

Diagnostyka stanu narzędzi i procesu skrawania

Tool and process condition monitoring

KRZYSZTOF JEMIELNIAK*

DOI: <https://doi.org/10.17814/mechanik.2017.7.64>

Automatyczna diagnostyka stanu narzędzi i procesu skrawania jest oparta na pomiarach wielkości fizycznych skorelowanych z tym stanem. Z każdego sygnału da się wyznaczyć bardzo wiele miar i nie można przewidzieć, które z nich będą przydatne w określonym przypadku. Miary te muszą być zatem wybierane automatycznie, a następnie integrowane w jedno oszacowanie stanu, np. z wykorzystaniem metod sztucznej inteligencji.

SŁOWA KLUCZOWE: diagnostyka stanu narzędzia, obróbka sygnałów

Automatic tool condition monitoring is based on the measurements of physical phenomena which are correlated with this condition. There are numerous signal features (SFs) that can be extracted from the signal. As it is really not possible to predict which signal features will be useful in a particular case they should be automatically selected and combined into one tool condition estimation. This can be achieved by various artificial intelligence methods.

KEYWORDS: tool condition monitoring, signal processing

Dążenie do coraz większej niezawodności procesów produkcyjnych stwarza potrzebę ich ciągłego monitorowania. Automatyczna diagnostyka narzędzi i procesu skrawania (DNIiPS) staje się więc nieodzownym elementem zapewnienia wysokiej jakości produktów i niskich kosztów. System diagnostyczny powinien umożliwiać wykrycie katastroficznego stępienia ostrza (KSO) czy nadmiernego zużycia narzędzia oraz jego wymianę na nowe w odpowiednim czasie, a także zidentyfikowanie innych nieprawidłowości, takich jak niepożądana postać wiórowych drgań samowzbudne. Istnieje wiele obszernych przeglądów stanu zagadnienia, np. [21], prezentujących różnorodne idee i podejścia zmierzające do rozwiązania problemu automatycznej diagnostyki. Mimo to problem wciąż jest daleki od rozwiązania, ponieważ istniejące systemy są oparte na mglistych, niepełnych i losowo zakłóconych danych,

pochodzących z czujników mierzących zjawiska występujące w strefie skrawania.

Celem niniejszego artykułu jest skrótowne przedstawienie problematyki automatycznego monitorowania, diagnostyki oraz nadzoru stanu narzędzia i procesu skrawania. Pojęcia z zakresu tego zagadnienia czasem są używane zamiennie, a czasem są mylone, dlatego uporządkowano je na rys. 1.

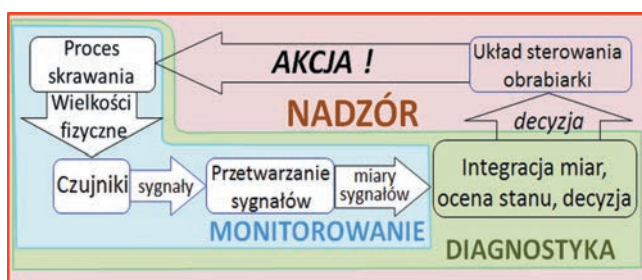
Wielkości fizyczne i czujniki stosowane w DNIiPS

Zużycie narzędzia skrawającego powoduje ubytek materiału ostrza i w konsekwencji zmiany jego geometrii, które z kolei pociągają za sobą zmiany sił skrawania i wielkości pochodnych (momentu, mocy silnika, odkształceń elementów obrabiarki lub narzędzia). Z tego względu to właśnie siły skrawania najczęściej wykorzystuje się w DNIiPS. W przypadku toczenia, gwintowania oraz innej obróbki – głównie z użyciem małych narzędzi trzpieniowych – stosuje się czujniki sił i momentów skrawania. Przy frezowaniu, zwłaszcza wieloosiowym, zainstalowanie czujnika sił jest znacznie utrudnione ze względu na złożone ruchy narzędzia i przedmiotu, dlatego stosunkowo chętnie stosowane są czujniki mocy silnika [11].

Emisja akustyczna AE (*acoustic emission*) to powstawanie i rozchodzenie się zanikających fal sprężystych, będące efektem gwałtownego wyzwolenia energii wiązań wewnętrznych naruszanych przez odkształcenia, pęknięcie itd. W strefie skrawania istnieje bardzo wiele źródeł AE, takich jak: pęknięcie materiału obrabianego, wióra i narzędzia; tarcie narzędzia o przedmiot obrabiany oraz wióra o powierzchnię natarcia; ścinanie i plastyczna deformacja materiału obrabianego [10, 12]. Wbrew nieco mylącej nazwie częstotliwości AE wykorzystywane w DNIiPS zaczynają się od ok. 80 kHz i sięgają 1 MHz, a więc są bardzo wysokie – znacznie wyższe od pasma słyszalnego (20 Hz ÷ 20 kHz), a także od pasma sił skrawania czy drgań. Podobnie jak dźwięk, AE rozchodzi się w ciałach stałych i cieczach zgodnie z wszelkimi prawami załamania i odbicia, jednak powietrze jest dla emisji barierą. Emisja jest bardzo silna nawet przy niewielkim przekroju warstwy skrawanej i prawie niezauważalnych siłach skrawania. Z tego względu AE wykorzystuje się w przypadku małych naddatków oraz wszędzie tam, gdzie trudno jest zainstalować czujnik sił.

Najbardziej stosowaną wielkością są drgania mechaniczne [4], przydatne zwłaszcza przy wierceniu małych otworów. Jak wiadomo, wiertło stępione piszczy, czyli drga z wysoką częstotliwością (rzędu kilku kHz).

Czujniki używane w układach DNIiPS są z reguły specjalnie do tych układów przeznaczone – przystosowane do trudnych warunków panujących w strefie skrawania, a więc odporne na oddziaływanie chłodziwa i uderzające wióry. W tabelicy zestawiono typy czujników oferowanych przez czołowych producentów komercyjnych układów DNIiPS.



