

Algorytm diagnostyki zużycia ostrza oparty na wielu sieciach neuronowych

Algorithm of the tool condition monitoring system based on many neural networks

SEBASTIAN BOMBIŃSKI
JOANNA KOSSAKOWSKA*

DOI: <https://doi.org/10.17814/mechanik.2017.3.42>

Porównano różne sposoby określania zużycia ostrza – z wykorzystaniem sieci neuronowych RBF, metody hierarchicznej oraz standardowego zliczania czasu pracy. Analizę sygnałów z procesu skrawania przeprowadzono dla trzech różnych zestawów badań doświadczalnych. Wyniki otrzymane w przypadku zespołu sieci neuronowych są zbliżone do wyników z algorytmu hierarchicznego – jest to potencjalnie bardzo skuteczna metoda szacowania zużycia ostrza.

SŁOWA KLUCZOWE: diagnostyka stanu narzędzia, sieci neuronowe RBF

Presented is a comparison of different methods of estimating tool wear – obtained for group of RBF neural networks, hierarchical methods and the standard time counting. The analysis of the signals from the machining process carried out for three different experiments, clearly demonstrating the effect of presented methods. The results obtained for group of RBF neural networks are similar to results obtained for hierarchical methods.

KEYWORDS: tool condition monitoring, RBF neural network

Wraz ze wzrostem wymagań dotyczących wydajności i jakości produkcji rośnie stopień automatyzacji obróbki skrawaniem. Jednym z elementów tej automatyzacji są systemy nadzoru procesu skrawania. Podstawowym zadaniem tych systemów jest diagnozowanie stanu ostrza.

Zbudowano i przetestowano algorytm diagnostyki zużycia ostrza oparty na zespole sieci neuronowych. Jego działanie porównano z algorytmem bazującym na pojedynczej sieci neuronowej, a także z algorytmem hierarchicznym. Celem pracy było zbadanie, czy algorytm oparty na zespole sieci neuronowych może konkurować z algorytmem hierarchicznym zbudowanym i udoskonalanym w ITW PW w ramach kilku projektów krajowych i europejskich na przestrzeni ostatnich kilkunastu lat. Algorytm hierarchiczny zbudowany na zasadzie integracji oszacowań z pojedynczych miar wyczerpał już praktycznie swój potencjał rozwojowy. Jednym z kierunków rozwoju algorytmów diagnostyki zużycia ostrza są właśnie zespoły sieci neuronowych, które mogłyby wykorzystać efekt synergii przy szacowaniu zużycia na podstawie kilku miar jednocześnie.

Analiza stanu zagadnienia

Do integracji miar w diagnostyce zużycia ostrza najczęściej wykorzystuje się sieci neuronowe. Może to być perceptron o różnej liczbie warstw ukrytych: 0 i 1 [3, 8], 1 [9–11], oraz 1, 2 i 3 [2] z propagacją wsteczną błędu jako algorytmem uczenia.

Stosuje się również inne sieci neuronowe, takie jak: samoorganizująca się sieć Kohonena [6], sieć o logice rozmytej [7], sieć o radialnych funkcjach bazowych [4]. Przegląd takich rozwiązań można znaleźć w pracy [1] – jej autor analizuje ponad 100 pozycji literaturowych. Oprócz sieci neuronowych można zastosować logikę rozmytą [12], która może być wspomagana algorytmami genetycznymi [12]. Stosowano również algorytm hierarchiczny. Najpopularniejszą siecią jest perceptron wielowarstwowy, jednak czas jej optymalizacji (doboru liczby neuronów, parametrów uczenia i samego uczenia) jest dość długi. Wykazano jednak, że dobre rezultaty osiąga się z wykorzystaniem sieci o radialnych funkcjach bazowych [4]. Ma ona tę przewagę nad perceptronem, że czas jej uczenia jest nieporównywalnie krótszy. Cały proces optymalizacji struktury i parametrów sieci można przeprowadzić w kilka sekund. Dzięki temu nie wprowadza się dodatkowych opóźnień w produkcji związanych ze stosowaniem układu nadzoru procesu skrawania.

