3. Schemat logiczny przetwarzania sygnałów w układach DNiPS
Fig. 3. Signal processing logical scheme in TCM systems

We wspomnianych wyżej badaniach [7] surowy sygnał emisji akustycznej AE_{raw} był rejestrowany z szybkością próbkowania 2Ms/s przy pomocy karty DAQ, NI PCI 6111. Przy tej szybkości próbkowania ilość danych jest ogromna, trudna do bieżącej obróbki, stąd rejestrowano jedynie po 0.05 sekundy (100 000 próbek) co 10 sekund obróbki. W tym samym czasie rozpoczynano rejestrację dwóch sygnałów sił skrawania (F_x i F_z), dwóch sygnałów drgań (V_y i V_z) oraz wartości skutecznej emisji akustycznej (AE_{RMS}), z szybkością próbkowania 30 ks/s przy użyciu karty DAQ, NI-PCI 6221. Te próbkowania trwały po 1.66 sekundy (50 000 próbek). Każde przejście obróbkowe trwało 96 sekund i było tu (z punktu widzenia diagnostyki stanu narzędzia) traktowane jak obróbka kolejnego przedmiotu (kolejna operacja). Z każdego przejścia do dalszych analiz wzięto osiem środkowych zarejestrowanych przebiegów sygnałów.

Z sygnałów w postaci cyfrowej (szeregów czasowych) wyznaczone są miary sygnałów, które opisują jego cechy związane z monitorowanym zjawiskiem. Miary te mogą być wyznaczone z sygnałów w dziedzinie czasu, z ich transformat w dziedzinie częstotliwości lub czasu i częstotliwości. Więcej szczegółów na temat stosowanych miar można znaleźć w [4],[8-9]. Ponieważ nie można z góry przewidzieć, jakie miary sygnałów (SF) będą przydatne do monitorowania stanu narzędzia w konkretnym przypadku, dlatego z dostępnych sygnałów należy wyznaczyć wiele miar, a następnie wybrać powiązane ze stanem narzędzia. W omawianych badaniach [7] z sześciu zarejestrowanych sygnałów wyznaczono pięć miar w dziedzinie czasu: wartość skuteczna (np. $F_{x,RMS}$), odchylenie standardowe (np. $F_{x,StDev}$), skośność (np. $F_{x,Skew}$), kurtoza (np. $F_{x,Kurt}$), współczynnik szczytu (np. $F_{x,Crest}$).

Wykorzystano szybką transformatę Fourier'a (FFT) do wyznaczenia ośmiu miar z dziedziny częstotliwości: częstotliwość dominująca (np. $F_{x,DF}$), moc częstotliwości dominującej (np. $F_{x,PDB}$), moc w 6 pasmach (np. $F_{x,P62-125}$, $F_{x,P2000-4000}$).

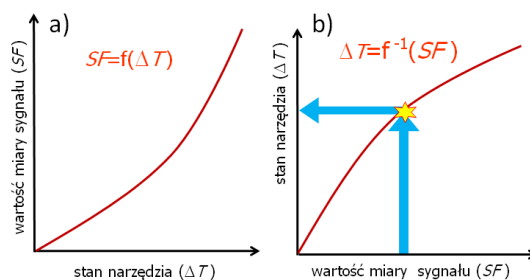
W ciągu ostatnich ok. 20 lat, transformata falkowa stała się jednym z nowych i szybko rozwijających się narzędzi matematycznych i przetwarzania sygnałów. Została ona wykorzystana m. in. do monitorowania rodzaju wióra [10]. Ostatnio transformata falkowa jest coraz częściej stosowana do monitorowania stanu narzędzia skrawającego, np. [11]. Pogłębioną analizę przydatności różnych typów falek przedstawiono w [12]. Zastosowana do omawianych badań trójpoziomowa Pakietowa Transformata Falkowa (WPT) pozwoliła uzyskać 14 współczynników falkowych, a z każdego z nich wyznaczono sześć miar w dziedzinie czasowo–częstotliwościowej: energia logarytmiczna (np. $F_{x,ADA,E}$), skośność (np. $F_{x,ADA,Skew}$), kurtoza (np. $F_{x,ADA,Kurt}$), wartość skuteczna (np. $F_{x,ADA,RMS}$), liczba przekroczeń poziomu progu (np. $F_{x,ADA,Count}$), szerokość przekroczeń (np. $F_{x,ADA,Pulse}$). W sumie wyznaczono automatycznie 582 miary sygnałów (97 z każdego z sygnałów, 194 z każdego z czujników). Ich przykłady przedstawiono na rysunku 4.