Rys. 1. Struktura układu monitorowania, diagnostyki oraz nadzoru stanu narzędzia i procesu skrawania [6]

* Prof. dr hab. inż. Krzysztof Jemielniak (k.jemielniak@wip.pw.edu.pl) – Zakład Automatykacji i Obróbki Skrawaniem, Wydział Inżynierii Produkcji Politechniki Warszawskiej

TABLICA. Czujniki stosowane w handlowych układach DNiPS

Wielkość fizyczna (typ czujnika)		Producent układów DNiPS					
		Artis	Bran- kamp	Kistler	Montro- nix	Nord- mann	Prome- tec
Siła i wielkości pochodne	Moc	○	○		○	○	○
	Moment skręcający	○		○	○		
	Odształcenie		○	○	○		○
	Dystans					○	○
	Czujnik sił	○	○	○	○		○
	Płyta pomiarowa			○	○		○
AE	Emisja akustyczna	○	○	○	○	○	○
	Cieczowy czujnik AE					○	○
	Obrotowy czujnik AE	○				○	○
Inne	Drgania i dźwięk			○	○		○
	Kamera	○	○				
	Laser	○				○	

Przetwarzanie sygnałów w DNiPS

W diagnostyce stanu narzędzi i procesu skrawania stosuje się całe bogactwo technik obróbki sygnałów znanych z innych dziedzin, w tym ogólnej diagnostyki maszyn. Tu zostały poruszone tylko niektóre aspekty tej obróbki charakterystyczne dla DNiPS.



Rys. 2. Ogólny schemat przetwarzania sygnałów w DNiPS

■ **Wstępne przygotowanie sygnału.** Sygnały analogowe pochodzące z czujnika są zazwyczaj poddawane wstępnej obróbce analogowej, np. filtrowaniu w celu wyeliminowania zakłóceń lub wybrania interesującego pasma częstotliwościowego sygnału czy wzmacnianiu dopasowującemu zakres sygnału do przetwornika A/C. Sygnały wstępnie obróbrane analogowo są zamieniane na postać cyfrową i poddawane dalszemu przetwarzaniu w celu wyznaczenia cech (miar) sygnału mogących posłużyć jako symptomy. Nie da się jednak prowadzić automatycznej diagnostyki na całych (ciągłych) przebiegach sygnałów z czujników, gdyż obejmują one sygnały zebrane w czasie ruchów szybkich oraz dobiegu i wybiegu narzędzia. Konieczne jest zatem automatyczne wybranie fragmentów pochodzących wyłącznie ze skrawania. Najprostszym i najczęściej stosowanym sposobem identyfikacji skrawania jest wykrywanie przekroczenia przez sygnał założonej przez operatora wartości granicznej w wybranym przez niego oknie czasowym. Ten sposób jest niewygodny, podatny na zakłócenia i ludzkie błędy oraz nieskuteczny w przypadku sygnałów opadających, co się czasem zdarza. Skuteczniejsze jest wykorzystanie filtrowanych dolnoprzepustowo wszystkich dostępnych

sygnałów i ich odchyłeń standardowych oraz wykrywanie skrawania na podstawie integracji tych miar [3]. Ponadto diagnostyka online wykonana na podstawie długich fragmentów sygnału jest niemożliwa dla współczesnych komputerów ze względu na konieczność analizy dużej liczby (nawet kilkuset) miar. Z drugiej strony do określenia stopnia zużycia narzędzia wystarczające jest analizowanie krótkich wycinków sygnałów. Najbardziej nadają się segmenty sygnału pochodzące z odcinków o ustalonej wartości. Miarą zmienności segmentu B sygnału – tj. wskaźnikiem określającym, na ile jego wartość skuteczna różni się od sąsiadujących fragmentów A i C – może być wartość współczynnika F_{LB} [3]:


$$F_{LB} = \left| \frac{\text{RMS}[A]}{\text{RMS}[B]} - 1 \right| + \left| \frac{\text{RMS}[C]}{\text{RMS}[B]} - 1 \right| \quad (1)$$

Cały sygnał zarejestrowany w czasie skrawania jest więc dzielony na sekundowe segmenty, z których wybiera się odpowiednią (niewielką) liczbę segmentów najmniej różniących się od swoich sąsiadów.

■ Wyznaczanie miar sygnałów w dziedzinie czasu.

Ze wstępnie przygotowanych, ograniczonych do samego skrawania fragmentów sygnału cyfrowego wyznacza się miary w dziedzinie czasu. Najczęściej stosowane to: średnia, amplituda, zakres, współczynnik szczytu, wartość skuteczna, wariancja (lub odchylenie standardowe), skośność, kurtoza, moc, stosunek lub przyrosty sygnałów. Niektóre miary używane są zwykle do sygnałów drgań i AE – są to liczba lub tempo impulsów bądź wybuchów oraz szerokość impulsów lub wybuchów (procent czasu powyżej progu) [10]. Istnieją także techniki modelowania szeregów czasowych: autokorelacja (AR), ruchoma średnia (MA) oraz połączenie tych technik (ARMA) [15]. Jako miary sygnału wykorzystuje się współczynniki AR, MA lub ARMA pierwszego lub pierwszego i drugiego rzędu, rzadziej trzeciego, czwartego i piątego rzędu [20]. Współcześnie ma niekiedy zastosowanie analiza głównych składowych PCA (*principal component analysis*) oraz analiza widma osobliwego SSA (*singular spectrum analysis*). PCA to jedna ze statystycznych metod analizy czynnikowej, szeroko wykorzystywana do identyfikacji i redukcji wymiarowości systemów. Zbiór danych składający się z N obserwacji, z których każda obejmuje K zmiennych, można interpretować jako chmurę N punktów w przestrzeni K -wymiarowej. PCA polega na takim obrocie układu współrzędnych, który maksymalizuje wariancję pierwszej współrzędnej, następnie wariancję drugiej współrzędnej itd. Przekształcone wartości współrzędnych nazywane są ładunkami wygenerowanych czynników (składowych głównych). Shi i Gindy [18] wykorzystali sygnały dwóch prostopadłych składowych sił skrawania przy przeciąganiu do diagnostyki zużycia ostrza. Wyniki pomiarów tworzyły charakterystyczne, zniekształcone elipsy w przestrzeni 2D o kształcie i położeniu wyraźnie skorelowanym ze zużyciem (rys. 3). Za pomocą PCA wyznaczono: długości osi (a/b) i nachylenie elipsy (β). Środki elips to średnie wartości sił. Miary sygnałów przyjęte do diagnostyki to: $F_{y,\dot{s}r}$, $F_{z,\dot{s}r}$, a , b , β .

