

MODELOWANIE STANU WARSTWY WIERZCHNIEJ ZA POMOCĄ SIECI NEURONOWYCH

Słowa kluczowe:

materiały trudnoskrawalne, naprężenia własne, sieci neuronowe, warstwa wierzchnia

1. Wstęp

Wśród materiałów trudnoskrawalnych wyróżnia się stopy na bazie tytanu oraz niklu. Elementy wykonane z tych materiałów są powszechnie stosowane do pracy w ekstremalnych warunkach, do których dochodzi między innymi w przemyśle lotniczym czy motoryzacyjnym (wysokie temperatury zmienne i duże obciążenia).

Obróbka tych materiałów niesie ze sobą pewne niedogodności, związane między innymi z generowaniem bardzo wysokich temperatur. W związku ze słabą przewodnością cieplną materiałów trudnoskrawalnych utrudnione jest odprowadzanie ciepła ze strefy skrawania podczas obróbki.

Podczas skrawania w przedmiocie obrabianym dochodzi do wielu złożonych zjawisk, które wpływają na zmianę właściwości warstwy skrawanej, decydujących o cechach użytkowych elementów maszyn i urządzeń. W obrabianym materiale pojawia się zmienne w czasie i przestrzeni pole temperatur wywołujące naprężenia własne, będące nieodłącznym zjawiskiem procesu skrawania. Z polem temperatur związanych są przemiany fazowe, które prowadzą do lokalnej zmiany objętości właściwej, a w konsekwencji do zmiany stanu naprężeń [10]. Znajomość rozkładu oraz charakteru naprężeń jest bardzo ważna, ponieważ mają one istotny wpływ na właściwości wytrzymałościowe elementu obrabianego (odporność na kruche pęknięcie, wytrzymałość zmęczeniowa), właściwości tribologiczne oraz korozyjne. Ze względu na przyczynę powstawania, naprężenia można podzielić na: cieplne, mechaniczne i strukturalne.

Istnieje możliwość wpływania na wartość oraz znak naprężeń za pomocą różnych zabiegów technologicznych. Co więcej, w pewnym zakresie możliwe jest celowe sterowanie ich powstawaniem [10], co umożliwi kontrolowanie pracy danego wyrobu i jego cech eksploatacyjnych. Znajomość metod pomiaru naprężeń własnych nie zmienia faktu, iż pomiary te są czasochłonne i kosztowne. W artykule zaproponowano metodę prognozowania wartości naprężeń własnych w wybranych materiałach trudnoskrawalnych [12].

2. Algorytmy uczące

Sieci neuronowe można zastosować w różnych dziedzinach m.in. do klasyfikacji i rozpoznawania wzorów, do identyfikacji i sterowania procesami dynamicznymi oraz w dziedzinie predykcji. Utworzone sieci neuronowe miały na celu predykcję wartości naprężeń własnych. Zadaniem sieci neuronowych było określenie przyszłych odpowiedzi systemu na podstawie wcześniej zaimplementowanych wartości.

Sieć, mając informacje o zmiennych wartościach wejściowych i wyjściowych, podejmuje decyzję o tym, jaka wartość będzie estymowana dla badanego ciągu w chwili aktualnej. Najważniejszą cechą sieci neuronowej jest umiejętność uczenia się oraz generalizacji zdobytej wiedzy. Sieć, która jest trenowana na ograniczonej grupie danych, potrafi skojarzyć nabytą wiedzę i wykazać oczekiwane działanie na danych nieuczestniczących w procesie uczenia [9].

Najczęściej spotykanymi sieciami są sieci jednokierunkowe (bez sprzężenia zwrotnego), w których informacje przepływają tylko w jednym kierunku (od wejścia do wyjścia). Sieć neuronową tworzą neurony, którym przypisywane są odpowiednie wagi (w_{ij}), których dobór zależy od procesu uczenia się sieci. Jednym z najskuteczniejszych algorytmów uczenia sieci neuronowych jest model propagacji wstecznej, za pomocą którego określane są strategie doboru wag w sieciach wielowarstwowych.