Rys. 4. Przykłady miar sygnałów wyznaczonych z dostępnych sygnałów w czasie wszystkich siedmiu okresów trwałości ostrza; skośność sygnału AE_{RMS} (a), odchylenie standardowe sygnału F_x (b) oraz energia współczynnika falkowego ADD sygnału V_y (c)

Fig. 4. Examples of signal features calculated from available signals during all 7 tool lives; skew of AE_{RMS} signal (a), standard deviation of F_x signal (b) and energy of WPT coefficient ADD of V_y signal (c)

Z pośród blisko 600 wyznaczonych miar, tylko niektóre są powiązane ze stanem narzędzia i mogą być wykorzystane do jego monitorowania. Ocena przydatności miar sygnałów zależy od dalszego ich wykorzystania i może być przeprowadzona na wiele różnych sposobów, patrz np. [13],[14]. Samo monitorowanie opiera się zawsze na jakimś modelu zależności miary od stanu narzędzia (rys. 5).



Rys. 5. Model zależności miary sygnału od stanu narzędzia (a), jego wykorzystanie w diagnostyce tego stanu (b)

Fig. 5. Model of signal feature dependence on tool condition (a), its usage in tool condition monitoring (b)

Model ten może być różny, np. zależność liniowa jak w równaniu (1), wielomian wyznaczany statystycznie itd. Układ diagnostyczny musi wyznaczyć tę zależność (parametry modelu), a następnie odwrócić go, by na podstawie wartości miary sygnału określać stan narzędzia (rys. 5b).

W pracach ZAOiOS stosowano różne modele zależności $SF(\Delta T)$, np. podział na klasy [13] czy aproksymacja wielomianem [14],[15]. Użyteczność miary do monitorowania stanu narzędzia skrawającego można określić przy pomocy współczynnika determinacji R_s^2 , który jest statystycznym wskaźnikiem na ile dobrze model odpowiada danym doświadczalnym, lub inaczej mówiąc, na ile model lepiej oddaje te dane niż średnia arytmetyczna. Jego ważną zaletą jest fakt, że w przeciwieństwie np. do współczynnika korelacji Pearsona, oceniającego zależność liniową, może być stosowany niezależnie od przyjętego modelu, nawet jeśli nie ma postaci funkcyjnej, a jest zapisany w postaci tablicy czy klas [13]. Opisany jest on zależnością:

$$R_s^2 = \frac{CSK - RSK}{CSK} \quad (2)$$

gdzie $CSK = \sum (y_i - \bar{y})^2$ – całkowita (pierwotna) suma kwadratów,

$RSK = \sum (y_i - \hat{y}_i)^2$ – reszkowa suma kwadratów,

y_i , \bar{y} , \hat{y}_i – pojedyncza, średnia i oszacowana na podstawie modelu wartość modelowanej zmiennej.

W układach ADONiS postanowiono nie zakładać żadnej postaci funkcyjnej, lecz za model rzeczywistej zależności miary od stanu narzędzia przyjąć jej przebieg filtrowany dolnoprzepustowo. W czasie pierwszego okresu trwałości ostrza układ wyznacza wartości wszystkich możliwych miar sygnałów i zapamiętuje je w funkcji numeru operacji (tu w funkcji numeru przejścia) $SF[NrOp]$. Obróbka prowadzona jest do chwili, gdy po wykonaniu kolejnej operacji (tu kolejnego przejścia) operator uzna narzędzie za stępione na podstawie kryteriów stosowanych przed zainstalowaniem układu diagnostycznego. Nie wprowadza przy tym żadnych wartości liczbowych. Po zakończeniu okresu trwałości ostrza układ przypisuje numerom wykonanych operacji wykorzystaną część okresu trwałości ostrza wg prostej zależności:

$$\Delta T = \frac{NrOp}{LicOp} \quad (3)$$

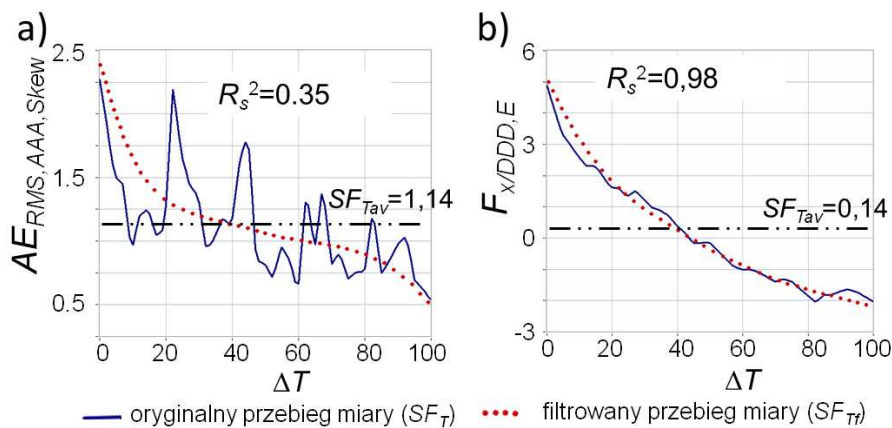
gdzie $NrOp$ – numer operacji, $LicOp$ – liczba operacji wykonanych do stępienia ostrza.

Ponieważ wyniki filtrowania dolnoprzepustowego zależą od liczby elementów szeregu czasowego składającego się na przebieg miary sygnału, przebiegi te są normalizowane w dziedzinie czasu, tj. przekształcane na tablicę 101 elementową (od 0 do 100), czyli tablice $SF[\Delta T]$ są przekształcane w tablice $SF_T[\Delta T]$. Dopiero takie szeregi czasowe są filtrowane dolnoprzepustowo w celu uzyskania tablic $SF_{TF}[\Delta T]$. Współczynnik determinacji, wskazujący na ile przebieg filtrowany oddaje oryginalny, znormalizowany w czasie, opisany jest zależnością:

$$R_s^2 = \frac{\sum_i (SF_{Ti} - SF_{Tav})^2 - \sum_i (SF_{Ti} - SF_{Tfi})^2}{\sum_i (SF_{Ti} - SF_{Tav})^2} \quad (4)$$

gdzie: $\sum_i (SF_{Ti} - SF_{Tav})^2$ – całkowita suma kwadratów, $\sum_i (SF_{Ti} - SF_{Tfi})^2$ – resztkowa suma kwadratów, SF_{Ti} oraz SF_{Tfi} to odpowiednio pojedyncze wartości SF_T oraz SF_{Tf} ($i=0..100$), SF_{av} jest średnią wartością SF_T .

Układ monitorujący stan narzędzia powinien być gotowy do pracy po zakończeniu pierwszego okresu trwałości ostrza, dlatego to oszacowanie jest oparte o sygnały zarejestrowane w czasie jego trwania. Miary dla których $R_s^2 > 0,4$ zostały uznane za wystarczająco powiązane ze stanem narzędzia (użyteczne do monitorowania). Przykłady miar zaakceptowanych i odrzuconych w ten sposób przedstawiono na rysunku 6.



Rys. 6. Przykłady miar sygnałów odrzuconych przez kryterium $R_s^2 > 0,4$ (a), zaakceptowanych przez nie (b)
Fig. 6. Examples of signal features rejected by the $R_s^2 > 0,4$ criterion (a), those which met the criterion (b)

Wybrane miary nie powinny być zbyt mocno powiązane ze sobą, aby nie zwielokrotnić tej samej informacji. W kolejnym kroku wybrane miary są sortowane malejąco względem wartości R_s^2 , a następnie wybierana jest pierwsza (najlepsza) i wyznaczany jest współczynnik korelacji Pearsona r^2 pomiędzy tą miarą i każdą następną. Miary dla których ten współczynnik jest wyższy niż 0.8 są odrzucone jako zbyt powiązane z najlepszą. Z pozostałych miar ponownie wybierana jest najlepsza i odrzucone miary z nią powiązane. Procedurę tą system powtarza do momentu, gdy nie pozostanie żadna miara spełniająca warunek $R_s^2 > 0,4$. W ten sposób, w omawianych badaniach, z pośród wszystkich 582 miar sygnałów, 133 zostały automatycznie wyselekcjonowane jako przydatne, lecz po eliminacji miar podobnych pozostało ich jedynie 40.