SSA to technika nieparametrycznej analizy szeregów czasowych. Polega na rozkładzie sygnału na trzy niezależne składowe: wolnozmienny trend reprezentujący lokalną średnią, różnicę między sygnałem a średnią (składową oscylacyjną) oraz szum pozbawiony jakiegokolwiek struktury [13]. Te trzy składowe traktuje się jak nowe sygnały i wyznacza z nich omówione wcześniej podstawowe miary (np. średnią, wariancję, RMS, skośność, kurtozę).



Rys. 3. Wykresy kołowe sygnałów sił skrawania w różnych stadiach zużycia ostrza [17]

Kolejną interesującą miarą złożoności szeregów czasowych, stosowaną w DNiPS, jest entropia permutacji [11]. Im mniejsza jest entropia permutacji, tym bardziej regularny szereg czasowy. Z szeregu czasowego $x[i]$, $i = 1 \dots n$ można otrzymać $n!$ permutacji π (ustawień w różnej kolejności). Entropię permutacji takiego szeregu definiuje zależność:

$$H_p(n) = \sum_{i=1}^{n!} p(\pi_i) \ln p(\pi_i) \quad (2)$$

gdzie: $p(\pi_i)$ – względna częstość występowania permutacji π_i .

Znormalizowana entropia permutacji jest wtedy opisana wzorem:

$$H_p = \frac{H_p(n)}{\ln(n!)} \quad (3)$$

Li i in. [11] wykorzystali tę miarę do wykrywania KSO na podstawie sygnału silnika przy frezowaniu palcowym. W czasie normalnego skrawania sygnał jest regularnie okresowy, a H_p niska. Po wystąpieniu KSO regularność ta znacznie spada, czemu towarzyszy skok wartości H_p .

■ **Wyznaczanie miar sygnałów w dziedzinie częstotliwości lub czasu i częstotliwości.** Sygnały cyfrowe w dziedzinie czasu mogą być przekształcone do dziedziny częstotliwości lub czasu i częstotliwości. Miary sygnałów w dziedzinie częstotliwości z reguły są oparte na jednym z wielu dostępnych algorytmów – szybkiej transformacji Fouriera (FFT), która przekształca szereg czasowy o N elementach $x[n]$, $n = 0 \div (N - 1)$, na dyskretną reprezentację w dziedzinie częstotliwości $X[m]$, $m = 0 \div (N - 1)$:

$$X[m] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi nm/N} \quad (4)$$

Bezpośrednie zastosowanie współczynników Fouriera $X[m]$ jest niepraktyczne zarówno ze względu na ich znaczną liczbę, jak i przeciek widma. Wyznacza się zatem miary tej transformaty: amplitudę dominujących składowych, moc lub energię w wybranych pasmach, średnią częstotliwość, a także omówione wcześniej miary, które wykorzystuje się do sygnałów z dziedziny czasu

[4, 10, 20]. Mimo że sygnały pochodzące ze strefy skrawania są z reguły niestacjonarne, FFT uśrednia składowe częstotliwościowe po czasie trwania sygnału, ze stałą rozdzielczością równą odwrotności tego czasu. W celu uwzględnienia zmienności widma w czasie stosuje się analizę czasowo-częstotliwościową, np. krótkookresową transformatę Fouriera (STFT), w której okno $w[n]$ jest przemieszczane wzdłuż osi czasu, dzięki czemu kolejne transformaty FFT przedstawiają zmiany składowych częstotliwościowych w kolejnych krótkich odcinkach czasu. Marinescu i Axinte [12], którzy zastosowali sygnały AE do wykrywania KSO przy frezowaniu, posłużyli się STFT w celu precyzyjnego określenia momentu rozpoczęcia i kończenia skrawania poszczególnymi ostrzami, czyli do segmentacji sygnału.

STFT jako metoda analizy czasowo-częstotliwościowej ma zasadniczą wadę: długość okna decyduje o rozdzielczości w obu dziedzinach – czasu i częstotliwości. Obie nie mogą być arbitralnie duże i poprawa jednej odbija się na pogorszeniu drugiej. Problemowi temu wychodzi naprzeciw transformata falkowa (WT), w której wysokie częstotliwości są analizowane wąskimi oknami dla lepszej rozdzielczości w dziedzinie czasu, a niskie – szerokimi oknami, co daje lepszą rozdzielczość w dziedzinie częstotliwości. Dyskretna transformata falkowa (DWT) rozkłada sygnał na współczynniki skali (tzw. aproksymacje A) i współczynniki falkowe (tzw. detale D) przy pomocy filtrów dolno- i górnoprzepustowego. Odpowiedzi filtrów są dwójkowane (brana jest co druga próbka). Aproksymacja pierwszego poziomu A_1 jest ponownie rozkładana na A_2 i D_2 . Ogólnie aproksymację A_{j+1} i detal D_{j+1} można opisać jako:

$$A_{j+1}[n] = \sum_{k=-\infty}^{\infty} (A_j[k] h[2n - k]) \quad (5)$$

$$D_{j+1}[n] = \sum_{k=-\infty}^{\infty} (A_j[k] g[2n - k]) \quad (6)$$

gdzie h i g to odpowiedzi impulsowe filtrów dolno- i górnoprzepustowego (funkcji skalującej i falki).

Innym typem WT jest pakietowa transformata falkowa (WPT), w której dalszej dekompozycji podlega nie tylko aproksymacja, lecz także detal. Pozwala to na uzyskanie większej liczby użytecznych miar sygnałów. Podobnie jak w przypadku transformaty Fouriera z reguły nie korzysta się bezpośrednio ze współczynników falkowych, lecz wyznacza z nich miary stosowane do sygnałów z dziedziny czasu.