Porównanie skuteczności różnych sieci neuronowych w diagnostyce zużycia ostrza można znaleźć w pracy [13]. Przetestowano tu sieci:

- sieć jednokierunkową z jedną warstwą ukrytą uczoną metodą propagacji wstecznej,
- sieć jednokierunkową z jedną warstwą ukrytą uczoną metodą quasi-Newtona,
- sieć jednokierunkową z jedną warstwą ukrytą uczoną metodą Levenberga-Marquardta,
- sieć jednokierunkową z jedną warstwą ukrytą uczoną metodą gradientów sprzężonych,
- sieć jednokierunkową z jedną warstwą ukrytą uczoną metodą Quick-Propagation,
- sieć jednokierunkową z jedną warstwą ukrytą uczoną metodą Delta-Bar-Delta,
- sieć o radialnych funkcjach bazowych uczoną metodami: K-means, explicit,
- sieć o radialnych funkcjach bazowych uczoną metodami: K-means, Isotropic,
- sieć o radialnych funkcjach bazowych uczoną metodami: K-means, Isotropic, pseudoinverse, propagacji wstecznej błędu,
- sieć z rozszerzeniem funkcyjnym wejść uczoną metodą propagacji wstecznej błędu.

* Dr inż. Sebastian Bombiński (s.bombinski@wip.pw.edu.pl), dr inż. Joanna Kossakowska (j.kossakowska@wip.pw.edu.pl) – Zakład Automatyki, Obrabiarek i Obróbki Skrawaniem Politechniki Warszawskiej

Wyniki tej pracy także wskazują, że sieć neuronowa RBF (Radial Basis Function) uzyskuje zbliżone wyniki do sieci MLP (MultiLayer Perceptron).

W publikacji [5] porównano algorytm hierarchiczny i sieć RBF. Wynik wykazywał wyższość algorytmu. Został on jednak uzyskany w oparciu o pojedyncze badania doświadczalne, co mogło być przypadkiem. Badania te zostały powtórzone przez autorów pracy [15] z wykorzystaniem trzech zdecydowanie różnych (różne sposoby obróbki) badań doświadczalnych zależności sygnałów diagnostycznych od stanu ostrza. Wyniki potwierdziły wstępną obserwację, że pojedyncza sieć neuronowa znacznie gorzej sprawdza się w roli algorytmu integracji wielu miar w systemie diagnostyki zużycia niż algorytm hierarchiczny.

Poważnym problemem przy wykorzystaniu pojedynczej sieci neuronowej jest konieczność zachowania właściwego stosunku liczby wejść sieci (wykorzystywanych miar) do liczby danych uczących (ograniczonych ze względu na ekonomiczną konieczność minimalizowania liczby okresów trwałości przeznaczonych do uczenia).

Jednym z rozwiązań tego problemu jest wstępna fuzja miar poprzez wyznaczenie iloczynów ilorazów sum itp. pojedynczych miar [2]. Nie gwarantuje to jednak, że wykorzystana zostanie pełna informacja zawarta w pierwotnych miarach i wystąpi efekt synergii. Innym rozwiązaniem jest wyznaczenie stanu ostrza osobno, na podstawie zespołu miar, a następnie integracja tych cząstkowych odpowiedzi. Taką strategię zaproponowano w [14]. Składa się ona z dwóch części:

- etapu realizującego estymację zużycia ostrza oddzielnie dla każdego z czujników na podstawie miar docierających z nich sygnałów i parametrów skrawania; użyto przy tym pojedynczej sieci o radialnych funkcjach bazowych dla każdego czujnika;
- etapu realizującego integrację przewidywań z pojedynczych czujników w końcową odpowiedź systemu; etap ten wykonano w postaci zespołu reguł logiki rozmytej.

Dane doświadczalne

Przy opracowywaniu algorytmu diagnostyki zużycia posługiwano się plikami tekstowymi z wyznaczonymi wcześniej miarami, gdyż wyznaczenie miar z plików z sygnałami jest bardzo czasochłonne, a powtarzanie tej czynności za każdym razem jest zbędne, gdy testuje się nową wersję algorytmu. W trakcie poprzednich prac powstało oprogramowanie do generowania plików tekstowych z miarami. W pracy zamieszczono jedynie bardzo skrócony opis algorytmu, według którego wyznaczone są miary. Szerszy opis znajduje się np. w [15].