Po zakończeniu drugiego okresu trwałości ostrza, selekcja jest powtarzana z wykorzystaniem wszystkich zarejestrowanych danych. Współczynniki R_s^2 są obliczane dla dwóch okresów i uśredniane. Możliwe też jest wprowadzenie drugiego, nawet bardziej istotnego kryterium przydatności miar – powtarzalności. Jest ona określana przy wykorzystaniu drugiego współczynnika determinacji R_r^2 :

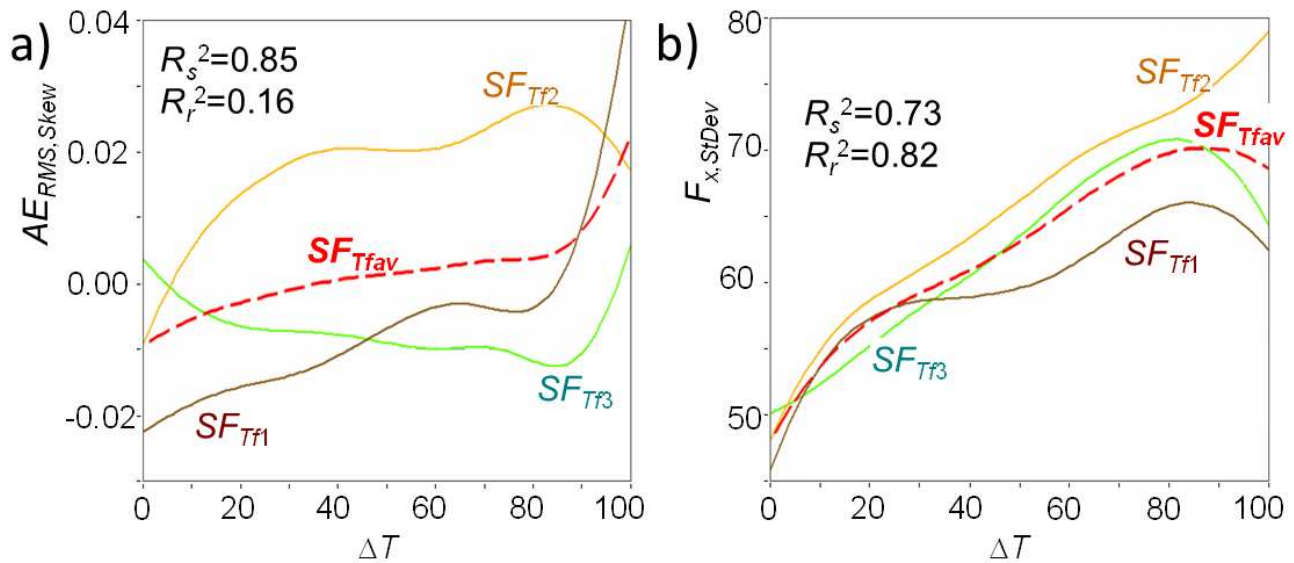
$$R_r^2 = \frac{\sum_j \sum_i (SF_{Tfji} - SF_{2Tfjav})^2 - \sum_j \sum_i (SF_{Tfji} - SF_{Tfavi})^2}{\sum_j \sum_i (SF_{Tfji} - SF_{2Tfjav})^2} \quad (5)$$

gdzie SF_{Tfji} – wartość SF_{Tf} w i -tym punkcie ($i=0..100$) i j -tym okresie trwałości ($j=1..2$),

$SF_{Tfavi} = \frac{1}{2} \sum_j SF_{Tfij}$ – średnia wartość SF_{Tf} w i -tym punkcie,


$SF_{2Tfjav} = \frac{1}{202} \sum_j \sum_i SF_{Tfij}$ – średnia wszystkich wartości SF_{Tf} dla dwóch okresów trwałości.