Kolejną, stosunkowo nową metodą analizy czasowo-częstotliwościowej, używaną w DNiPS, jest transformata Hilberta-Huanga – HHT (*Hilbert-Huang transform*), przydatna zwłaszcza do sygnałów niestacjonarnych i nieliniowych, które mogą się zmieniać nawet w ramach jednego okresu oscylacji sygnału. W przeciwieństwie do STFT czy WT metoda HHT jest raczej algorytmem (ze względu na podejście empiryczne) niż narzędziem teoretycznym. Wykorzystuje dwie techniki przetwarzania sygnałów (dwa kroki):

- empiryczną dekompozycję sygnału na nieliniowe składowe modalne (w przeciwieństwie do typowych składowych harmonicznych funkcje te mogą mieć zmienną amplitudę oraz częstotliwość w dziedzinie czasu),
- transformatę Hilberta, która wyznacza zmiany amplitudy i częstotliwości składowych sygnału w czasie oraz tworzy wynikowy rozkład czasowo-częstotliwościowy (spektrum Hilberta).

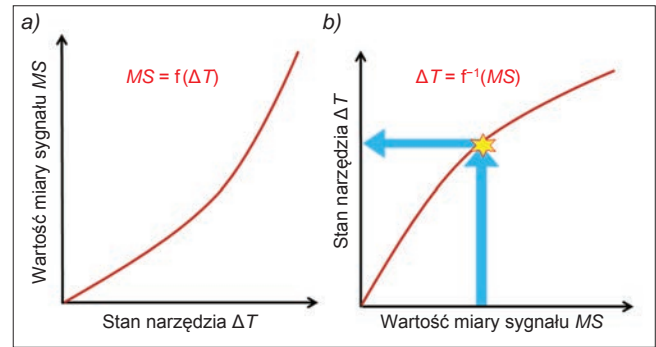
Peng [13] zastosował tę metodę do wykrywania KSO na podstawie sygnałów sił skrawania we frezowaniu. KSO może być wykrywane bezpośrednio w spektrum Hilberta lub za pośrednictwem składowych modalnych związków z charakterystycznymi dla frezowania częstotliwościami. Po wystąpieniu KSO energia charakterystycznych składowych zmienia się w przeciwnym kierunku, inaczej niż po zmianie parametrów skrawania.

■ **Selekcja miar sygnałów.** Ponieważ w ogólnym przypadku nie jest możliwe wiarygodne monitorowanie stanu narzędzia i procesu skrawania na podstawie pojedynczej miary sygnału, a ponadto nie da się z góry przewidzieć, które miary sygnałów będą przydatne w konkretnym zastosowaniu, powszechnie uważa się, że wyznaczanie odpowiednio dużej liczby miar jest kluczowym zagadnieniem w każdym układzie DNiPS. Liczba wybranych miar sygnałów musi być na tyle duża, aby skompensować przypadkowe zakłócenia (które są nieuniknione), a z drugiej strony konieczne jest usunięcie miar zbędnych lub nieskorelowanych z procesem. O ile wyznaczenie miar sygnałów jest zagadnieniem dość dobrze znanym z wielu innych zastosowań, o tyle wybór miar przydatnych jest często niedoceniany, mimo że jego znaczenie dla efektywności systemu diagnostyki jest ogromne. W zastosowaniach przemysłowych wybór miar musi być prowadzony automatycznie, bez udziału, a nawet bez wiedzy operatora. Tymczasem jak wynika z bardzo interesującej klasyfikacji procedur wyboru miar do diagnostyki zużycia ostrza przy toczeniu, przedstawionej przez Sicka [19], w 38% ze 138 przeanalizowanych publikacji miary sygnałów były wybierane bez żadnego uzasadnienia (lub w oparciu o dane literaturowe), w 26% były definiowane po analizie zmierzonych sygnałów, a w 21% najbardziej użyteczne miary były wybierane bez uwzględnienia wynikającej z nich oceny zużycia ostrza. Jedynie w 15% analizowanych publikacji optymalny zestaw miar był określany po przeanalizowaniu wpływu tego wyboru na ocenę zużycia ostrza.

W laboratoryjnych układach diagnostyki jako wskaźniki zużycia ostrza z reguły są używane geometryczne miary tego zużycia (szerokość starcia powierzchni przyłożenia VB_B lub głębokość krateru KT). Jednakże w warunkach przemysłowych takie wskaźniki są stosowane rzadko. Z tego powodu w [7] zaproponowano, by miarą zużycia ostrza była wykorzystana część jego trwałości (ΔT), definiowana jako stosunek dotychczasowego czasu skrawania (t) do całego okresu trwałości (T): $\Delta T = t/T$. Uniezależnia to ocenę stanu narzędzia od wskaźnika zużycia, umożliwia korzystanie z kilku wskaźników jednocześnie lub ze wskaźników dyskretnych, oznaczających stopień ostrza, pojawienie się zadziórów, wykruszenia, wyłamań ostrza itd. [9].

Ocena przydatności miar sygnałów (MS) zależy od ich dalszego wykorzystania i może być przeprowadzona na wiele sposobów. Samo monitorowanie opiera się zawsze na jakimś modelu zależności miary od stanu narzędzia (rys. 4). Modelem może być np. aproksymacja wielomianem drugiego lub trzeciego stopnia czy przebieg filtrowany dolnoprzepustowo. Układ diagnostyczny musi wyznaczyć tę zależność (parametry modelu), a następnie odwrócić ją, by na podstawie wartości miary sygnału określić stan narzędzia (rys. 4b).

Niektórzy badacze (np. [15,16]) do znalezienia miar najlepiej charakteryzujących zużycie ostrza stosowali współczynnik korelacji r Pearsona między miarą a wartością zużycia – zakładając, że im niższa jego wartość, tym



Rys. 4. Model zależności miary sygnału od stanu narzędzia (a) i jego wykorzystanie w diagnostyce tego stanu (b)

mniejsza szansa, że miara wykaże jakąkolwiek zależność od zużycia ostrza. Ignorowany jest przy tym fakt, że nawet jeśli miara jest doskonale skorelowana ze zużyciem, lecz korelacja jest nieliniowa, współczynnik korelacji $r < 1$.