Istnieje wiele algorytmów uczenia sieci neuronowych. Jedną z powszechnie wykorzystywanych metod jest newtonowska strategia optymalizacji, tzw. metoda Levenberga-Marquardta. Metoda ta polega na zastąpieniu dokładnej wartości hesjanu $H(w)$ jego wartością aproksymowaną $G(w)$, uwzględniającą czynnik regulujący [9]. Aproksymowana macierz hesjanu (wzór 1) oraz wektor gradientu odpowiadające funkcji celu są określane wg wzoru (2) i wzoru (3).

$$H(w) = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1 \partial w_1} & \dots & \frac{\partial^2 E}{\partial w_1} \\ \frac{\partial^2 E}{\partial w_n \partial w_1} & \dots & \frac{\partial^2 E}{\partial w_n \partial w_n} \end{bmatrix} \quad (1)$$

$$g(w) = [J(w)]^T e(w) \quad (2)$$

$$G(w) = [J(w)]^T J(w) + R(w) \quad (3)$$

$R(w)$ odpowiada składnikom rozwinięcia hesjanu $H(w)$. Aproksymowana macierz hesjanu przyjmuje postać – wzór (4). W którym aproksymacja $R(w)$ następuje za pomocą czynnika $1 -$ tzw. parametru Levenberga-Marquardta, który jest wielkością skalarną.

$$G(w_k) = [J(w_k)]^T J(w_k) + v_k 1 \quad (4)$$

Skuteczność działania algorytmu jest zależna w dużym stopniu od parametru Levenberga-Marquardta, który na początku powinien mieć bardzo duże wartości w stosunku do wartości własnych macierzy i w miarę zmniejszania się błędów powinien dążyć do zera. Kolejnym stosowanym algorytmem jest RPROP (*Resilient backPROPagation*). Daje on dobre efekty uczenia, a przy zmianie wag uwzględniany jest jedynie znak składowej gradientu, a jej wartość jest pomijana – wzór (5).

$$\Delta w_{ij}(k) = -\eta_{ij}(k) \operatorname{sgn} \left(\frac{\partial E(w(k))}{\partial w_{ij}} \right) \quad (5)$$

Na podstawie wartości gradientu, dla każdej wagi w_{ij} dobierany jest współczynnik uczenia ζ_{ij} – wzór (6).

$$\eta_{ij}^k = \begin{cases} \min(a\eta_{ij}(k-1), \eta_{\max}), & \text{dla } S_{ij}(k)S_{ij}(k-1) > 0 \\ \max(b\eta_{ij}(k-1), \eta_{\min}), & \text{dla } S_{ij}(k)S_{ij}(k-1) < 0 \\ \eta_{ij}(k-1), & \text{w innych przypadkach} \end{cases} \quad (6)$$

Gdzie $S_{ij}(k)$ oraz a i b są stałymi ($a=1,2$; $b=0,5$), η_{\min} oraz η_{\max} to minimalna oraz maksymalna wartość współczynnika uczenia. Funkcja sgn oznacza znak argumentu. W przypadku, gdy wartość gradientu jest pomijana, proces uczenia przebiega bardzo szybko w szczególności w obszarach, w których nachylenie funkcji celu jest niewielkie. Zakłada się ciągły wzrost współczynnika uczenia, w przypadku gdy znak gradientu w dwóch kolejnych krokach jest taki sam. Gdy znak gradientu jest różny, należy zmniejszać współczynnik uczenia. Dla przeprowadzonego procesu skrawania i dla otrzymanych wyników, w stworzonych sieciach neuronowych został wykorzystany algorytm PROP.