Miary, dla których $R_r^2 > 0.6$ uznawane są za wystarczająco powtarzalne. Na rysunku 7 przedstawiono przykłady miar zaakceptowanych i odrzuconych przez to kryterium. Warto zauważyć, że skośność wartości skutecznej emisji akustycznej ($AE_{RMS,Skew}$), która wg kryterium powiązania z ΔT ($R_s^2 > 0.4$) wypadła zupełnie nieźle, okazała się niepowtarzalna i została odrzucona. Wszystkie miary spełniające oba kryteria są sortowane malejąco względem R_r^2 . Eliminacja miar podobnych jest teraz oparta o dwa okresy trwałości. W omawianych badaniach, przydatne i powtarzalne okazały się 108 miary, lecz po eliminacji podobnych pozostało ich 39.



Rys. 7. Przykłady miar sygnałów odrzuconych (a), zaakceptowanych przez kryterium powtarzalności (b)
Fig. 7. Examples of signal features rejected by repeatability criterion (a), those which met the criterion (b)

Po zakończeniu trzeciego okresu trwałości ostrza, procedura jest powtarzana z wykorzystaniem wszystkich danych. Ostatecznie w cytowanych tu badaniach 62 miary zostały uznane za przydatne i powtarzalne, ale tylko 27 z nich jako niepowiązane wzajemnie. Szczegółowe wyniki selekcji miar zostały przedstawione na rysunku 8. Miary sygnałów wybrane w ten sposób są wykorzystywane do monitorowania czwartego i kolejnych okresów trwałości.



Rys. 8. Szczegółowe wyniki selekcji miar sygnałów
 Fig. 8. Detailed results of signal feature selection

4. INTEGRACJA MIAR, DIAGNOZA STANU NARZĘDZIA

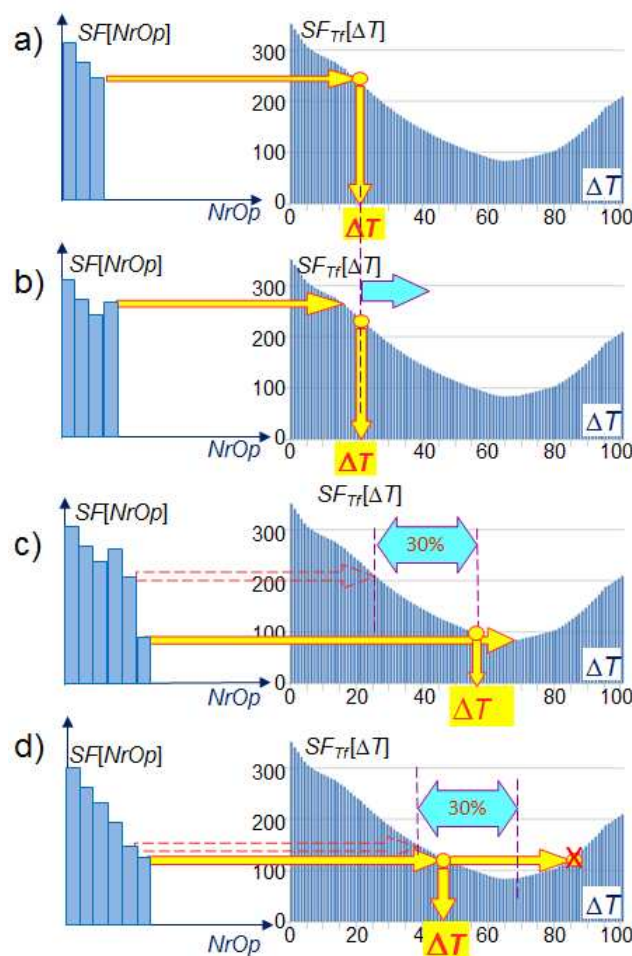
Miary sygnałów przydatne do diagnostyki stanu narzędzia, wyznaczone automatycznie, wg algorytmów opisanych wyżej, muszą zostać zintegrowane, to znaczy należy na ich podstawie określić stan narzędzia – wykorzystaną część okresu trwałości ostrza. Istnieje wiele metod takiej integracji, a szczególnie chętnie stosowane są metody sztucznej inteligencji jak sieci neuronowe czy logika rozmyta [13],[16-17]. W pracy [18] wykazano, że liczba danych uczących uzyskiwana w czasie jednego okresu trwałości ostrza jest zbyt mała w stosunku do wymaganej wielkości sieci koniecznej do odwzorowania złożonych zależności licznych miar od stanu narzędzia. Jeśli układ diagnostyczny ma wspierać operatora już po stąpieniu pierwszego ostrza, należy znaleźć inny sposób integracji miar. W budowanych obecnie w ZAOiOS układach ANONiS postanowiono zastosować algorytm hierarchiczny [18]. Składa się on z dwóch kroków.