W celu uniknięcia niepewności związanej z modelowaniem zależności miary od stanu narzędzia w [9] zaproponowano wykorzystanie współczynnika determinacji R_s^2 . Wskazuje on, na ile dowolny model oddaje wartości doświadczalne, lub – innymi słowy – na ile ten model zależności miary sygnału MS od stanu narzędzia lepiej opisuje rzeczywisty przebieg miary niż jej wartość średnia \overline{MS} . Współczynnik determinacji wyraża się zależnością:

$$R_s^2 = \frac{CSK - RSK}{CSK} = \frac{\sum_i (MS_i - \overline{MS})^2 - \sum_i (MS_i - MS_{mi})^2}{\sum_i (MS_i - \overline{MS})^2} \quad (7)$$

gdzie: $CSK = \sum_i (MS_i - \overline{MS})^2$ – całkowita suma kwadratów; $RSK = \sum_i (MS_i - MS_{mi})^2$ – resztkowa suma kwadratów; $CSK - RSK = ZNK$ – zniesiona suma kwadratów; MS_i, MS_{mi} – kolejne wartości zmierzonych i zamodelowanych wartości miary w znormalizowanych punktach wykorzystanej części okresu trwałości ostrza ($i = 0 \div 100$); \overline{MS} – średnia wartość miary.

Akceptuje się miary, dla których wartość R_s^2 jest wyższa od założonego progu, np. $R_s^2 > 0,4$.

Układ monitorujący stan narzędzia powinien być gotowy do pracy po zakończeniu pierwszego okresu trwałości. Niemniej jednak po zakończeniu drugiego okresu trwałości ostrza selekcję można powtórzyć z wykorzystaniem wszystkich zarejestrowanych danych. Współczynniki R_s^2 są wtedy obliczane dla dwóch okresów i uśredniane. Możliwe jest również wprowadzenie drugiego, nawet bardziej istotnego kryterium przydatności miar – powtarzalności. Jest ona określana z wykorzystaniem drugiego współczynnika determinacji R_r^2 , w którym porównuje się modele stworzone automatycznie na podstawie pierwszego i drugiego okresu trwałości:

$$R_r^2 = \frac{\sum_j \sum_i (MS_{mji} - \overline{MS}_{2m})^2 - \sum_j \sum_i (MS_{mji} - \overline{MS}_{mi})^2}{\sum_j \sum_i (MS_{mji} - \overline{MS}_{2m})^2} \quad (8)$$

gdzie: MS_{mji} – wartość zamodelowanej wartości miary MS_m w i -tym punkcie ($i = 0 \div 100$) i j -tym okresie trwałości ($j = 1 \div 2$), $\overline{MS}_{mi} = \frac{1}{2} \sum_j MS_{mji}$ – średnia wartość modelu MS_m w i -tym punkcie, $\overline{MS}_{2m} = \frac{1}{202} \sum_j \sum_i MS_{mji}$ – średnia wszystkich wartości MS_m dla dwóch okresów trwałości.

Miary, dla których R_r^2 jest wyższe od założonego progu (np. $R_r^2 > 0,6$), są uznawane za wystarczająco powtarzalne. Oczywiście procedurę można powtórzyć po trzecim okresie trwałości.

Al-Habaibeh i Gindy [1] wyszukiwali miary sygnałów zależne od stanu frezu, stosując średnie wartości zależności otrzymane z ortogonalnych macierzy Taguchiego, jako wskaźniki przydatności kombinacji miar z określonego czujnika, do wykrywania stępienia narzędzia (im silniejsza zależność, tym czujnik jest bardziej przydatny). Sun i in. [20] identyfikowali najbardziej przydatne miary za pomocą modelu Bayesowskiego i metody wektorów nośnych SVM (*support vector machine*). Oceniano błąd oceny stanu narzędzia modelowanego z zastosowaniem wybranej miary ze stanem rzeczywistym (ostre – stępione), a najgorsze miary były eliminowane.

Inny sposób weryfikacji przydatności miar to współczynnik statystycznego pokrywania się SOF (*statistical overlap factor*), określający stopień separacji wartości miar odpowiadających narzędziom ostrym i stępionym [17]. Współczynnik ten jest definiowany jako:

$$SOF = \frac{|\overline{MS}_1 - \overline{MS}_2|}{(\sigma_1 + \sigma_2)/2} \quad (9)$$

gdzie: $\overline{MS}_1, \sigma_1, \overline{MS}_2, \sigma_2$ – odpowiednio średnie i odchylenia standardowe wartości miar dla narzędzia ostrego (1) i stępionego (2).

Autorzy [17] zauważyli, że przy automatycznej selekcji miar często wybierane są miary zbyt bliskie lub podobne jedna do drugiej, co przeczy celowi, jakim jest integracja różnych miar. W takich przypadkach zalecili oni „inżynierską ocenę”, co ogranicza automatyzm wyboru i zmusza do ręcznej interwencji operatora, czy raczej naukowca. Taka procedura nie jest do zaakceptowania w warunkach przemysłowych, dlatego w [9] miary, które spełniły warunek powiązania ze stanem ostrza ($R_s^2 > 0,4$), posortowano malejąco względem wartości R_s^2 , a następnie wybrano pierwszą (najlepszą) i obliczono współczynnik korelacji Pearsona r^2 pomiędzy tą miarą i każdą następną. Miary, dla których $r^2 > 0,8$, odrzucono jako zbyt powiązane z najlepszą. Z pozostałych miar ponownie wybrano najlepszą i odrzucono miary z nią powiązane.

Binsaeid i in. [2] również oceniali przydatność miary na podstawie korelacji pojedynczej miary ze stanem ostrza oraz korelacji między miarami. Współczynnik przydatności miary określali zależnością:

$$m = \frac{N\bar{r}_{cf}}{\sqrt{N+N(N-1)\bar{r}_{ff}}} \quad (10)$$

gdzie: N – liczba miar, \bar{r}_{cf} , \bar{r}_{ff} – średnia korelacja miara–stan narzędzia oraz miara–miara.

Korelację badano miarami entropii. Wysoki wynik osiągają miary dobrze skorelowane ze stanem narzędzia, a jednocześnie słabo skorelowane między sobą.

