

Możliwości zastosowania sieci neuronowej RBF do diagnostyki zużycia ostrza w systemie online

Possibility of applying the RBF neural network to the on-line tool condition monitoring systems

SEBASTIAN BOMBIŃSKI
KRZYSZTOF BŁĄŻEJAK
MIROSLAW NEJMAN*

DOI: 10.17814/mechanik.2016.8-9.245

Porównano wyniki dwóch metod szacowania zużycia ostrza: uzyskane dla sieci neuronowej RBF oraz metodą hierarchiczną. Analizę sygnałów z procesu skrawania przeprowadzono dla trzech różnych eksperymentów, jednoznacznie wykazując skuteczność obu metod.

SŁOWA KLUCZOWE: diagnostyka stanu narzędzia, sieci neuronowe RBF

Presented are the results of a comparison of two different methods of estimating tool wear: obtained for RBF neural network and hierarchical methods. The analysis of the signals from the machining process carried out for three different experiments, clearly demonstrating the effect of both presented methods.

KEYWORDS: tool condition monitoring, RBF neural network

Wraz ze wzrostem wymagań dotyczących wydajności i jakości produkcji zwiększa się stopień automatyzacji obróbki skrawaniem. Jednym z elementów tej automatyzacji są systemy nadzoru procesu skrawania. Podstawowym zadaniem tych systemów jest diagnostyka stanu ostrza. W pracy przedstawiono porównanie dwóch metod szacowania zużycia ostrza na podstawie wielu miar sygnałów diagnostycznych.

Typowym rozwiązaniem problemu aproksymacji zużycia ostrza na podstawie wielu miar jest zastosowanie sieci neuronowej. Szeroki przegląd takich rozwiązań można znaleźć w [1]. Najpopularniejszą siecią jest perceptron wielowarstwowy [2, 3]. Wykazano jednak, że dobre rezultaty można osiągnąć, stosując sieć 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 (wynikających z czasu wykonywania obliczeń) w produkcji związanych ze stosowaniem układu nadzoru procesu skrawania. Dlatego w ramach pracy postanowiono przetestować właśnie tę sieć.

Pierwsze porównanie algorytmu hierarchicznego i sieci neuronowej przedstawiono w [5]. Tam też znajduje się dokładny opis algorytmu hierarchicznego, do którego porównywano sieć RBF w niniejszej pracy. Uzyskany wtedy wynik wykazywał wyższość algorytmu hierarchicznego, jednakże był on oparty na pojedynczych badaniach doświadczalnych, co mogło sugerować, że jest to wynik przypadkowy. W niniejszym artykule przedstawiono porównanie oparte na trzech badaniach doświadczalnych przeprowadzonych na różnych obrabiarkach, co podnosi wiarygodność uzyskanych wyników.

W tablicy zamieszczono skrótowy opis badań, do których zastosowano porównywane algorytmy przetwarzania danych.

TABLICA. Opis badań

Nazwa badania	Toczenie Inconel 625	Wiercenie stal NC10	Toczenie stal 45
Materiał obrabiany	Inconel 625	NC10	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 (Baildon) $\varnothing 6$	CNMG 120408 BP30A
Oprawka	CRSNL 3225P12 MN7	7625-40-20-63 firmy „Bizon” (Białystok)	PCLNR 3225P 12
Parametry skrawania	$a_p = 2,5$ mm	$f = 31,86$ mm/min	$a_p = 1,5$ mm $a_p = 2,0$ mm
	$f = 0,2$ mm/obr	$f_z = 0,06$ mm/obr	$f = 0,1$ mm/obr
	$v_c = 220$ m/min	$v_c = 10$ m/min	$v_c = 150$ m/min
Czujniki	Kistler 9017B	Kistler 9017B	Kistler 9601A31
	Kistler 8152B	Kistler 8152B	Kistler 78152B121
	PCB PIEZOTRONICS 356A16	PCB PIEZOTRONICS 356A16	–
Sygnały	$AE_{rms}, V_y, V_z, F_x, F_y, F_z$	$AE_{rms}, V_x, V_y, V_z, F_x, F_y, F_z$	AE_{rms}, F_x, F_y, F_z
Akwizycja danych	NI-PCI 6221 30 kS/s	NI-PCI 6221 30 kS/s	1 kS/s

Metoda aproksymacji z wykorzystaniem sieci neuronowej RBF

Metoda aproksymacji RBF jest oparta na sieci neuronowej typu RBF. Zastosowano sieć jednokierunkową, dwuwarstwową. Składa się ona z warstwy ukrytej neuronów radialnych oraz warstwy wyjściowej obejmującej neuron liniowy. W pracy wykorzystano neuron radialny z funkcją bazową opartą na funkcji wykładniczej. Uczenie sieci neuronowej RBF obejmuje trzy etapy: dobór centrów funkcji radialnych, dobór szerokości funkcji radialnych i dobór wag neuronu liniowego warstwy wyjściowej.