W pierwszym kroku układ ocenia stan narzędzia na podstawie pojedynczych miar [19]. W czasie pierwszego okresu trwałości ostrza powstają tablice zależności $SF_{Tf}[\Delta T]$, będące modelami zależności miar od wykorzystanej części okresu trwałości ostrza (patrz wyżej). W trakcie obróbki następnymi narzędziami, układ podobnie jak w czasie uczenia, wyznacza wartości miar sygnałów w kolejnych operacjach. Tym razem jednak wyznacza także wykorzystaną część okresu trwałości ostrza przez wyszukanie w tablicy $SF_{Tf}[\Delta T]$, wartości miary najbliższej do uzyskanej w ostatniej operacji (rys. 9a). Może się zdarzyć, że wartość miary odpowiada niższej wartości wykorzystanej części okresu trwałości ostrza niż uzyskana w poprzedniej operacji. Takie wskazanie byłoby dezorientujące dla operatora. Stąd przyjęto, iż przeszukiwanie rozpoczyna się od ostatnio uzyskanej wartości, czyli wykorzystana część okresu trwałości pokazywana operatorowi nie może maleć (rys. 9b). Niekiedy zdarza się, iż wartość miary sygnału, w wyniku jakiegoś zakłócenia, odpowiada bardzo znacznemu przyrostowi zużycia ostrza. Aby ograniczyć skutki takich błędów, przeszukiwanie ograniczone jest do trzydziestu elementów tablicy $SF_{Tf}[\Delta T]$, czyli do 30% trwałości ostrza (rys. 9c). Oznacza to, iż w razie przyspieszonego zużywania się ostrza, układ pozwoli na wykonanie trzech operacji przed zasygnalizowaniem stąpienia ostrza. Procedura ta ma jeszcze jeden cel – umożliwia, do pewnego stopnia przynajmniej, wykorzystanie miar sygnału niemonotonicznych w funkcji wykorzystanej części okresu trwałości ostrza, jak to pokazano na rys. 9d.

W drugim kroku algorytmu hierarchicznego wszystkie wartości ΔT wyznaczone z pojedynczych miar są uśredniane, a wynik jest przyjmowany za aktualny stan narzędzia. Istotną zaletą algorytmu hierarchicznego jest możliwość zastosowania dowolnej liczby miar sygnałów, które zostały ocenione jako przydatne do diagnostyki. Ponadto w trakcie uśredniania możliwe jest odrzucanie wartości skrajnych, traktowanych jako przypadkowe zakłócenia.

Dokładność oszacowania stanu narzędzia przez układ może być oceniona z wykorzystaniem pierwiastka błędu średniokwadratowego (RMSE):

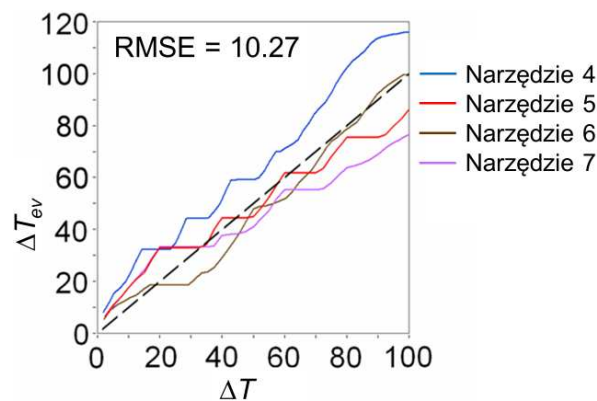
$$RMSE = \sqrt{\frac{1}{n} \sum_i (\Delta T_{ev} - \Delta T)^2} \quad (6)$$



Rys. 9. Ocena stanu narzędzia na podstawie pojedynczej miary sygnału
Fig. 9. Tool condition evaluation based on singular signal feature

Wartości ΔT są wyrażone w procentach, dlatego RMSE można traktować jako średni błąd procentowy. Wyniki uzyskane w omawianych badaniach dla ostrzy 4-7 (w czasie pierwszych trzech okresów trwałości układ był trenowany) przedstawiono na rys. 10. Jak widać błąd jest rzędu 10%. Nie jest to zły wynik, zważywszy bardzo niekorzystne warunki,

w jakich przyszło układowi diagnostycznemu działać, co objawia się bardzo trudnymi do wykorzystania miarami sygnałów (rys. 4).



