

Andrzej SOKOŁOWSKI, Jan KOSMOL

Katedra Budowy Maszyn

Politechnika Śląska

SIEĆ NEURONOWA TYPU FEED FORWARD BACK PROPAGATION JAKO NARZĘDZIE DO SELEKCJI I INTEGRACJI CECH SYGNAŁÓW POMIAROWYCH

Streszczenie. Celem przedstawionych badań była ocena sieci neuronowej typu Feed Forward Back Propagation (FFBP) jako narzędzia do selekcji i integracji cech sygnałów pomiarowych w układach identyfikacji stanu ostrza skrawającego. Prace skoncentrowano na testach metod określania liczby komórek w warstwie ukrytej i metodzie selekcji cech wejściowych do sieci. Jako dane wykorzystano prędkości drgań rejestrowane podczas toczenia narzędziem o różnym zużyciu i z różnymi parametrami skrawania.

FEED FORWARD BACK PROPAGATION NEURAL NETWORK AS A TOOL FOR MEASURING SIGNAL FEATURE SELECTION AND INTEGRATION

Summary. The main goal of the research presented in this paper was to assess the Feed Forward Back Propagation Neural Network as a core of the signal processing procedure in tool wear monitoring systems. The work was focused on testing methods allowing network structure determination and input feature selection. The results are presented while designing a tool wear monitoring system basing on vibration measurement during turning with varying cutting parameters.

НЕЙТРОННАЯ СЕТЬ FEED FORWARD BACK PROPAGATION КАК ОРУДИЕ К ОТБОРУ И ИНТЕГРАЦИИ ИЗМЕРИТЕЛЬНЫХ СИГНАЛОВ

Резюме. Цель наших исследований это оценка нейтронной сети типа Feed Forward Back Propagation как орудия к отбору и интеграции измерительных сигналов в системе оценки состояния режущего инструмента. Работы сосредоточены на тестах метод определения количества камерок в скрытом слое и методе отбора входных черт к сети. Измерительными сигналами были колебания станка ввремя точения с различными параметрами резания.

1. WPROWADZENIE

Analizując przykłady aplikacji sieci typu Feed Forward Back Propagation (FFBP), wydawać się może, że zastosowanie tej sieci w celu rozwiązania odpowiednio zdefiniowanego zadania nie nastręcza zbyt wiele trudności. Jakkolwiek już pobieżna analiza algorytmu

treningu sieci FFBP [4] wskazuje na stosunkowo dużą liczbę parametrów, które należy określić przed rozpoczęciem treningu. Przede wszystkim należy określić liczbę komórek w warstwie ukrytej. Następnie, problematyczny jest wybór wartości współczynnika uczenia η mającego istotny wpływ na szybkość treningu sieci FFBP. Z punktu widzenia użytkownika istotne jest także, jak przygotować zbiór trenujący sieci. W tym przypadku konieczne jest określenie struktury warstwy wejściowej i wyjściowej, tzn. konieczny jest dobór liczby komórek w tych warstwach.

Generalnie zaznacza się, że przy braku podstaw matematycznych użytkownik jest zwykle skazany na eksperymentowanie z różnymi kombinacjami parametrów sieci oraz na konieczność "wyobrażenia sobie" podstawowych mechanizmów działania sieci. Niemniej jednak podejmowane są również próby analitycznego rozwiązywania niektórych z wyżej zasygnalizowanych problemów. Zagadnienie wyboru lub budowy metod konstruowania sieci typu Feed Forward Back Propagation stanowi zasadniczy przedmiot niniejszego artykułu.