Położenie centrów funkcji radialnych jest określane metodą k-means. Algorytm tworzy k centrów, gdzie k to liczba neuronów warstwy radialnej, i przypisuje im losowe wartości w przestrzeni danych. Następnie oblicza odległości wszystkich wektorów danych od centrów funkcji radialnych i przypisuje dany wektor do centrum znajdującego się najbliżej. Po przypisaniu centrum funkcji radialnej przybiera wartość środka ciężkości wektorów danych uczących przypisanych do tego klastra. Jeżeli po kolejnej iteracji tych obliczeń nie nastąpi zmiana położenia

* Dr inż. Sebastian Bombiński (s.bombinski@zaoios.pw.edu.pl), mgr inż. Krzysztof Błazejak (k.blazejak@zaoios.pw.edu.pl), dr inż. Mirosław Nejman (m.nejman@zaoios.pw.edu.pl) – Zakład Automatykacji, Obrabiarek i Obróbki Skrawaniem Politechniki Warszawskiej

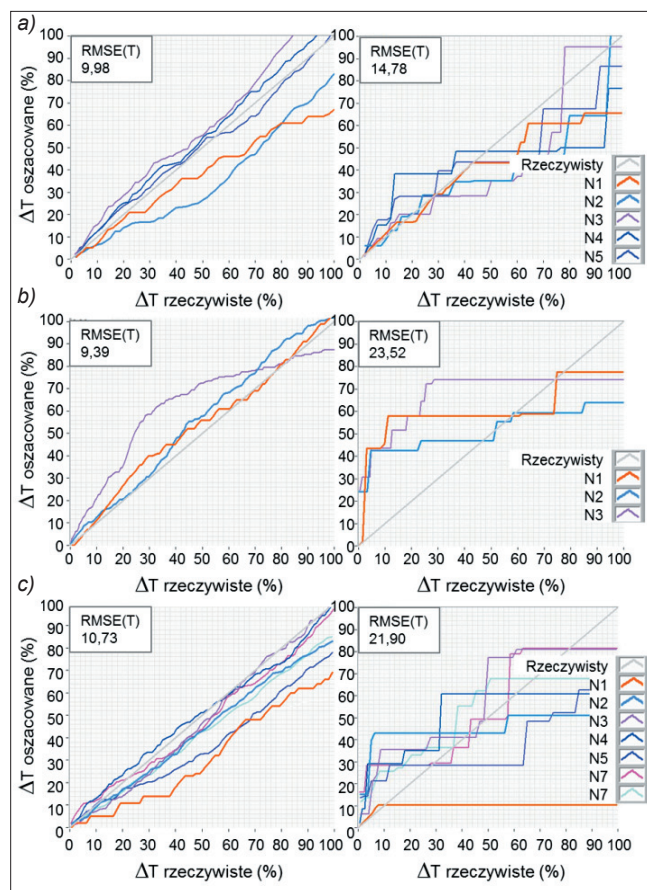
centrów, czyli żaden wektor danych nie zmieni swojego przyporządkowania, algorytm kończy działanie i centra funkcji radialnych są ustalone.

Szerokość funkcji radialnych jest określana za pomocą metody k-nearest. Algorytm ten wyznacza odchylenie standardowe jako pierwiastek średniokwadratowy odległości k najbliższych centrów funkcji radialnych, gdzie k jest równe zadanej liczbie sąsiadów. Tak obliczona szerokość funkcji radialnej jest mnożona przez współczynnik szerokości i daje ostateczną szerokość funkcji radialnej danego centrum.

Wagi warstwy wyjściowej są wyznaczone metodą najmniejszych kwadratów na podstawie porównania odpowiedzi algorytmu nauczonej warstwy radialnej oraz wartości wzorca odpowiedzi sieci.

Centra neuronów radialnych, ich szerokość i 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, dobierane są na podstawie wyników pracy sieci na zbiorze weryfikującym. Liczba neuronów radialnych jest wybierana z przedziału 2÷15 z krokiem 1, liczba sąsiadów z przedziału 1÷5 z krokiem 1, a współczynnik szerokości z przedziału 0,5÷2 z krokiem 0,1. W przypadku diagnostyki zużycia ostrza zbiór uczący i weryfikujący tworzony jest z danych wchodzących w skład uczących okresów trwałości ostrza poprzez przypisanie do nich co drugiej próbki.

