

Zastosowanie sztucznej inteligencji do diagnozowania zużycia narzędzia w procesie frezowania

Application of artificial intelligence to diagnose tool wear during milling

JAN BUREK
PAWEŁ KUBIK*

DOI: <https://doi.org/10.17814/mechanik.2018.8-9.123>

W artykule przedstawiono badania algorytmów sztucznej inteligencji w procesie rozpoznawania stanu narzędzia online. Ponadto opisano możliwości diagnozowania procesu frezowania, wynikające z zastosowania sztucznych sieci neuronowych, oraz ograniczenia zastosowania tej technologii. W przeprowadzonych badaniach doświadczalnych określono wpływ struktury sieci neuronowej na proces uczenia (zasochłonność uczenia i zdolność sieci do uogólniania wiedzy).

SŁOWA KLUCZOWE: frezowanie, sztuczne sieci neuronowe, TCM

The paper contains a research about an ability to use an artificial intelligence in tool condition monitoring process online. There was a parollee why developing a system which set a machine able to get a decision them self is advisable. Besides, there was described an ability to use an artificial intelligence, and limits to use the technology. In conducted experimental researchers there was discover an influence neural network's structure on learning process (learning time-consuming and ability to make a knowledge an abstract).

KEYWORDS: milling, neural networks, TCM

Rozwój technologii pociąga za sobą wzrost oczekiwań zarówno wobec jakości produktów oferowanych przez producentów, jak i bezpieczeństwa pracy. Optymalizowanie kosztów wytwarzania z jednoczesnym zwiększaniem różnorodności produktów wymaga zaś wykorzystania technologii informatycznych w procesie produkcji. Celowa jest zatem praca nad systemami umożliwiającymi automatyzację procesu produkcyjnego. Aby to osiągnąć, należy opracować szereg rozwiązań układów diagnostycznych, które będą w stanie wykrywać zdarzenia krytyczne oraz określać stopień zużycia elementów maszyn i narzędzi skrawających.

Prace nad systemami TCM (*tool condition monitoring*) służącymi do monitorowania stanu narzędzia podczas procesów technologicznych (frezowania, toczenia, szlifowania) są prowadzone od wielu lat [1, 2]. Mimo to wciąż brakuje efektywnych rozwiązań, które nadawałyby się do wykorzystania na skalę przemysłową.

System diagnostyczny nie może wpływać na przebieg procesu [3]. W praktyce możliwe są jedynie pomiary parametrów pośrednich obróbki, najczęściej drgań, emisji akustycznej, siły skrawania czy momentu obrotowego wrzeciona.

Podstawową przeszkodą w rozwoju systemów diagnostycznych i nadzorujących procesy frezowania jest duża liczba czynników, które wpływają na te same sygnały diagnostyczne. To stwarza problemy ze skorelowaniem wartości sygnałów z rozpoznawanymi usterkami. Z tego powodu w praktyce stosuje się modele uproszczone,

które jednak nie pozwalają przewidzieć wszystkich możliwych wartości sygnałów. Istniejące bazy z doświadczalnie zbadanymi wartościami parametrów często zawierają zbyt mało informacji o procesach, w których wystąpiły stany awaryjne. Ponadto takie bazy są drogie w tworzeniu, a dostęp do nich jest ograniczony [4].

Wzrost mocy obliczeniowej komputerów otwiera nowe możliwości w zakresie rozwoju sztucznej inteligencji. Systemy oparte na tej technologii zyskują coraz większą popularność, ponieważ przychodzą z pomocą wtedy, gdy opracowanie algorytmów bazujących na matematycznym modelu obiektu jest trudne lub niemożliwe ze względu na złożoność modelu zjawiska.

Zastosowanie sieci neuronowej w diagnozowaniu obiektu pozwala na uwzględnienie wielu korelacji pomiędzy różnymi parametrami technologicznymi i stanem obiektu a sygnałem diagnostycznym. Ze sposobu funkcjonowania sztucznej inteligencji wynika, że sieć w procesie uczenia samodzielnie powinna wypracować takie współczynniki wagowe, aby sygnały, które nie dostarczają informacji o stanie obiektu, były pomijane [5].