3. Sieć neuronowa do predykcji naprężeń własnych


Na Politechnice Krakowskiej został przeprowadzony proces frezowania obwodowego próbek wykonanych ze stopu na bazie niklu (Inconel 718) oraz ze stopu tytanu (Ti6Al4V). Frezowaniu poddano 15 próbek Inconel 718 oraz Ti6Al4V. Skrawanie prowadzone było przy zmiennych parametrach skrawania za pomocą palcowych frezów czterostrzowych z węglików spiekanych. Parametry skrawania (prędkość skrawania v_c , głębokość skrawania a_p , posuw f) zostały dobrane zgodnie z planem badawczym PS/DS.-P: α ($\alpha=1,215$), przy $v_{c\max}=94,2$ m/min, $v_{c\min}=30$ m/min oraz $a_{p\max}=0,8$ [mm],

$a_{p\min}=0,2$ [mm] dla próbek wykonanych zarówno ze stopu tytanu, jak i ze stopu niklu. Skrajne wartości posuwu dobmano $f_{\max}=1000$ [mm/min] oraz $f_{\min}=500$ [mm/min] dla próbek z Ti6Al4V oraz $f_{\max}=1000$ [mm/min] oraz $f_{\min}=100$ [mm/min] dla próbek z Inconel 718.


Pomiar naprężeń własnych został przeprowadzony na dyfraktometrze rentgenowskim w Państwowym Instytucie Badawczym w Radomiu. Istotą pomiarów dyfraktometrycznych jest identyfikacja parametrów sieci krystalograficznych. Pod wpływem sił działających na obrabiany materiał, w trakcie procesu frezowania dochodzi do zmiany parametrów tych sieci. Naprężenia wyznaczono w czterech punktach próbek poddanych frezowaniu. Przykłady otrzymanych wartości naprężeń zmierzonych w kierunku równoległym do obrobionej powierzchni dla próbek wykonanych ze stopu na bazie niklu oraz ze stopu na bazie tytanu przedstawiono na rysunkach 1-2.

Stworzono sieci neuronowe do wyznaczania wartości naprężeń własnych. Badaniom i ocenie poprawności działania były poddane sieci o różnej architekturze. Wstępne badania przeprowadzono na sieciach z dwiema warstwami ukrytymi, trenowane newtonowską strategią optymalizacji – metodą Levenberga-Marquardta. Wyniki otrzymywane przy badaniach wstępnych nie były satysfakcjonujące. Kolejne próby uwzględniły zmianę: ilości warstw ukrytych, neuronów, algorytmów uczących sieci. Ostatecznie najlepsze wyniki osiągnięte zostały dla jednowarstwowej sieci, z tansigmoidalną funkcją aktywacji, trenowanej algorytmem opracowanym przez Riedmillaera oraz Brauna (ang. *Resilient backpropagation*). Istotą metody wybranego algorytmu jest uwzględnienie w procesie aktualizacji jedynie wagi znaku składowej gradientu. Jako wielkości wejściowe sieci zostały przyjęte:

- v_c – prędkość skrawania,
- f – posuw,
- a_p – głębokość skrawania.



Rys. 1. Wartości naprężeń własnych dla próbek wykonanych ze stopu Inconel 718



Rys. 2. Wartości naprężeń własnych dla próbek wykonanych ze stopu Ti6Al4V

Danymi wyjściowymi były wartości naprężeń własnych. Zarówno wartości wejściowe, jak i wyjściowe zostały znormalizowane zgodnie ze wzorem (7).


$$V' = \frac{V - V_{min}}{V_{max} - V_{min}} \quad (7)$$

Tabela 1 oraz 2 zawierają znormalizowane wartości wejściowe oraz wyjściowe dla próbek wykonanych z Ti6Al4V oraz Inconel 718.

Schemat zbudowanej sieci neuronowej przedstawia rysunek 3.

Warstwa ukryta składa się z trzech podwarstw o różnych funkcjach aktywacji. Zbiór uczący składa się z dwóch podzbiorów: zbioru treningowego oraz zbioru sprawdzającego (rys. 4).

Zastosowanie tak skonstruowanej warstwy ukrytej zapobiega przeuczeniu sieci neuronowej, ponieważ jej celem jest znalezienie funkcji dopasowania dla zbioru sprawdzającego



Rys. 3. Budowa sieci neuronowej [7]

poza wartości ze zbioru uczącego. Sieć uczy się na danych ze zbioru treningowego, a co pewien czas kontroluje się uczenie na wartościach ze zbioru sprawdzającego.