Do testowania strategii diagnostyki zużycia ostrza wykorzystano trzy zestawy danych doświadczalnych – każdy uzyskany z innej obrabiarki i przy innym zadaniu obróbkowym. Szczegółowe informacje na temat tych badań zestawiono w tablicy. Z plików z sygnałami diagnostycznymi z tych badań według opisanego algorytmu wyznaczono miary i zapisano je w plikach tekstowych.

Przed przystąpieniem do wyznaczania miar w zautomatyzowanych układach diagnostycznych niezbędne są wstępna obróbka sygnału oraz wykrycie skrawania. Tarowanie to usunięcie offsetu czujnika. Do wykonania tarowania obliczana jest średnia ze 120 ms sygnału następujących zaraz po 40 ms od rozpoczęcia posuwu roboczego, a następnie wartość ta jest odejmowana od sygnału przez cały czas trwania posuwu. Następnie z 400 ms sygnału wyznacza się na bieżąco wartość ruchomego odchylenia standardowego, a sygnał poddawany jest filtracji za pomo-

TABLICA. Opis badań

Nazwa badania	Toczenie Inconel 625	Wiercenie stal NC10	Toczenie stal 45
Materiał obrabiany	Inconel 625	stal NC10	stal 45
Obrabiarka	TKX 50N	Arrow 500	VENUS 450
Obróbka	Toczenie czołowe obudowy wirnika silnika lotniczego	Wiercenie w powierzchni czołowej walca	Wzdłużne toczenie wałka pod stożek
Narzędzie	RNGN 120700T01020 CC670	NWka DIN 338 RN (Baidon) $\varnothing 6$	CNMG 120408 BP30A
Oprawka	CRSNL 3225P12 MN7	7625-40-20-63 firmy Bizon (Białystok)	PCLNR 3225P 12
Parametry skrawania	$a_p = 2,5$ mm $f = 0,2$ mm/obr $v_c = 220$ m/min	$f = 31,86$ mm/min $f_z = 0,06$ mm/obr $v_c = 10$ m/min	$a_p = 1,5$ mm $a_p = 2,0$ mm $f = 0,1$ mm/obr $v_c = 150$ m/min
Czujniki	Kistler 9017B	Kistler 9017B	Kistler 9601A31
	Kistler 8152B	Kistler 8152B	Kistler 78152B121
	PCB PIEZOTRONICS 356A16	PCB PIEZOTRONICS 356A16	–
Sygnały	$AE_{mss}, V_y, V_z, F_x, F_y, F_z$	$AE_{mss}, V_x, V_y, V_z, F_x, F_y, F_z$	AE_{mss}, F_x, F_y, F_z
Akwizycja danych	NI-PCI 6221 30 kS/s	NI-PCI 6221 30 kS/s	1 kS/s

cą dolnoprzepustowego filtra Butterwotha II rzędu o częstotliwości odcięcia 1 Hz przy próbkowaniu 10 kHz. Oba te sygnały są porównywane z progami, których wartość ustala się na etapie usuwania składowej stałej z sygnału. Wartość odchylenia standardowego z tego fragmentu sygnału jest mnożona przez:

- 3 dla metody opartej na ruchomym odchyleniu standardowym,
- 5 dla metody opartej na filtrowaniu sygnału.

Skrawanie jest wykryte wtedy, gdy zostaje przekroczony wyznaczony wcześniej próg (którykolwiek z dwóch możliwych) i musi to nieprzerwanie trwać przez określony czas (domyślnie 250 ms), co zapobiega powstawaniu fałszywych alarmów pochodzących z chwilowego wzrostu poziomu sygnału.

Podobnie przebiega wykrywanie zakończenia skrawania, ale tu przebiegi muszą spaść poniżej progów, do których się odnoszą, i taki stan również musi trwać co najmniej 250 ms. Jeśli w systemie próbkowany jest więcej niż jeden sygnał diagnostyczny, aby system uznał, że wykryto skrawanie, wystarczy jego detekcja na którymkolwiek z nich. Ze względu na zakłócenia przy różnych instalacjach systemu na obrabiarkach w trakcie instalacji systemu diagnostyki ustala się dla każdego sygnału, jaką metodą należy prowadzić wykrywanie na danym kanale.