Integracja miar, ocena stanu

Miary sygnałów przydatne do diagnostyki stanu narzędzia, wyznaczone automatycznie według opisanych wcześniej algorytmów, muszą zostać zintegrowane, co oznacza, że na ich podstawie należy określić stan narzędzia – wykorzystaną część okresu trwałości ostrza. Istnieje wiele metod takiej integracji, np.: modelowanie statystyczne, metody autoregresji, metody rozpoznawania wzorców czy metody systemów eksperckich. Chętnie stosowane są zwłaszcza metody sztucznej inteligencji, takie jak: sieci neuronowe, algorytmy genetyczne czy lo-

gika rozmyta, a także hybrydy tych metod [5, 21]. Najpopularniejsze są sieci neuronowe, a wśród nich perceptron wielowarstwowy z metodą propagacji wstecznej błędów [22]. Z reguły wykorzystuje się pojedynczą sieć neuronową, na której wejścia podawane są wybrane miary sygnałów, a na wyjściu otrzymuje się oszacowanie wybranego wskaźnika zużycia ostrza. W [8] 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. Podobnie jest z innymi metodami sztucznej inteligencji – duża liczba miar wymaga dużej liczby danych uczących dostępnych dopiero po kilku czy nawet kilkunastu okresach trwałości. Problem ten można rozwiązać, stosując algorytmy hierarchiczne [8, 9], w których najpierw ocenia się stan narzędzia na podstawie każdej wybranej miary lub kilku miar oddzielnie, a następnie integruje się otrzymane oceny, np. przez uśrednianie.

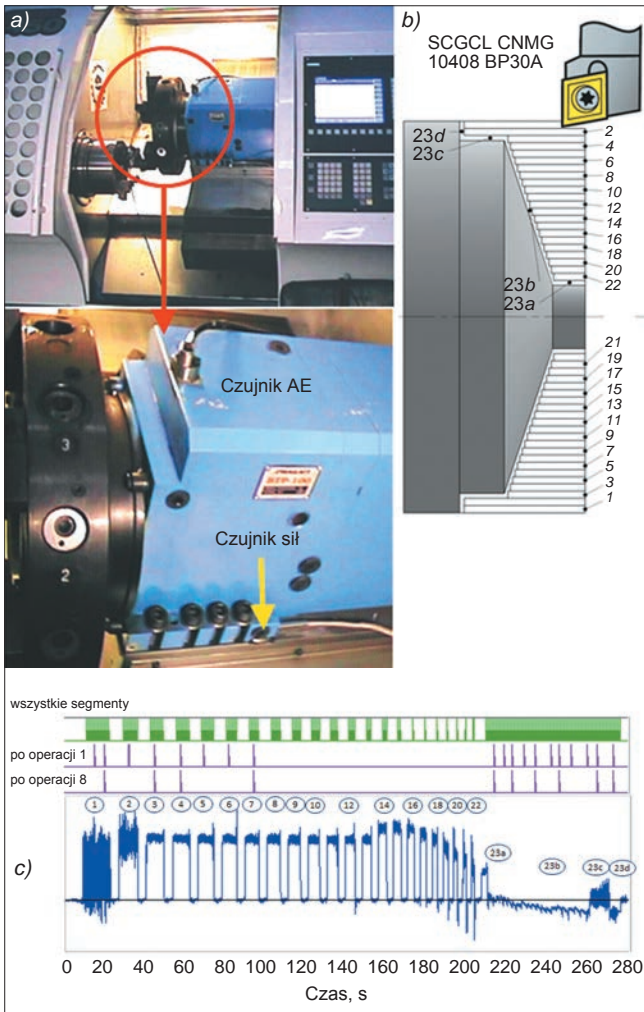
Przykład pracy układu diagnostyki stanu narzędzia

W celu zilustrowania zagadnień omówionych w niniejszym artykule dalej przedstawiono pracę układu diagnostyki stanu narzędzia na przykładzie układu ADONiS (skrótowiec od automatycznej diagnostyki ostrzy narzędzi skrawających), opracowanego przez zespół Zakładu Automatyzacji i Obróbki Skrawaniem Wydziału Inżynierii Produkcji Politechniki Warszawskiej [3, 8, 9]. Badania prowadzono na tokarce Venus 450 z czujnikiem sił skrawania (Kistler 9601A31) zainstalowanym pod suportem poprzecznym (rys. 5a) oraz czujnikiem emisji akustycznej (Kistler 7815B121) umieszczonym na tym suportcie. Mierzono cztery sygnały: F_c , F_f i F_p oraz AE_{RMS} . Przedmiotem obrabianym były wałki ze stali 45 o średnicy $\varnothing 160$ mm. Plan operacji (rys. 5b) składał się z 22 kolejnych przejść zgrubnych – o parametrach $a_p = 1,5$ mm (13 przejść) i $a_p = 2$ mm (9 przejść), $f = 0,1$ mm/obr oraz $v_c = 150$ m/min – i jednego przejścia wykończeniowego z tym samym posuwem i prędkością skrawania, ale ze zmienną głębokością skrawania. Stosowano noże tokarskie SCGCL z płytkami z węglików spiekanych CNMG 10408 BP30A. Obróbka jednego przedmiotu trwała 4,6 min, w tym czas skrawania wynosił 3,6 min. Stępiono osiem narzędzi po obróbeniu odpowiednio 8, 10, 10, 12, 10, 9, 14 i 10 przedmiotów.

Wykrywanie skrawania prowadzono na podstawie filtrowanych dolnoprzepustowo wartości wszystkich czterech sygnałów. Po starcie posuwu roboczego, a przed rozpoczęciem skrawania, układ obliczał wartości średnie sygnałów i odejmował je, usuwając offset.

Wartości odchylenia standardowego w czasie dobiegu narzędzia σ_0 służą do automatycznego wyznaczenia progów filtrowanych wartości sygnałów S_f oraz ich odchyłeń standardowych σ_c . Przekroczenie przez którykolwiek sygnał odpowiedniego progu ($S_f > 5\sigma_0$ lub $\sigma_c > 3\sigma_0$) oznacza rozpoczęcie skrawania. Przerwa w skrawaniu jest wykrywana, gdy wszystkie miary (wartości średnie i odchylenia standardowe), które przekroczyły swoje progi, spadną poniżej progów. Wszystkie wymienione czynności są wykonywane automatycznie, bez udziału czy nawet wiedzy operatora.