2. SIĘĆ NEURONOWA TYPU FEED FORWARD BACK PROPAGATION

Mając na uwadze szereg publikacji traktujących o sieci FFBP np. [3, 4, 10], w niniejszej części skoncentrowano się jedynie na wybranych zagadnieniach związanych z konstruowaniem tej sieci. W pierwszym kroku przedstawiono rozszerzone równanie opisujące zmiany wag podczas treningu sieci (1), polegające na minimalizacji błędu E_p , na podstawie metody największego spadku na powierzchni błędu w przestrzeni wag. W każdym kroku treningu obliczany jest gradient $\nabla E_p(W^k)$, a następnie wyznaczany jest nowy wektor wag W^{k+1} poprzez przesunięcie wzdłuż kierunku ujemnego gradientu w wielowymiarowej przestrzeni wag.

$$W^{k+1} = W^k - \frac{\eta}{n_{m-1}} \nabla E_p(W^k) + \alpha \Delta W^{k-1} \quad \text{oraz} \quad E_p^k = \frac{1}{2} \sum_{j=1}^N (d_j^k - o_j^k)^2 \quad (1)$$

gdzie :

- | | |
|--|---|
| η - współczynnik uczenia; | o_j - wartość j-tego wyjścia z sieci; |
| n_{m-1} - liczba komórek w warstwie m-1; | α - współczynnik momentum; |
| W - wektor wag i wartości progowych; | k - indeks kroku obliczeń; |
| d_j - wartość oczekiwana na j-tym wyjściu z sieci; | N - liczba komórek w warstwie wyjściowej. |

Porównując wzór (1) z podstawową zależnością określającą zmiany wag sieci FFBP podaną w [4], zauważyć można dwie zasadnicze modyfikacje. W pierwszym przypadku wykorzystano dostosowanie wartości η do struktury sieci [5]. Praktycznie, przed rozpoczęciem treningu arbitralnie ustala się wartość η , a następnie przyporządkowuje się każdej warstwie sieci współczynnik uczenia będący ilorazem przyjętego η i liczby komórek w warstwie niższej w stosunku do warstwy rozpatrywanej. W dalszej części artykułu podawane są wartości η_f odpowiadające najmniejszej wartości współczynnika uczenia wyznaczonego dla rozpatrywanej sieci.

Oprócz η_f , we wzorze (1) występuje również składnik określający wpływ zmian wag sieci w poprzednich krokach treningu na zmiany bieżące - tzw. metoda momentum. Stosowanie metody momentum ma na celu złagodzenie ewentualnych oscylacji błędu treningu sieci oraz przyspieszenie treningu.

Do określenia liczby komórek sieci wykorzystano tzw. algorytm **GDR-des** [1, 2, 6] oraz metodę pruningu komórek sieci [5] zmodyfikowaną w [6, 9]. W przypadku algorytmu **GDR-des** trening sieci rozpoczyna się z tylko jedną komórką w warstwie ukrytej. Po stwierdzeniu stabilizacji błędu treningu, tzn. w momencie, gdy kontynuacja treningu nie powoduje zmian błędu, do warstwy ukrytej wprowadzana jest druga komórka i rozpoczyna się kolejna faza treningu. Należy zaznaczyć, że w tej fazie trenowane są jedynie wagi nowo wprowadzonej komórki, a wagi pierwszej komórki uznawane są za ustalone, niezmiennie w dalszej części treningu. Proces wprowadzania komórek kontynuowany jest do spełnienia założonego kryterium błędu treningu sieci lub do osiągnięcia fazy, w której wprowadzanie kolejnych komórek nie powoduje zasadniczych zmian błędu treningu sieci.

Druga z zastosowanych metod opiera się na przeprowadzonym po treningu sieci wyborze komórek w warstwie ukrytej, których wyjścia zachowują w przybliżeniu stałe wartości dla wszystkich wektorów zbioru trenującego lub komórek, których wyjścia przyjmują analogiczne wartości do wyjścia z innych komórek w warstwie ukrytej, tzn. "naśladowują" inne komórki w tej warstwie. Zakłada się, że wybrane komórki mogą być odrzucone, co odpowiada określeniu koniecznej, z punktu widzenia rozwiązywanego zadania, liczby komórek w warstwie ukrytej [6].

Do selekcji wejść do sieci zastosowano metodę pruningu wag [6, 7, 8]. Proponowany algorytm pruningu wag realizowany jest krokowo. W każdym kroku kolejno testowane są wszystkie wagi łączące komórki wejściowe z komórkami ukrytymi. Test danej wagi polega na odrzuceniu tej wagi (nadaniu jej wartości zerowej) i wyznaczeniu błędów E_c (2) oraz E_k (3). Dany krok pruningu kończy się odrzuceniem wagi, dla której błąd E_c ma najmniejszą wartość oraz E_k jest mniejsze od wielkości pr_w nazywanej parametrem pruningu wag. Pruning wag uznaje się za zakończony, gdy nie jest możliwy wybór wagi, której odrzucenie pozwalałoby na spełnienie kryterium $E_k \leq pr_w$.