Kolejnym krokiem procedury wyznaczania miar jest segmentacja, czyli wybór fragmentu sygnału reprezentującego daną operację. W zautomatyzowanym układzie segmentacja musi przebiegać bez ingerencji operatora.

W układzie opisanym w niniejszym artykule segmentacja polegała na podziale sygnału w trakcie jego akwizycji na fragmenty o długości 1 s. Z takich wycinków – nazwanych segmentami – wyznaczane są miary. Przed przeprowadzeniem tych procedur niezbędne jest wyselekcjonowanie segmentów, które będą najlepiej reprezentować stan ostrza w trakcie obróbki. Korzystne jest, gdy sygnał do wyznaczenia miar pochodzi z sygnału zarejestrowanego przy stabilnym skrawaniu, któremu towarzyszą stabilne sygnały. Sposób oceny niezmienności sygnału (dla segmentu B sąsiadującego z segmentami A i C) został opisany równaniem (1). Im niższa będzie niezmienność, tym lepiej segment nadaje się do prowadzenia diagnostyki.

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

gdzie: RMS – wartość skuteczna segmentu odpowiednio: A, B, C ; Fl_B – wskaźnik oceny stabilności sygnału.

Aby wybrać najstabilniejsze segmenty, z zachowaniem ich równomiernego rozkładu w operacji, grupuje się je w pakiety po sześć i z każdego z nich wybiera segment o najlepszej ocenie. Gdyby jednak prowadzić analizę średnio co 6 s, mogłoby się okazać, że przy długich operacjach obróbkowych, powszechnych w przemyśle lotniczym, współczesne komputery będą miały zbyt mało mocy obliczeniowej i pamięci, aby podjąć takiemu zadaniu. Sposobem na uniknięcie tego problemu jest eliminacja nadmiarowej liczby segmentów, gdyż diagnostyka poziomu naturalnego zużycia nie musi być prowadzona online.

Przyjęto dwa kryteria eliminacji. Pierwszym jest maksymalna liczba segmentów w operacji. W przypadku ograniczenia liczby segmentów w operacji sąsiadujące segmenty kolejno grupuje się po pierwszym wykonanym przedmiocie w pakiety (tak aby w każdym była zawarta – w miarę możliwości – taka sama liczba segmentów) odpowiadające postawionemu ograniczeniu (maksymalnie 20), a następnie z każdego wybiera się najlepiej oceniony segment.

Dzięki takiej selekcji w przypadku narzędzi, na które przypada niewielka liczba operacji na okres trwałości, system diagnostyczny stawia diagnozę często w trakcie obróbki. Odmiennie – dla narzędzi o długim okresie trwałości, które są w stanie wykonać wiele przedmiotów – dopuszczalne jest szacowanie zużycia znacznie rzadziej.

Sygnał z każdego wybranego segmentu przetwarzany jest z wykorzystaniem transformaty falkowej WP3 (wszystkie poziomy od WP0 do WP3), falka db2, a dla poszczególnych pasm wyznaczane są: energia, rms (wartość skuteczna), wartość średnia, odchylenie standardowe, wartość modalna, liczba przekroczeń progu (dla trzech różnych wartości progu) oraz czas przebywania sygnału ponad progiem (dla trzech różnych wartości progu). Ponadto wyznaczono widmową gęstość mocy (PSD – Power Spectral Density), a z uzyskanego w ten sposób sygnału wyznaczono energię.

Każda miara jest aproksymowana wielomianem drugiego stopnia. Jako wskaźnik jakości modelu przyjęto średniokwadratowy (RMSE):

$$RMSE = \sqrt{\frac{\sum_i^n (Y_i - A_i)^2}{n}} \quad (2)$$

gdzie: Y_i – wartość miary w i -tej operacji, A_i – aproksymowana wartość miary w i -tej operacji, n – liczba wszystkich operacji.