Rys. 10. Wykorzystana część okresu trwałości ostrza oszacowana przez układ (ΔT_{ev}) w funkcji rzeczywistej (ΔT)
 Fig. 10. Used-up portion of the tool live evaluated by TCM system (ΔT_{ev}) vs. actual one (ΔT)

5. PODSUMOWANIE

Automatyczna diagnostyka ostrzy narzędzi skrawających oparta jest na wykorzystaniu miar wielkości fizycznych powiązanych z ich stanem – sił skrawania, drgań i emisji akustycznej. Zaawansowane metody przetwarzania sygnałów pozwalają na wyznaczenie ogromnej liczby miar sygnałów. Nie da się przewidzieć, które miary będą przydatne w konkretnym przypadku obróbkowym, dlatego z jednej strony zalecane jest wykorzystanie możliwie wielu miar pochodzących z możliwie wielu czujników, z drugiej zaś konieczna jest automatyczna selekcja miar przydatnych do diagnostyki. Przedstawiona, w pełni automatyczna, oryginalna metodyka selekcji miar jest oparta na:

- modelowaniu zależności miary sygnału od wykorzystanej części okresu trwałości ostrza poprzez filtrowanie dolnoprzepustowe przebiegu miary, które mogą być rosnące lub malejące, dodatnie lub ujemne, jak również w pewnym zakresie niemonotoniczne,
- klasyfikowaniu użyteczności miar przez współczynnik determinacji, obliczony pomiędzy miarą a modelem jej zależności od wykorzystanej części okresu trwałości ostrza oraz w oparciu o powtarzalność miar,
- eliminowaniu miar podobnych (powiązanych ze sobą).

Integrację dowolnej liczby miar sygnałów uznanych za przydatne można skutecznie przeprowadzić przy pomocy algorytmu hierarchicznego, w którym najpierw prowadzi się ocenę stanu narzędzia na podstawie każdej z miar oddzielnie, a następnie uzyskiwane wyniki uśrednia.

Przedstawione tu algorytmy zostały zaimplementowane w programach napisanych w środowisku LabVIEW i umożliwiają w pełni automatyczną diagnostykę stanu narzędzia. Zostały one przetestowane w omówionych tu trudnych warunkach obróbki stopów lotniczych, gdy liczba wykorzystanych okresów trwałości jest większa niż liczba wyprodukowanych przedmiotów. Testowano je także przy mikro frezowaniu materiału

narzędziowego [15] oraz przy toczeniu złożonych przedmiotów, gdy operacja składała się z wielu krótkich zabiegów [18].

W tym artykule przedstawiono główne osiągnięcia zespołu Zakładu Automatyk Obrabiarek i Obróbki Skrawaniem, na Wydziale Inżynierii Produkcji Politechniki Warszawskiej w zakresie diagnostyki stanu narzędzia. Pominięto jednakże zupełnie zagadnienia pomocnicze jak wykrywanie skrawania, segmentację sygnałów czy mające fundamentalne znaczenie wykrywanie katastroficznego stopienia ostrza, będące przedmiotem badań ZAOiOS od wielu lat [20],[21], a nowe rozwiązania wkrótce będą przedmiotem kolejnych publikacji.

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 (PO IG). Projekt współfinansowany przez Unię Europejską ze środków Europejskiego Funduszu Rozwoju Regionalnego.