Ostatnim etapem selekcji jest wyznaczenie istotności poszczególnych wejść. Istotność danego wejścia wyraża się stosunkiem liczby aktywnych wag do początkowej liczby wag. W tym przypadku przyjęto proste kryterium wyboru odrzucanych wejść do sieci: jeżeli istotność danego wejścia jest mniejsza niż 0.5 (tj. 50%), to wejście to może być odrzucone.

$$E_c = \sqrt{\frac{1}{N \cdot P} \sum_{i=1}^N \sum_{j=1}^P (d'_i - o'_i)^2} \quad (2)$$

$$E_k = \max\{abs(d'_i - o'_i)\} \quad \text{dla } j=1..P \text{ i } i=1..N \quad (3)$$

gdzie: P - liczba wektorów trenujących.



Sprawność klasyfikacji dokonywanej przez sieć FFBP może być oceniana na podstawie dwóch kryteriów. Pierwsze z zastosowanych kryteriów (**Kr. I**) opiera się na klasycznej ocenie wyjść względem wartości 0.5, tzn. dane wyjście jest aktywne, jeżeli wartość wyjścia jest większa od 0.5. Następnie, w celu określenia poprawności klasyfikacji, porównuje się bieżący stan (aktywny - nieaktywny) komórek w warstwie wyjściowej ze stanem oczekiwanym na wyjściu. W drugim przypadku stan aktywny przyporządkowuje się komórce, której wyjście ma największą wartość, natomiast pozostałe komórki traktuje się jako nieaktywne (**Kr. II**). Ostatecznie sprawność sieci wyraża się stosunkiem liczby poprawnie sklasyfikowanych wektorów zbioru testującego do całkowitej liczby wektorów tego zbioru.

3. BADANIA EKSPERYMENTALNE

Próby zastosowania sieci FFBP do identyfikacji zużycia VB_B dla przypadku obróbki ze zmiennymi parametrami skrawania oparto na zestawie pomiarów przedstawionym na rys. 1. Każdy pomiar realizowano w dwóch krokach. Podczas pomiarów rejestrowano prędkości drgań w wybranych punktach obrabiarki (rys. 1), a następnie, bezpośrednio po rejestracji dokonywano pomiaru zużycia głównej powierzchni przyłożenia VB_B . Pomiary przeprowadzono z parametrycznie zmiennym zużyciem powierzchni przyłożenia ostrza skrawającego, tj. skrawano wyselekcjonowanymi płytkami o zadanym zużyciu: $VB_B=0.0$ mm; $VB_B=0.4$ mm i $VB_B=0.8$ mm.

v [m/min]	p [mm/obr]	g [mm]	VB_B [mm]
150	0.1; 0.2	1.0; 2.0	0.0; 0.4; 0.8;
120	0.1; 0.2	1.0; 2.0	
90	0.1; 0.2	1.0; 2.0	
materiał obrab. 30HN3A, materiał ostrza S10S			

Rys. 1. Zestawienie przeprowadzonych prób skrawaniowych oraz zastosowana konfiguracja czujników przyspieszeń
Fig. 1. Measurement schedule and acceleration sensor configuration



Rys. 2. Wpływ prędkości skrawania i zużycia VB_B na wartość składowej widma o częstotliwości $f=7200$ Hz, punkt pomiarowy - S_{zn} , $p=0.1$ mm/obr.; $g=1$ mm
Fig. 2. Influence of the cutting speed and tool wear VB on the magnitude of spectrum component $f=7200$ Hz, measuring point S_{zn} , $p=0.1$ mm/rev.; $g=1$ mm

Zasadnicza część analiz sygnału pomiarowego sprowadzała się do wskazania pasma częstotliwości, w którym składowe widma prędkości drgań wykazywały największą współzmiennność ze zużyciem VB_B . Wykazano, iż w każdym z punktów pomiarowych wyróżnić można jedną tę samą składową widma o częstotliwości $f=7200$ Hz, której wartość (W_{sw}) wraz ze wzrostem zużycia VB_B wykazuje największe przyrosty względne.