Na rys. 5c przedstawiono przykładowy przebieg sygnału siły F_c oraz wyniki procedury wyboru segmentów. Po pierwszej operacji (górną wiersz na rys. 5c) zidentyfikowano 165 jednosekundowych segmentów w czasie skrawania, z których wybrano 19, biorąc pod uwagę



Rys. 5. Sposób zainstalowania czujników (a), plan operacji (b) i eliminacja segmentów (c)

Kryterium niezmienności w stosunku do sąsiednich – równanie (1). Po siedmiu operacjach w pamięci układu było już $19 \times 7 = 133$ segmenty, a więc więcej niż założone maksimum 128, dlatego z każdego z dwóch wybrano lepszy (bardziej zbliżony do sąsiadów), pozostawiając 10 segmentów na operację.

Każdy z czterech mierzonych sygnałów został automatycznie przetworzony z użyciem pakietowej transformaty falkowej na 14 współczynników (aproxymacji i detali – równania (5) i (6)), z których wyznaczono automatycznie następujące miary:

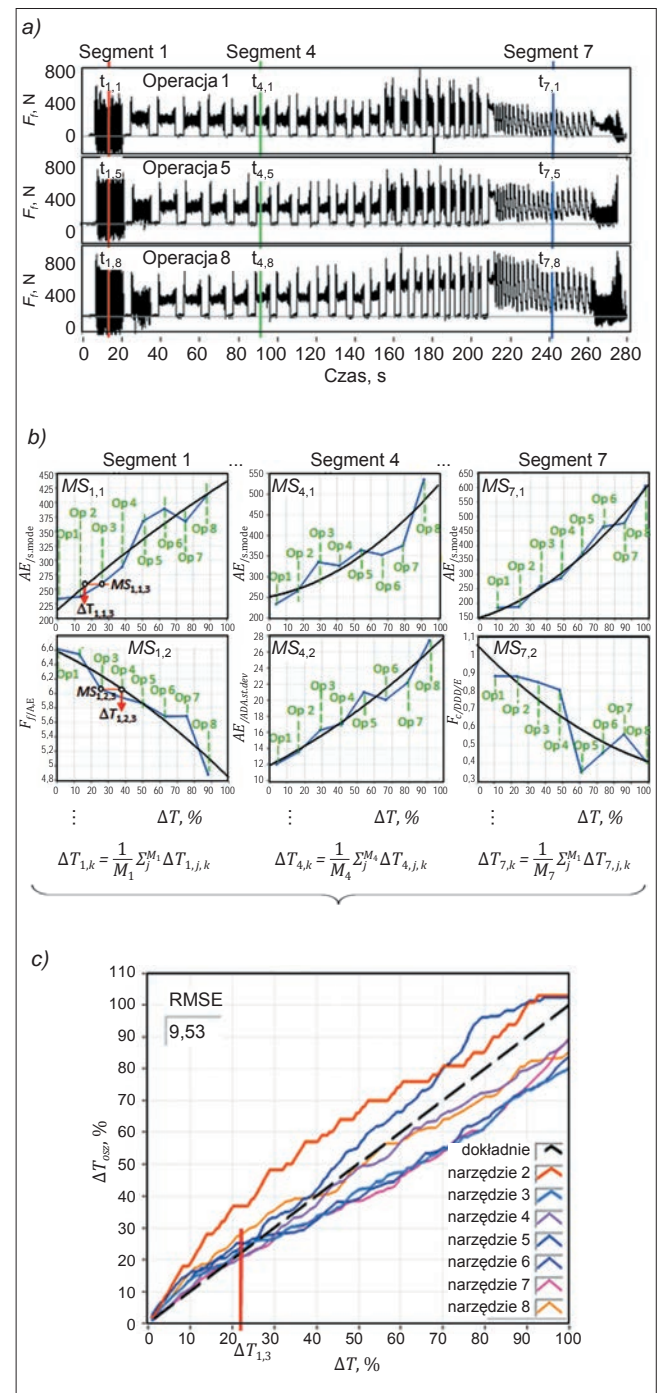
- energię logarymiczną (np. $F_{c/DD,E}$ – dla współczynnika DD sygnału F_c),
- wartość skuteczną (np. $F_{i/ADA,RMS}$ – dla współczynnika ADA sygnału F_i),
- odchylenie standardowe (np. $F_{i/A,st_dev}$ dla współczynnika A sygnału F_i),
- modę (np. $AE_{i/s,mode}$ dla oryginalnego sygnału AE),
- tempo wybuchów 1, 2 i 3 – liczbę przekroczeń progów 30%, 50% i 70% wartości maksymalnej (np. $F_{p,ADA,Count1}$),
- szerokość wybuchów 1, 2 i 3 – procent czasu powyżej progów (np. $F_{p,ADA,Pulse1}$).

Ponieważ wszystkie procedury są automatyczne (nie wymagają udziału operatora), w każdym segmencie wyznaczona została inna liczba innych miar. Ich przykłady w trzech z ośmiu operacji pierwszego okresu trwałości przedstawiono na rys. 6b (niebieskie linie). Po zakończeniu tego okresu dla każdego segmentu układ ADONiS wyznaczył oddzielny model oparty na aproksymacji wielo-

mianem drugiego stopnia (czarne ciągłe linie na rys. 6b). W czasie pracy następnych narzędzi układ działał w trybie diagnostyki. Po zebraniu danych z każdego wyselekcjonowanego segmentu układ wyznaczał wykorzystaną część okresu trwałości oddzielnie na podstawie każdej miary.

Przykładowo, dla pierwszego segmentu w trzeciej operacji ΔT oszacowywane na podstawie pierwszej i drugiej miary – $AE_{i/s,mode}$ i $F_{i/A,E}$ – wyniosły odpowiednio $\Delta T_{1,1,3}$ i $\Delta T_{1,2,3}$ (rys. 6b). Po ich uśrednieniu uzyskano oszacowanie wykorzystanej części okresu trwałości ostrza w tym momencie czasowym (dla danego segmentu):

$$\Delta T_{i,k} = \frac{1}{M_i} \sum_j^{M_i} \Delta T_{i,j,k} \quad (11)$$



Rys. 6. Sygnały siły posuwowej w trzech operacjach (a); przykłady miar sygnałów wybranych i zamodelowanych przez układ ADONiS w segmentach 1, 4 i 7 (b); oszacowanie wykorzystanej części okresu trwałości ostrza w okresach 2+8 (c)

gdzie: i – numer segmentu, j – numer miary dla segmentu, k – numer operacji, M_i – liczba miar w segmencie i .