Wykorzystując tak zbudowaną sieć zaimplementowano wartości wejściowe oraz wyjściowe w zbiorze uczącym i sprawdzającym oraz obliczono błąd względny wg wzoru (8).

$$\delta_{x_{rz}} = \frac{|x_{rz} - x_{ssn}|}{x_{rz}} \times 100\% \quad (8)$$

Trenowanie sieci odbywało się zgodnie z parametrami przedstawionymi na rysunkach 5-6.

W zbiorze sprawdzającym znajdowały się wartości dla próbki N22. Wartość, która powinna zostać wyliczona przez wytrenowaną sieć to $\sigma_{psr} = 0,738210665491406$. Otrzymana wartość z sieci neuronowej wyniosła $\sigma_{psrSSN} = 0,7235$. Wyliczony błąd względny jest równy $\delta_{x_{rz}} = 1,1\%$. W sieci neuronowej do wyznaczania naprężeń dla wartości wyznaczonych dla próbek Ti6Al4V zbiór sprawdzający składał się z następujących wartości wejściowych: $v_c = 0,739875$, $f = 0,646$, $a_p = 0,2$ (rys. 7-8). Wartość, która powinna zostać wyliczona przez wytrenowaną sieć wynosi $\sigma_{psr} = 0,752528658125421$. Otrzymana wartość z sieci neuronowej wyniosła $\sigma_{psrSSN} = 0,61177$. Wyliczony błąd względny wynosi $\delta_{x_{rz}} = 7,2\%$.

4. Podsumowanie


Wśród istniejących metod pomiaru naprężeń można wyróżnić metodę *ring-core*, metodę usuwania warstw (metody niszczące) oraz dyfrakcję rentgenowską, metodę ultradźwiękową czy metodę prądów wirowych (metody nieniszczące). Niestety, metody nieniszczące są czasochłonne, a aparatura bardzo droga. Metody niszczące natomiast wymagają usunięcia pewnej części materiału w celu pomiaru naprężeń, przez co element poddany identyfikacji naprężeń jest niszczone. Określanie wartości naprężeń jest zagadnieniem bardzo złożonym, a wiedza na temat naprężeń własnych w obrabianym materiale ma istotne znaczenie praktyczne. Przeprowadzone symulacje wykazały zdolność sieci neuronowych do predykcji wartości naprężeń, co otwiera nowe możliwości aktywnej identyfikacji naprężeń w trakcie procesu obróbki, zwłaszcza w odniesieniu do materiałów trudnoskrawalnych.

Lp.	v_c	f	a_p	θ_{psr}
T1	0.2601246105919	0.354	0.25	0,343897505
T11	0.7398753894081	0.354	0.25	0,418745786
T2	0.2601246105919	0.646	0.25	0,436952124
T22	0.7398753894081	0.646	0.25	0,752528658
T3	0.2601246105919	0.354	0.75	0,467296022
T33	0.7398753894081	0.354	0.75	0,608900877
T4	0.2601246105919	0.646	0.75	0,513823331
T44	0.7398753894081	0.646	0.75	0,708024275
T5	0	0.5	0.5	0,026298045
T55	1	0.5	0.5	0,708024275
T6	0.5	0	0.5	0,52596089
T66	0.5	1	0.5	0,641267701
T7	0.5	0.5	0	0
T77	0.5	0.5	1	0,627107215
T8	0.5	0.5	0.5	1