W kolejnym kroku przeprowadzono ocenę wpływu parametrów skrawania. Wykazano, że parametry skrawania mogą mieć analogiczny wpływ na W_{sw} jak zużycie VB_B ostrza skrawającego (rys. 2). Założono w tym przypadku, iż sieć FFBP jest w stanie poprawnie

rozróżniać wzrost zużycia od zmian parametrów skrawania, a tym samym umożliwić identyfikację 3 poziomów zużycia.

4. KLASYFIKACJA POZIOMÓW ZUŻYCIA Z WYKORZYSTANIEM SIECI FFBP

Zestaw pomiarów przedstawionych na rys. 1 składał się z pomiarów przeprowadzonych dla 12 kombinacji parametrów skrawania i 3 wartości zużycia VB_B , co pozwoliło na budowę zbioru 36 wektorów trenujących. Zbiór testujący zawierał również 36 wektorów wejściowych wyznaczonych na podstawie dodatkowo przeprowadzonych pomiarów (te same parametry obróbki i wartości zużycia) lub zbioru danych uzyskane poprzez powtórna dyskretyzację sygnałów pomiarowych. Utworzenie zbiorów trenujących i testujących oparto na koncepcji wieloczuJNIKOWEGO układu pomiarowego (Sensor Integration Approach). Założono, iż każdy czujnik reprezentowany będzie przez jedną cechę odpowiadającego mu sygnału pomiarowego - wartość składowej widma o częstotliwości $f=7200$ Hz. Oprócz cech sygnałów pomiarowych, wejścia do sieci FFBP stanowiły także prędkość skrawania, posuw i głębokość skrawania (tablica 1). Na wyjściu z sieci obserwowano 3 poziomy zużycia, tj. w każdej z testowanych sieci zastosowano 3 komórki wyjściowe, którym przyporządkowano wartości zużycia : $VB_B=0.0$ mm, $VB_B=0.4$ mm i $VB_B=0.8$ mm.

Tablica 1

Reprezentacja elementów wektorów wejściowych oraz reprezentacja wyjść z sieci FFBP

elementy wektora wejściowego						
1	2	3	4	5	6	7
S_{zn}	S_{ym}	S_{zn}	S_{zi}	v	p	g

wyjścia z sieci FFBP		
1	2	3
$VB_B=0.0$ mm	$VB_B=0.4$ mm	$VB_B=0.8$ mm


Wyniki pierwszych testów sieci FFBP przedstawiono w tablicy 2. Pierwszy etap konstruowania sprowadzał się do treningu sieci o arbitralnie dobranej strukturze. Zakładano, że przyjęta na tym etapie struktura jest strukturą znacznie "przewymiarowaną" w sensie liczby komórek warstwy ukrytej jak i liczby wejść do sieci. Stąd też w pierwszym kroku dokonywano pruningu komórek warstwy ukrytej, dążąc do wstępnego określenia wymaganej do rozwiązania danego zadania struktury sieci (Etap 2). Kolejny etap stanowił próbę odrzucenia wybranych wejść do sieci - selekcję cech wejściowych (rys. 3). W przypadku stwierdzenia możliwości odrzucenia niektórych wejść odpowiednio zmniejszono liczbę komórek warstwy wejściowej i ponownie arbitralnie ustalano liczbę komórek warstwy ukrytej. Ostateczną strukturę sieci otrzymywano po dokonaniu kolejnego pruningu komórek warstwy ukrytej (Etap 4). W tablicy przedstawiono także strukturę i sprawność sieci trenowanej z wykorzystaniem algorytmu **GDR-des**.

Przedstawione w tablicy 2 próby zastosowania sieci FFBP do identyfikacji zużycia VB sprowadzały się do treningu, a następnie wyznaczenia sprawności z wykorzystaniem

wektorów wejściowych utworzonych dla analogicznych kombinacji parametrów skrawania. Z punktu widzenia hipotetycznego układu nadzorowania zużycia VB odpowiada to przypadkowi treningu i przede wszystkim zastosowania sieci jedynie dla wybranych wartości tych parametrów. Celem kolejnych testów było określenie sprawności sieci w przypadku zastosowania zbioru testującego utworzonego dla różnych w stosunku do zbioru trenującego parametrów skrawania.