Wskaźnik RMSE zależy od wartości przyjmowanych przez miary. Aby móc porównać ten wskaźnik dla różnych miar, należy je znormalizować do jednego przedziału. Wybrano przedział $[0; 1]$. Po pierwszym okresie trwałości wskaźnik ten jest miarą „gładkości” miary, a po kolejnych okresach trwałości – miarą powtarzalności. Może się jednak okazać, że kilka miar ma bardzo podobne do siebie przebiegi i – co za tym idzie – bardzo podobne wartości wskaźnika jakości. W celu wyeliminowania tego zjawiska za miarę podobieństwa przyjęto współczynnik korelacji różnic między modelem a miarą sygnału.

Opracowanie algorytmu diagnostyki zużycia ostrza opartego na wielu sieciach neuronowych

Jedną z najczęściej stosowanych metod określania stanu narzędzia w praktyce przemysłowej jest zliczanie czasu pracy ostrza/liczby operacji wykonanych danym ostrzem na podstawie czasu skrawania/liczby operacji wykonanych wzorcowym (zazwyczaj pierwszym) ostrzem. Metoda ta jednak ma poważne ograniczenia wynikające z losowego charakteru trwałości ostrzy. Dalej przedstawiono bardziej zaawansowane metody szacowania zużycia ostrza w oparciu o miary sygnałów diagnostycznych, nadające się do zastosowania w automatycznych układach diagnostyki stanu narzędzia.

Integracja miar – algorytm hierarchiczny

Do każdej wybranej miary tworzony jest model na podstawie wielomianu trzeciego stopnia. Wartości wielomianu wpisywane są do tablicy 120-elementowej, której indeks odpowiada wykorzystanej części okresu trwałości ostrza w procentach. Szacowanie zużycia za pomocą algorytmu hierarchicznego można podzielić na dwa kroki:

- **Krok 1:** Przeszukiwanie tablicy modelu przebiegu miary w poszukiwaniu wartości najbliższej do uzyskanej w trakcie analizowanej operacji. Przeszukiwać można tylko powyżej poprzednio uzyskanego wyniku. Zapobiega to sytuacji, w której wskazany poziom zużycia maleje. Przeszukiwane jest maksymalnie $n\%$ od początkowego punktu, gdzie n to poprzednia wartość oszacowania zużycia powiększona o dwukrotność średniego przyrostu zużycia na operację. Zapobiega to bardzo gwałtownym przyrostom wskaźników zużycia, wyliczonych na podstawie przypadkowo błędnych wskazań. Umożliwia to też wykorzystanie miar niemonotonicznych.
- **Krok 2:** Uśrednianie oszacowań uzyskanych dla każdej z miar.

Integracja miar z wykorzystaniem wielu sieci neuronowych

W pracy zastosowano sieć RBF składającą się z warstwy ukrytej neuronów radialnych oraz warstwy wyjściowej obejmującej neuron liniowy. Wykorzystano neurony radialne z funkcją bazową opartą na funkcji wykładniczej. Uczenie sieci neuronowej RBF składa się z trzech etapów: doboru centrów funkcji radialnych, doboru szerokości funkcji radialnych i doboru wag neuronu liniowego warstwy wyjściowej.

Położenie centrów funkcji radialnych jest określane metodą K-means. Szerokość funkcji radialnych jest określana za pomocą metody K-nearest. Wagi warstwy wyjściowej są wyznaczane metodą najmniejszych kwadratów na podstawie porównania odpowiedzi algorytmu nauczanej warstwy radialnej oraz wartości wzorca odpowiedzi sieci. Centra neuronów radialnych, ich szerokość oraz wagi liniowego neuronu wyjściowego dobierane są w procesie uczenia na podstawie danych uczących. Parametry uczenia sieci (którymi w przypadku metody aproksymacji RBF są: liczba neuronów, liczba sąsiadów oraz współczynnik szerokości funkcji radialnych) są dobierane na podstawie wyników pracy sieci na zbiorze weryfikującym.