Ta technologia mimo niewątpliwych zalet ma też ograniczenia. Nie istnieją jasne reguły, które pozwoliłyby na zaprojektowanie działającej sieci neuronowej. Sam proces uczenia jest długotrwały i trudno ocenić, czy (i po ilu iteracjach) zakończy się powodzeniem. Czasochłonność procesu uczenia zależy od struktury sieci i ilości informacji wejściowych, a także od czynnika losowego.

Z tego punktu widzenia ważne jest zbadanie wpływu struktury sieci neuronowej na proces uczenia oraz zdolność sieci do uogólniania wiedzy wykorzystywanej do rozpoznawania stanu narzędzia – właśnie to było celem niniejszej pracy. Uogólnianie wiedzy jest istotne z uwagi na różnorodność zabiegów wykonywanych w procesie frezowania. Sieć neuronowa powinna rozpoznawać uniwersalne cechy drgań pojawiających się z powodu zużycia narzędzia. Jest to kluczowe w przypadku wykorzystania sztucznej inteligencji w systemie TCM.

Warunki badań

W badaniach przyjęto założenie, że sygnałem diagnostycznym będą drgania z czujnika piezoelektrycznego, umieszczonego na obrabianym przedmiocie, co ma uzasadnienie praktyczne. Po pierwsze doświadczony operator potrafi ocenić stan narzędzia za pomocą zmysłu słuchu, co pozwala przypuszczać, że sieć neuronowa również będzie zdolna określić ten stan na podstawie drgań przedmiotu. Po drugie pomiar drgań nie wymaga użycia specjalnie przystosowanej do tego maszyny i – po trzecie – nie ingeruje w proces obróbki.

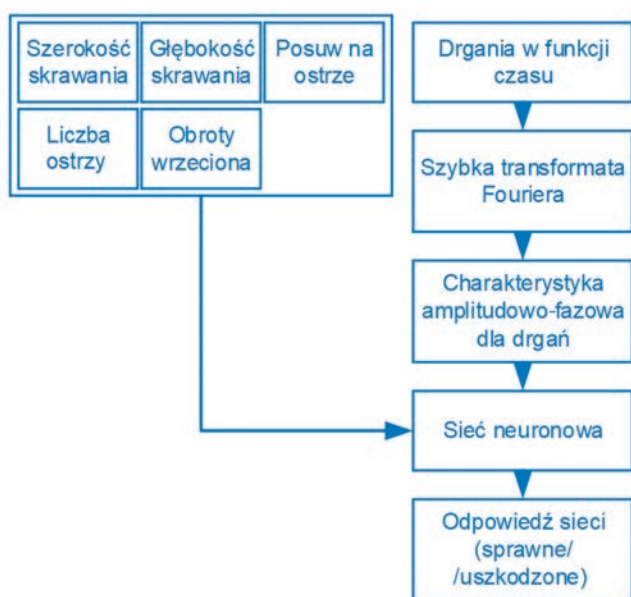
Analiza drgań w funkcji czasu jest niewygodna, dlatego jako dane wejściowe do sieci neuronowej wykorzystano charakterystykę amplitudowo-fazową, obliczoną za pomocą szybkiej transformaty Fouriera [6]. Ze względu na

* Dr hab. inż. Jan Burek, prof. PRZ (jburek@prz.edu.pl); mgr inż. Paweł Kubik (p.kubik@prz.edu.pl) – Katedra Technik Wytwarzania i Automatyki, Wydział Budowy Maszyn i Lotnictwa Politechniki Rzeszowskiej

fakt, że powstające drgania zależą od parametrów technologicznych procesu [7], wśród danych wejściowych znalazły się: szerokość skrawania, głębokość skrawania, posuw na ostrze, liczba ostrzy, obroty wrzeciona.

Projektowana sieć neuronowa w założeniu ma jeden neuron wyjściowy. Wartość 0 tego neuronu oznacza narzędzie zdadne do użytku, a wartość 1 – narzędzie zużyte.

Dla uproszczenia eksperymentu i skrócenia czasu badań przyjęto, że zmieniany będzie tylko jeden parametr technologiczny: głębokość skrawania. Założono, że drgania będą się powtarzać w cyklach oraz że danymi wejściowymi będą drgania z okna czasowego o szerokości 1 s (aby uśrednić drgania występujące w trakcie procesu). Schemat metodyki diagnozowania stanu narzędzia przedstawiono na rys. 1.