Tablica 2
Wstępne testy sieci Feed Forward Back Propagation, liczba wektorów
trenujących/testujących : 36/36, $\eta_f=0.2$

opis	struktura sieci	reprezentacja elementów wektora wejściowego	sprawność sieci	
			Kr. I	Kr. II
GDR-des	7-11-3		94.4%	87.2%
Etap 1	7-20-3		94.4%	85.8%
Etap 2 sieć po pruningu komórek	7-11-3		94.4%	86.3%
GDR-des	6-10-3		94.4%	87.2%
Etap 3 sieć po pruningu wag	6-20-3		96.3%	87.2%
Etap 4 sieć po pruningu komórek	5-11-3		97.2%	89.1%



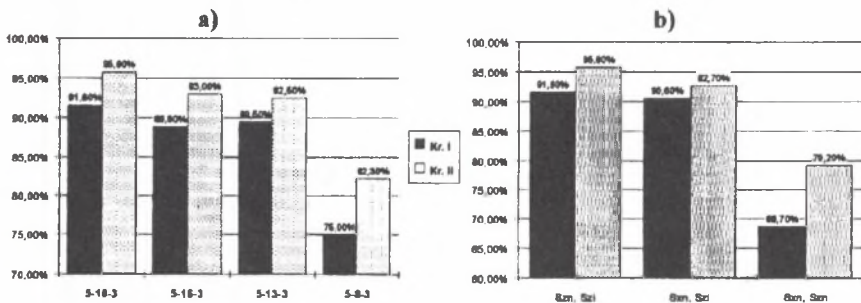
Rys. 3. Istotności poszczególnych wejść do sieci wyznaczone podczas testów przedstawionych w tablicy 2 (Etap 3)

Fig. 3. Input feature importance estimated for the tests shown in table 2 (Etap 3)

Pomiary wykorzystane do testów sieci (rys. 1) obejmowały przypadki obróbki z 3 prędkościami skrawania. W kolejnych testach zdecydowano się pominąć w zbiorach trenujących dane odnoszące się do wybranej prędkości skrawania i wykorzystywać je jedynie jako dane testujące. Ze względu na pominięcie danych odpowiadających wybranej prędkości skrawania w opisywanych poniżej testach wykorzystywano 24 wektory trenujące i 48 wektorów testujących.

Tablica 3
 Testy sieci Feed Forward Back Propagation przeprowadzone z pominięciem w fazie treningu danych odpowiadających prędkości skrawania $v=120$ m/min; liczba wektorów trenujących/testujących : 24/48, $\eta=0.2$

opis	struktura sieci	reprezentacja elementów wektora wejściowego	sprawność sieci	
			Kr. I	Kr. II
GDR-des	7-11-3		88.5%	93.5%
Etap 1	7-20-3		88.1%	88.2%
Etap 2 sieć po pruniu komórek	7-16-3		90.8%	96.7%
GDR-des	5-13-3		89.5%	92.5%
Etap 3 sieć po pruniu wag	5-20-3		87.9%	95.0%
Etap 4 sieć po pruniu komórek	5-18-3		91.8%	95.8%



Rys. 4. Wyniki testów sieci FFBP o różnej liczbie komórek w warstwie ukrytej (a) oraz testy z różnymi konfiguracjami danych wejściowych (b)

Fig. 4. Results of FFBP tests conducted with networks contained different numbers of nodes in the hidden layer (a) and different input feature configurations (b)