Liczba neuronów radialnych jest wybierana z przedziału $2 \div 15$ z krokiem 1, liczba sąsiadów – z przedziału $1 \div 5$ z krokiem 1, a współczynnik szerokości – z przedziału $0,6 \div 2$ z krokiem 0,2. W przypadku diagnostyki zużycia ostrza zbiór uczący i weryfikujący tworzone są z danych

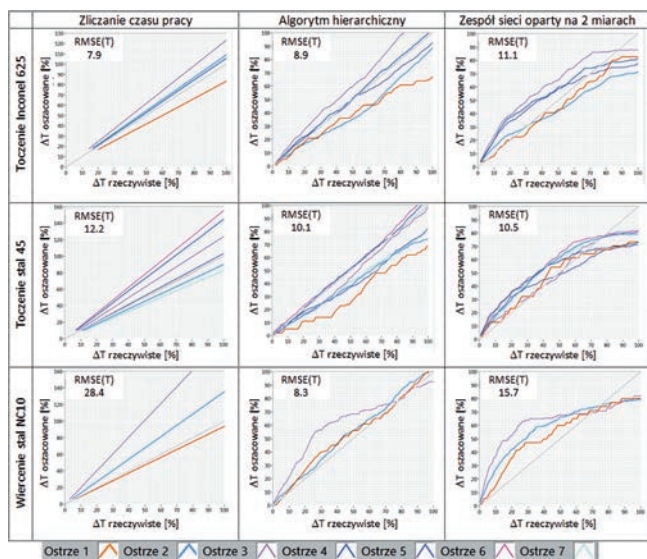
wchodzących w skład uczących okresów trwałości ostrza poprzez przypisanie do nich co drugiej próbki.

Sieć budowana jest dla każdego wyznaczonego segmentu. Jeżeli w trakcie nadzoru kolejna odpowiedź sieci jest mniejsza niż poprzednie oszacowanie zużycia przez system, to oszacowanie się nie zmienia. Wszystkie wyselekcjonowane miary są dzielone na zespoły po K miar, gdzie parametr K można dowolnie regulować. Dla każdego zespołu miar tworzona jest oddzielna sieć neuronowa, która jest optymalizowana na zbiorach uczącym i weryfikującym (zbudowanym w oparciu o te miary). W trybie nadzoru odpowiedź każdej sieci jest porównywana z ostatnim oszacowaniem zużycia. Jeśli jest mniejsza, to wartość zużycia ustalana jest na ostatnią oszacowaną. Jeśli tempo wzrostu odpowiedzi przekracza dwukrotność tempa wzrostu zużycia w okresie uczącym, to za odpowiedź sieci jest przyjmowana dwukrotność wzrostu zużycia z okresów uczących.

Analiza skuteczności różnych sposobów szacowania zużycia ostrza w oparciu o badania własne

Przed przystąpieniem do analizy skuteczności różnych sposobów szacowania zużycia ostrza wykonano badania w zakresie doboru optymalnego progu powtarzalności. Badania polegały na przeprowadzeniu szeregu eksperymentów w poszukiwaniu najmniejszego wskaźnika RMSE, w których zastosowano różne metody szacowania zużycia ostrza (zliczanie czasu pracy, algorytmy hierarchiczne, sieci neuronowe) dla trzech różnych wartości progu (8, 15, 25). W wyniku badań ustalono, że optymalny próg powtarzalności (dający statystycznie najmniejszą wartość RMSE) uzyskano dla progu równego 15.

Wyniki szacowania zużycia ostrza różnymi metodami (zliczanie czasu pracy, algorytm hierarchiczny oraz zespół sieci opartych na dwóch miarach) dla trzech różnych eksperymentów zestawiono na rysunku. Wykresy przedstawiają wartości oszacowanej części okresu trwałości ostrza ($\Delta T\%$) w funkcji rzeczywistej części okresu trwałości ostrza dla poszczególnych ostrzy skrawających. Na wykresach pokazano również wartość $RMSE(T)$, będącą miarą skuteczności danego algorytmu – im wartość ta jest bliższa jedności, tym lepsze jest oszacowanie zużycia.



Wyniki szacowania zużycia ostrza różnymi metodami (zliczanie czasu pracy, algorytm hierarchiczny oraz zespół sieci opartych na dwóch miarach) dla trzech różnych eksperymentów

Dla dwóch z trzech badań lepsze wyniki od zliczania czasu pracy uzyskano z algorytmu hierarchicznego i zespołu sieci. Statystycznie jednak najlepsze wyniki uzyskano dla algorytmu hierarchicznego. Wyniki zespołu sieci można uznać za porównywalne. Wskaźnik jakości oszacowania RMSE może nie być w tym przypadku najważniejszy. Zliczanie czasu pracy ma najwyższy błąd tam, gdzie jest najistotniejsze, żeby błąd był jak najmniejszy – czyli w końcówce okresu trwałości. Niski błąd w pierwszej części okresu przy wskaźniku jakości RMSE faworyzuje to rozwiązanie. Błąd dla zespołu sieci także jest duży w końcówce okresu. Jednak sam rozrzut oszacowanych wartości jest mały, co daje szansę na poprawę skuteczności algorytmu po wyeliminowaniu błędu systematycznego.