Rys. 1. Schemat blokowy metody diagnozowania stanu narzędzia

Model drgań

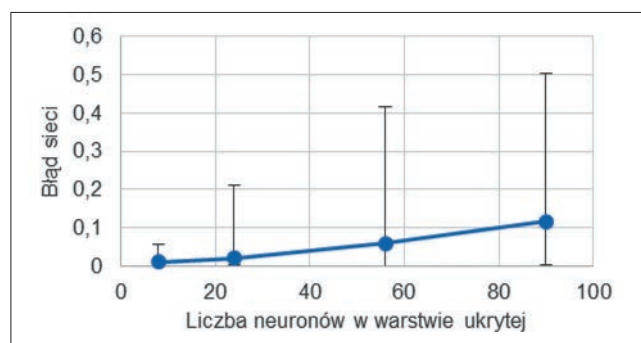
Na pierwszym etapie badań stworzono model drgań na podstawie opracowań literaturowych [7]. Model ten uwzględnia jakościowe związki pomiędzy parametrami procesu frezowania a częstotliwością i amplitudą drgań (tabl. I).

W tej fazie badań sieć neuronowa bez trudu uczyła się rozpoznawania stanu narzędzia. W wyniku prób doświadczalnych stwierdzono, że zwiększanie liczby neuronów w warstwie ukrytej powoduje:

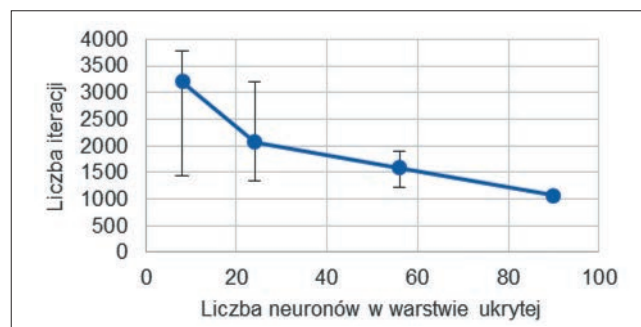
- zwiększenie średniego błędu sieci (rys. 2),
- zmniejszenie liczby iteracji potrzebnych do nauczenia się przez sieć rozpoznawania stanu narzędzia (rys. 3),
- wzrost tendencji sieci do zapamiętywania wzorców z jednoczesnym zmniejszeniem skłonności do uogólniania wiedzy (rys. 4).

TABLICA I. Wpływ parametrów skrawania na drgania w procesie frezowania

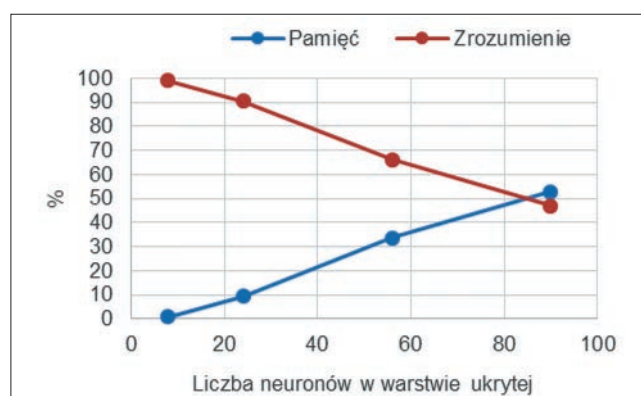
Parametr	Częstotliwość drgań	Amplituda drgań
Prędkość skrawania	wzrost	zmniejszenie
Posuw	bez zmian	wzrost
Głębokość skrawania	bez zmian	wzrost
Szerokość skrawania	bez zmian	wzrost
Zużycie narzędzia	wzrost	wzrost



Rys. 2. Wykres zmiany średniej wartości błędu sieci neuronowej



Rys. 3. Wykres średniej liczby iteracji wymaganej do ukończenia procesu uczenia sieci neuronowej



Rys. 4. Wykres wpływu liczby neuronów w warstwie ukrytej na zdolność sieci do uogólniania wiedzy