Wyniki testów sieci FFBP przeprowadzonych z pominięciem w fazie treningu danych odpowiadających prędkości skrawania $v=120$ m/min przedstawiono w tablicy 3. Analizując te wyniki, dyskusyjna wydaje się ostateczna struktura sieci FFBP, a konkretnie stosunkowo duża liczba komórek w warstwie ukrytej. W celu określenia wpływu struktury sieci na sprawność klasyfikacji przeprowadzono dodatkowe testy sieci o różnej liczbie komórek w warstwie ukrytej (rys. 4a). Należy zaznaczyć, że na rys. 4a, sieć 5-13-3 trenowano z wykorzystaniem algorytmu GDR-des (tablica 3). Jak można zauważyć, dla liczby komórek w warstwie ukrytej wahającej się pomiędzy 18 (pruning komórek) i 13 (algorytm GDR-des) uzyskiwano sprawności powyżej 90% (Kr. II). Dalsze zmniejszanie liczby komórek prowadziło jednak do znacznego obniżenia sprawności sieci FFBP. Stąd też przyjmuje się, że zastosowane metody służyć mogą do określenia zakresu wymaganej w celu zapewnienia relatywnie wysokiej

sprawności liczby komórek. Jakkolwiek ponownie zaznaczyć należy, iż pruning komórek pozwala na uzyskanie najwyższych sprawności klasyfikacji.

Na rys. 4.b przedstawiono również testy sieci z różnymi konfiguracjami cech sygnałów pomiarowych. Analizując uzyskane sprawności w świetle istotności poszczególnych cech przedstawionych na rys. 3, zauważa się, iż konfiguracje cech różne od tej wskazanej przez sieć dawały niższe sprawności. Szczególnie fakt ten uwidacznia się w przypadku, gdy pomijane były informacje z czujnika S_2 .

5. PODSUMOWANIE

Podsumowując, stwierdzić można, że przedstawione testy jednoznacznie potwierdzają celowość zastosowania sieci FFBP jako narzędzia do identyfikacji 3 poziomów zużycia VB_B dla przypadku obróbki ze zmiennymi parametrami skrawania. Wydaje się, że tak zdefiniowane zadanie nie stanowiło zbytniego "problemu" dla sieci FFBP. Podkreślenia wymaga również, że zastosowane metody określania struktury sieci oraz selekcji wejść do sieci umożliwiły zredukowanie ilości komórek w warstwie ukrytej i warstwie wejściowej bez istotnego obniżenia sprawności sieci. Pozwala to na wstępne potwierdzenie poprawności zdefiniowania tych metod, a tym samym potwierdzenie ich przydatności do konstruowania sieci FFBP.

LITERATURA

- [1] Chester D. : New trends in neural networks. Scientific Computing & Automation, Technology for the Laboratory, May 1992.
- [2] Li C.J., Kim T. : A new feedforward neural network structural and weight learning algorithm. Neural Networks in Manufact. and Robotics, ASME, PED, Vol. 57, 1992.
- [3] Pao Yoh-Han : Adaptive Pattern Recognition and Neural Networks. Addison - Wesley Publishing Company Inc., 1989.
- [4] Rumelhart D.E., Hinton G.E., Williams R.J. : Learning internal representation by error propagation. Parallel Distributing Processing, The MIT Press, 1986.
- [5] Sietsma J., Dow R.J.F. : Creating artificial neural networks that generalize. Neural Networks, Vol. 4, No. 1, 1991.
- [6] Sokołowski A. : Nadzorowanie stanu ostrza skrawającego z zastosowaniem sieci neuronowych. Rozprawa doktorska, Politechnika Śląska w Gliwicach, Wrzesień 1994.
- [7] Sokolowski A., Rehse M. : Feature selection task in tool wear monitoring - genetic algorithm approach. Research Reports 1993/1994, Laboratory for Manufacturing Automation, University of California at Berkeley, March 1994.
- [8] Sokolowski A., Rehse M. : Feature selection task in tool wear monitoring - neural network approach. Research Reports 1993/1994, Laboratory for Manufacturing Automation, University of California at Berkeley, March 1994.
- [9] Sokołowski A., Dornfeld D.A. : Intelligent System for Cutting Parameter Optimization and Design of Cutting Process Monitoring Systems. First S.M. Wu Symposium on Manufacturing Science, SME, Chicago, May 1994.
- [10] Zurada J.,M.: Introduction to Artificial Neural Systems. West Publishing Comp., 1992.

Recenzent : prof. dr hab. inż. Wojciech Cholewa

Wpłynęło do Redakcji w grudniu 1994 r.