Wyniki nadzorowania przedstawiono na rys. 6c jako wykorzystane części okresu trwałości ostrza oszacowane przez układ ADONiS – ΔT_{osz} w funkcji wartości doświadczalnych ΔT dla narzędzi 2÷8 (pierwszy okres trwałości był wykorzystany do nauczania układu).

Dokładność oszacowania wykorzystanej części okresu trwałości oceniono za pomocą błędu średniokwadratowego ($RMSE$):

$$RMSE = \sqrt{\frac{1}{n} \sum (\Delta T_{osz} - \Delta T)^2} \quad (12)$$

Ponieważ ΔT jest wyrażane w procentach, $RMSE$ można interpretować jako średni procentowy błąd oszacowania. Jego wartość również podano na rys. 6c.

Prezentowanie oszacowania stanu narzędzia w czasie trwania operacji jest istotne zwłaszcza w przemyśle lotniczym, gdzie obróbka jednego przedmiotu może trwać kilkadziesiąt minut, a do wykonania jednej operacji konieczne jest wykorzystanie szeregu narzędzi (np. [9]).

Podsumowanie

W artykule ogólnie omówiono zagadnienia związane z diagnostyką stanu narzędzi. Szczególnie istotne są wyznaczanie możliwie wielu miar ze wszystkich dostępnych sygnałów oraz ich automatyczna (bez udziału operatora) ocena i selekcja. Integrację miar można łatwo przeprowadzić różnymi metodami, lecz dobrze jest stosować algorytm hierarchiczny, w którym w pierwszym kroku szacuje się stan narzędzia na podstawie pojedynczych lub niewielu miar, a w drugim te oceny się integruje.

11. Li X., Ouyang G., Liang Z. "Complexity measure of motor current signals for tool flute breakage detection in end milling". *International Journal of Machine Tools and Manufacture*. 48 (2008): s. 371–379.
12. Marinescu I., Axinte D. "A time-frequency AE-based monitoring technique to identify workpiece surface malfunctions in milling with multiple teeth cutting simultaneously". *International Journal of Machine Tools and Manufacture*. 49 (2009): s. 53–65.
13. Peng Y. "Empirical model decomposition based time-frequency analysis for the effective detection of tool breakage". *Journal of Manufacturing Science and Engineering*. 128, 1 (2006): s. 154–166.
14. Salgado D., Alonso F. "Tool wear detection in turning operations using singular spectrum analysis". *Journal of Materials Processing Technology*. 171 (2006): s. 451–458.
15. Quan Y., Zhou M., Luo Z. "On-line robust identification of tool wear via multi-sensor NN fusion". *Engineering Applications of Artificial Intelligence*. 11 (1998): s. 717–722.
16. Scheffer C., Heyns P.C. "Wear monitoring in turning operations using vibration and strain measurements". *Mechanical Systems and Signal Processing*. 15, 6 (2001): s. 1185–1202.
17. Scheffer C., Heyns P.C. "An industrial tool wear monitoring system for interrupted turning". *Mechanical Systems and Signal Processing*. 18 (2004): s. 1219–1242.
18. Shi D., Gindy N.N. "Tool wear predictive model based on least squares support vector machines". *Mechanical Systems and Signal Processing*. 21 (2007): s. 1799–1814.
19. Sick B. "On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research". *Mechanical Systems and Signal Processing*. 16, 4 (2002): s. 487–546.
20. Sun J., Hong G.S., Rahman M., Wong Y.S. "Identification of feature set for effective tool condition monitoring by AE sensing". *International Journal of Production Research*. 42, 5 (2004): s. 901–918.
21. Teti R., Jemielniak K., O'Donnell G., Dornfeld D. "Advanced monitoring of machining operations (keynote paper)". *CIRP Annals – Manufacturing Technology*. 59, 2 (2010): s. 717–739.
22. Teti R., Kumara S.R.T. "Intelligent computing methods for manufacturing systems". STC-O KN Paper. *CIRP Annals*. 46/2 (1997): s. 629–652. ■

LITERATURA

1. Al-Habaibeh A., Gindy N. "A new approach for systematic design of condition monitoring systems for milling processes". *Journal of Materials Processing Technology*. 107 (2000): s. 243–251.
2. Binsaeid S., Asfoura S., Chob S., Onarc A. "Machine ensemble approach for simultaneous detection of transient and gradual anomalies in milling using multisensor fusion". *Journal of Materials Processing Technology*. 209 (2009): s. 4728–4738.
3. Błażej K., Bombiński S., Nejman M., Jemielniak K. "Sensor signal segmentation for tool condition monitoring". *Procedia CIRP*. 46 (2016): s. 155–160.
4. El-Wardany T.I., Gao D., Elbestawi M.A. "Tool condition monitoring in drilling using vibration signature analysis". *International Journal of Machine Tools and Manufacture*. 36 (1996): s. 687–711.
5. Halgamuge S.K., Glesner M. "NNs in designing fuzzy systems for real world applications". *Fuzzy Sets and Systems*. 65 (1984): s. 1–12.
6. Jemielniak K. „Automatyczna diagnostyka stanu narzędzia i procesu skrawania”. Warszawa: Oficyna Wydawnicza Politechniki Warszawskiej, 2002.
7. Jemielniak K. "Tool wear monitoring based on a non-monotonic signal feature". *J. Engineering Manufacture. Part B*. 220, 2 (2006): s. 163–170.
8. Jemielniak K., Bombiński S. "Hierarchical strategies in tool wear monitoring". *Proc. IMechE*. 220/B (2006): s. 375–381.
9. Jemielniak K., Kossakowska J., Urbański T., Bombiński S. "Tool condition monitoring based on numerous signal features". *International Journal of Advanced Manufacturing Technology*. 59 (2012): s. 73–81.
10. Li X. "A brief review-acoustic emission method for tool wear monitoring in turning". *International Journal of Machine Tools and Manufacture*. 42 (2002): s. 157–165.