Metoda aproksymacji RBF została wykorzystana w algorytmie szacowania zużycia ostrza zamiennie z algorytmem hierarchicznym. Segmentacja i dobór miar odbywają się dokładnie tak samo w obu algorytmach.



Rys. Wyniki szacowania zużycia naturalnego dla badań: a) „Toczenie Inconel 625”, b) „Wiercenie stal NC10”, c) „Toczenie stal 45” (po lewej – algorytm hierarchiczny, po prawej – sieć neuronowa)

Sieć neuronowa 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. Opisany algorytm uczenia sieci i szacowania zużycia ostrza został zaimplementowany w testerze zużycia symulującym pracę układu diagnostycznego w trybie online.

Na rysunku zestawiono wyniki algorytmu hierarchicznego (po lewej) i algorytmu opartego na sieci neuronowej typu RBF (po prawej) kolejno dla badań: „Toczenie Inconel 625”, „Wiercenie stal NC10”, „Toczenie stal 45”.

We wszystkich testowych badaniach doświadczalnych wyniki uzyskane przez ten algorytm można uznać za zadowalające. W przypadku algorytmu opartego na sieci neuronowej wyniki można uznać za zadowalające tylko w badaniach „Toczenie Inconel 625”. Jednak również tutaj wynik ten jest znacząco słabszy od algorytmu hierarchicznego.

Na zaniżenie wyniku sieci RBF w przypadku badań „Toczenie stal 45” duży wpływ ma wynik pierwszego nadzorowanego ostrza. Wyraźnie widać, że liczba danych uczących w stosunku do liczby neuronów warstwy ukrytej jest zbyt mała; dla kolejnych okresów trwałości ostrza, gdzie liczba danych uczących była większa, wyniki są już zdecydowanie lepsze. Rozwiązaniem tego problemu może być zastosowanie kilku sieci dla jednego segmentu, każdej opartej na podgrupie wybranych miar. Liczebność podgrupy powinna być zdecydowanie mniejsza (2÷4 miary) niż liczba wszystkich wybranych miar.

Podsumowanie

Skuteczność algorytmu hierarchicznego okazała się zdecydowanie większa niż algorytmu bazującego na sieci neuronowej. We wszystkich testowych badaniach doświadczalnych wyniki uzyskane przez ten algorytm można uznać za zadowalające. W przypadku algorytmu opartego na sieci neuronowej wyniki są zadowalające tylko w badaniach „Toczenie Inconel 625”. Jednak również tutaj wyniki są znacząco słabsze niż dla algorytmu hierarchicznego. Można zatem uznać, że stosowanie pojedynczej sieci neuronowej dla wszystkich wybranych miar nie jest skutecznym sposobem diagnostyki zużycia ostrza.

Otwarta pozostaje kwestia, czy zastosowanie kilku sieci neuronowych, z których każda jest oparta na podgrupie wybranych miar, oraz zastosowanie jakiegoś sprzężenia zwrotnego oszacowania zużycia, czyli stworzenie algorytmu hierarchicznego z wykorzystaniem sieci neuronowej, nie przyniosłoby lepszych rezultatów niż stosowany obecnie algorytm hierarchiczny.

LITERATURA

1. Sick B. „On-line and indirect tool wear monitoring with artificial neural networks: a review of more than a decade of research”. *Mechanical Systems and Signal Processing*. 16(4) (2002): s. 487÷546.
2. Chen S.L., Jen Y.W. „Data fusion neural network for tool condition monitoring in CNC milling machining”. *International Journal of Machine Tools & Manufacture*. 40(3) (2000): s. 381÷400.
3. Dimla E., Dimla Snr. „Application of perceptron neural networks to tool-state classification in a metal-turning operation”. *Engineering Applications of Artificial Intelligence*. 12(4) (1999): pp. 471÷477.
4. Pai P.S., Nagabhushana T.N., Rao P.K.R. „Flank Wear Estimation in Face Milling Based on Radial Basis Function Neural Networks”. *Int J Adv Manuf Technol*. 20 (2002): pp. 241÷247.
5. Jemielniak K., Bombiński S. „Hierarchical strategies in tool wear monitoring”. *Proc. IMechE Part B: J. Engineering Manufacture*. 220(3) (2006): pp. 375÷382. ■