LITERATURA

- [1] TLUSTY J., ANDREWS G.C., 1983, *A critical review of sensors for unmanned machining*, CIRP Annals - Manufacturing Technology, 32/2, 563-572.
- [2] TÖNSHOFF H. K., WULFSBERG J. P., KALS H. J. J., KÖNIG W., VAN LUTTENVELT C. A., 1988, *Developments and Trends in Monitoring and Control of Machining Processes*, CIRP Annals - Manufacturing Technology, 37/2, 611-622.
- [3] JEMIELNIAK K., KWIATKOWSKI L., 1987, *Emisja akustyczna w diagnostyce stanu narzędzia skrawającego*, Mechanik, 12, 563-567.
- [4] TETI R., JEMIELNIAK K., O'DONNELL G., DORNFELD D., 2010, *Advanced monitoring of machining operations*, CIRP Annals - Manufacturing Technology, 59/ 2, 717-739.
- [5] JEMIELNIAK K., 2002, *Automatyczna diagnostyka stanu narzędzia i procesu skrawania*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- [6] JEMIELNIAK K., 1999, *Commercial tool condition monitoring systems*, Int J Adv Manuf Technol, 15, 711-721.
- [7] JEMIELNIAK K., KOSSAKOWSKA J., URBAŃSKI T., BOMBIŃSKI S., 2012, *Tool condition monitoring based on numerous signal features*, Int J Adv Manuf Technol, 59, 73-81.
- [8] JEMIELNIAK K., 2001, *Some Aspects of Acoustic Emission Signal Pre-processing*, J Mat Proc Technol., 109/3, 242-247.
- [9] JEMIELNIAK K., 2011, *Przetwarzanie sygnałów w diagnostyce stanu narzędzia i procesu skrawania*, Archiwum Technologii Maszyn i Automatykacji, 31/2, 37-49.
- [10] TETI R., JAWAHIR I. S., JEMIELNIAK K., SEGRETTO T., CHEN S., KOSSAKOWSKA J., 2006, *Chip form monitoring through advanced processing of cutting force sensor signals*, CIRP Annals - Manufacturing Technology, 55/1, 75-80.
- [11] JEMIELNIAK K., KOSSAKOWSKA J., URBAŃSKI T., 2011, *Application of wavelet transform of acoustic emission and cutting force signals for tool condition, monitoring in rough turning of Inconel 625*, Proc. IMechE J Eng Manuf, 225B/1, 123-129.
- [12] 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.
- [13] 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*, J Intelligent Manufacturing, 9, 447-455.
- [14] BOMBIŃSKI S., JEMIELNIAK K., 2005, *Ocena przydatności miar sygnałów w diagnostyce stanu narzędzia*, Archiwum Technologii Maszyn i Automatykacji, 25/2, 201-210.
- [15] JEMIELNIAK K., BOMBIŃSKI S., ARISTIMUNO P. X., 2008, *Tool Condition Monitoring in Micromilling Based on Hierarchical Integration of Signal Measures*, CIRP Annals - Manufacturing Technology, 57/1, 121-124.
- [16] JEMIELNIAK K., 2003, *Tool Wear Monitoring by Means of Artificial Neural Networks*, Int J Manufacturing Science and Technology, 4/ 1, 28-43.

- [17] BALAZINSKI M., CZOGALA E., JEMIELNIAK K., LESKI J., 2002, *Tool condition monitoring using artificial intelligence methods*, Engineering Applications of Artificial Intelligence, 15, 73–80.
- [18] JEMIELNIAK K., BOMBIŃSKI S., 2006, *Hierarchical strategies in tool wear monitoring*, Proc. IMechE J Eng Manuf, 220B, 375-381.
- [19] JEMIELNIAK K., *Tool wear monitoring based on a non-monotonic signal feature*, Proc. IMechE J of Eng Manuf, 220/B2,163-170.
- [20] JEMIELNIAK K., 1992, *Detection of cutting edge breakage in turning*, CIRP Annals - Manufacturing Technology, 41/1, 91-100.
- [21] JEMIELNIAK K., OTMAN O., 1998, *Catastrophic tool failure detection based on acoustic emission signal analysis*, CIRP Annals - Manufacturing Technology, 47/1, 31-34.

AUTOMATIC TOOL CONDITION MONITORING

This paper presents principles of tool condition monitoring systems development, beginning from their logical scheme, through employing physical phenomena and sensors, signal processing up to signal feature integration into the final tool condition estimation. Tool condition monitoring systems ADONiS built in the Chair of Automation, Machine Tool and Metal Cutting were taken as an example. Thus main achievements of the Chair in TCM were presented.