Podsumowanie

Algorytm diagnostyki zużycia ostrza oparty na zespole sieci neuronowych RBF daje wyniki zbliżone do algorytmu hierarchicznego. Występuje w nim jednak systematyczny błąd zanikający oszacowania w najważniejszej, końcowej części okresu trwałości ostrza. Po wyeliminowaniu tego błędu i uwzględnieniu skupienia wyników można przypuszczać, że zespół sieci mógłby być lepszym rozwiązaniem niż dotychczasowy algorytm hierarchiczny. Algorytm oparty na zespole sieci ma także potencjał do rozwoju i opracowania nowej metody selekcji miar dedykowanej dla sieci neuronowych.

LITERATURA

- 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.
- Chen S.-L., Jen Y.W. "Data fusion neural network for tool condition monitoring in CNC milling machining". *International Journal of Machine Tools and Manufacture*. 40, 3 (2000): s. 381–400.
- Dimla D.E. "Application of perceptron neural networks to tool-state classification in a metal-turning operation". *Engineering Applications of Artificial Intelligence*. 12, 4 (1999): s. 471–477.
- Pai P.S., Nagabhushana T.N., Rao P.K.R. "Flank wear estimation in face milling based on radial basis function neural networks". *The International Journal of Advanced Manufacturing Technology*. 20, 4 (2002): s. 241–247.
- Jemiłniak K., Bombiński S. "Hierarchical strategies in tool wear monitoring". *Proceedings of the Institution of Mechanical Engineers. Part B: Journal of Engineering Manufacture*. 220, 3 (2006): s. 375–381.
- Govekar E., Grabec I. "Self-organizing neural network application to drill wear classification". *Journal of Engineering for Industry*. 116 (1994): s. 233.
- Yao Y., Li X., Yuan Z. "Tool wear detection with fuzzy classification and wavelet fuzzy neural network". *International Journal of Machine Tools and Manufacture*. 39, 10 (1999): s. 1525–1538.
- Dimla D., Lister P. "On-line metal cutting tool condition monitoring. Part I: Force and vibration analyses". *International Journal of Machine Tools and Manufacture*. 40, 5 (2000): s. 739–768.
- Tansel I.N. et al. "Tool wear estimation in micro-machining.: Part I: Tool usage–cutting force relationship". *International Journal of Machine Tools and Manufacture*. 40, 4 (2000): s. 599–608.
- Kim H.-Y., Ahn J.-H. "Chip disposal state monitoring in drilling using neural network based spindle motor power sensing". *International Journal of Machine Tools and Manufacture*. 42, 10 (2002): s. 1113–1119.
- Das S., Bandyopadhyay P.P., Chattopadhyay A.B. "Neural-networks-based tool wear monitoring in turning medium carbon steel using a coated carbide tool". *Journal of Materials Processing Technology*. 63, 1–3 (1997): s. 187–192.
- Szenci T. "A DC motor based cutting tool condition monitoring system". *Journal of Materials Processing Technology*. 92 (1999): s. 350–354.
- Bombiński S., Jemiłniak K. "Analiza przydatności różnych sztucznych sieci neuronowych do diagnostyki zużycia ostrza". *XLI Sympozjon „Modelowanie w mechanice”*. Włosta (2002).
- Kuo R.J., Cohen P.H. "Multi-sensor integration for on-line tool wear estimation through radial basis function networks and fuzzy neural network". *Neural Networks*. 12, 2 (1999): s. 355–370.
- Bombiński S., Błażej K., Nejman M. "Możliwości zastosowania sieci neuronowej RBF do diagnostyki zużycia ostrza w systemie online". *Mechanik*. 89 (2016): s. 1056–1057.