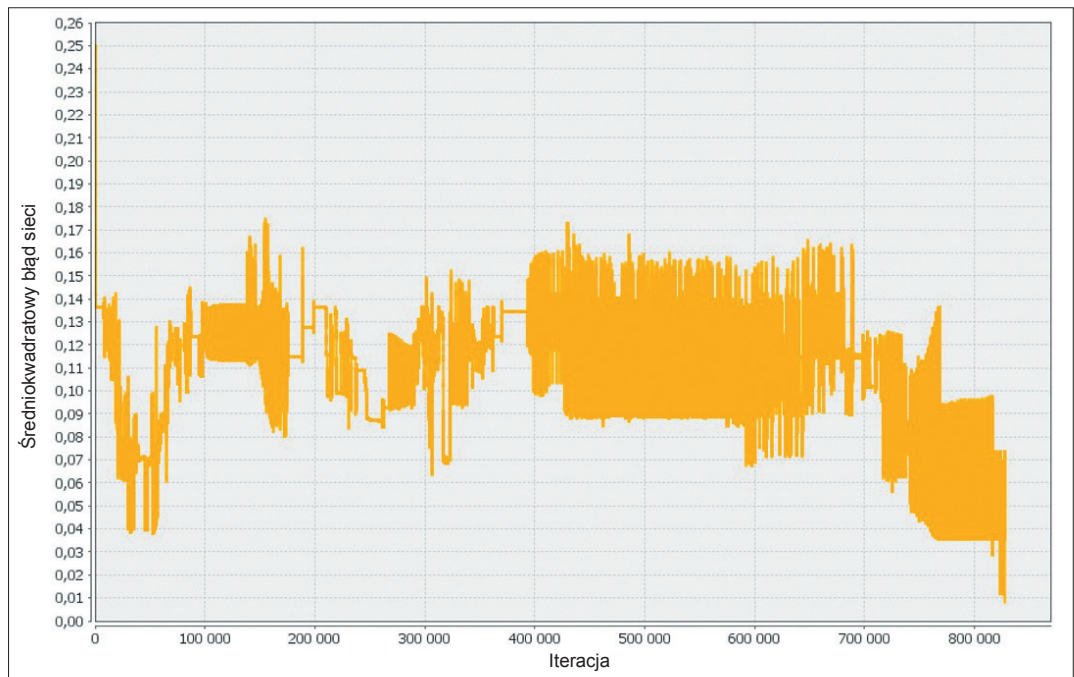
Badania eksperymentalne

Drugi etap badań obejmował wykonanie pomiarów drgań w trakcie procesu frezowania. Również w tym przypadku zmiennym parametrem technologicznym była głębokość skrawania. Pomiary wykonano z wykorzystaniem frezu monolitycznego z węgla spiekane o średnicy 10 mm. W doświadczeniu wykorzystano dwa frezy: nowy i zużyty. Dane nie podlegały filtracji. Zestaw danych składał się z 12 charakterystyk: sześciu dla narzędzia ostrego i sześciu dla zużytego. Pozwoliło to na przetestowanie trzech różnych głębokości skrawania. Dwukrotny pomiar przy takich samych parametrach technologicznych umożliwił pozyskanie informacji o zakłóceniach występujących w sygnale. Dodatkowo wykonano 10 pomiarów, które posłużyły jako dane testowe dla sieci neuronowej.

W trakcie badań proces frezowania był prowadzony z następującymi parametrami technologicznymi:

- głębokością skrawania $a_p = 0,7; 0,5; 0,4; 0,2$ mm;
- szerokością skrawania $a_e = 3$ mm;
- posuwem $f = 200$ mm/min;
- obrotami o wartości 3500 obr/min.

Rys. 5. Wykres błędu średniokwadratowego sieci neuronowej w trakcie uczenia



TABLICA II. Wyniki testu dla danych uczących

Lp.	Odpowiedź sieci	Oczekiwany rezultat	Błąd
1	0,1528	0	0,1528
2	0,1528	0	0,1528
3	0,0196	0	0,0196
4	0,1528	0	0,1528
5	0,841	0	0,841
6	0,9982	1	-0,0018
7	0,841	1	-0,159
8	0,841	1	-0,159
9	0,9972	1	-0,0028
10	0,841	1	-0,159
11	0,9972	1	-0,0028
12	0,9972	1	-0,0028
13	0,9972	1	-0,0028
Średnia błędu			0,00730

TABLICA III. Wyniki testu dla głębokości skrawania 0,4 mm

Lp.	Odpowiedź sieci	Oczekiwany rezultat	Błąd
1	0,1528	0	0,1528
2	0,1528	0	0,1528
3	0,1528	0	0,1528
4	0,9982	1	-0,0018
5	0,9982	1	-0,0018
6	0,9982	1	-0,0018
Średnia błędu			0,0116

Wykonano wiele prób mających na celu skuteczne nauczenie sieci neuronowej rozpoznawania zużycia frezu. Z doświadczenia wynikało, że sieć neuronowa z jedną warstwą ukrytą nie ma wystarczającego potencjału inteligencji do rozwiązania tego problemu. Ponadto posługiwanie się danymi o rozdzielczości 1 Hz jest zbyt czasochłonne.

Po tych niepowodzeniach dokonano obróbki danych. W pierwszej kolejności dokonano konwersji jednostek z m/s^2 na dB. Następnie obliczono średnią arytmetyczną z pomiarów szumów pochodzących od napędów obrabiarki CNC i uwzględniono je w charakterystykach stanowiących przykłady do uczenia sieci neuronowej. Ostatnim krokiem było zredukowanie rozdzielczości danych wejściowych do wartości 100 Hz. Po takim przygotowaniu danych ponownie wykonano próby uczenia sieci neuronowej. Sieć z jedną warstwą ukrytą nadal nie była w stanie znaleźć prawidłowego rozwiązania problemu. Pozytywny rezultat dała sieć neuronowa o dwóch warstwach ukrytych: pierwsza składała się ze 120 neuronów i z jednego

neuronu typu bias, a druga – z 20 neuronów i jednego neuronu typu bias. Wykres przedstawiający zmianę błędu sieci wraz z kolejnymi iteracjami przedstawiono na rys. 5.

W trakcie tej próby współczynnik uczenia sieci wynosił 0,2, natomiast maksymalny dopuszczalny błąd średniokwadratowy sieci – 0,01. Liczba iteracji wykonanych przez sieć w trakcie procesu uczenia wyniosła 827 494 i w rezultacie sieć osiągnęła błąd na poziomie 0,008.

Ostatnim zadaniem było określenie charakteru uczenia się sieci. Parametr ten określa, czy sieć zapamiętuje wzorce i później je rozpoznaje, czy też uogólnia wiedzę. W tym celu przeprowadzono próbę z parametrem $a_p = 0,4$ mm. Głębokość skrawania 0,4 mm nie była podana w danych uczących. Po przeprowadzeniu dwóch prób – jednej z tymi samymi danymi, których użyto w procesie uczenia, i jednej z $a_p = 0,4$ mm – otrzymano wyniki podane w tabl. II i III (czerwony kolor oznacza błędną diagnozę sieci co do stanu narzędzia).

Podsumowanie

Wykonane badania wskazują, że sieć neuronowa może zostać wykorzystana w procesie diagnozowania stanu narzędzia. Kluczowymi elementami decydującymi o powodzeniu procesu uczenia są liczba i jakość parametrów wejściowych. Dalsze badania w tym zakresie powinny obejmować zwiększenie różnorodności danych wejściowych.

LITERATURA

- Byrns G., Dornfeld D., Inassaki I., Ketteler G., König W., Teti R. "Tool Condition Monitoring (TCM) – The Status of Research and Industrial Application". CIRP, 1995.
- Kurada S., Bradley C. "A review of machine vision sensors for tool condition monitoring". *Computers in Industry*. 34, 1 (1997): s. 55–72.
- Kościelny J. „Praktyczne problemy diagnostyki procesów przemysłowych”. PAR, 2010.
- Korbicz J., Kościelny J., Kowalczyk Z., Cholewy W. „Diagnostyka procesów. Modele sztucznej inteligencji. Zastosowania”. Warszawa: Wydawnictwo Naukowo-Techniczne, 2002.
- Tadeusiewicz R. „Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami”. Warszawa: Oficyna Wydawnicza PLJ, 1998.
- Cormen T., Leiserson E., Rivest R., Stein C. „Wprowadzenie do algorytmów”. Warszawa: Wydawnictwo Naukowe PWN, 2012.
- Alper M., Asiltürk I. "Effects of cutting tool parameters on vibration". *ICMMR 2016*.