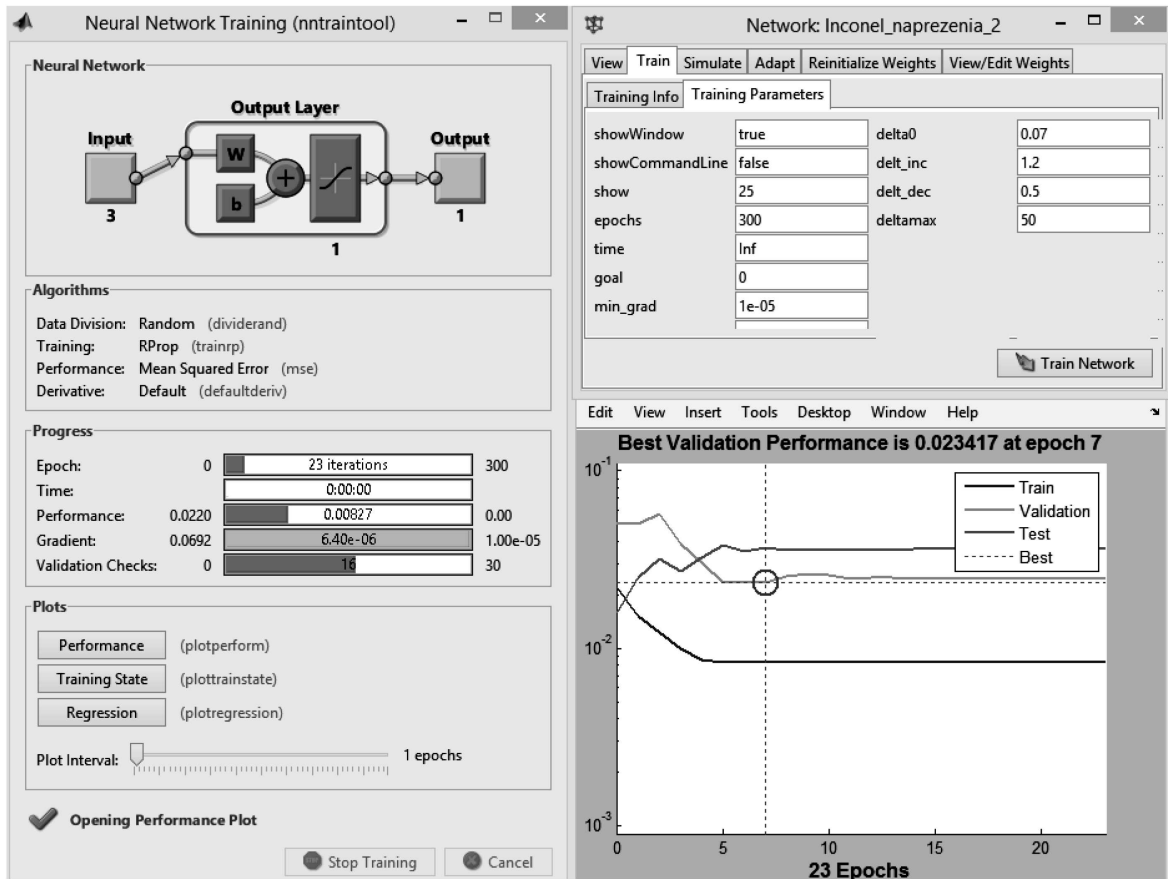
Tab. 1. Znormalizowane dane wejściowe i wyjściowe dla próbek z Ti6Al4V

Lp.	v_c	f	a_p	θ_{psr}
N1	0.2601246105919	0,2	0.25	0,282062583
N11	0.7398753894081	0,2	0.25	0,044072279
N2	0.2601246105919	0,8	0.25	0,804319083
N22	0.7398753894081	0,8	0.25	0,738210665
N3	0.2601246105919	0,2	0.75	0,427501102
N33	0.7398753894081	0,2	0.75	0,550462759
N4	0.2601246105919	0,8	0.75	0,823270163
N44	0.7398753894081	0,8	0.75	1
N5	0	0,5	0.5	0,507130895
N55	1	0,5	0.5	0,518289996
N6	0.5	0	0.5	0
N66	0.5	1	0.5	0,65814015
N7	0.5	0,5	0	0,128691053
N77	0.5	0,5	1	0,814014985
N8	0.5	0,5	0.5	0,6851829

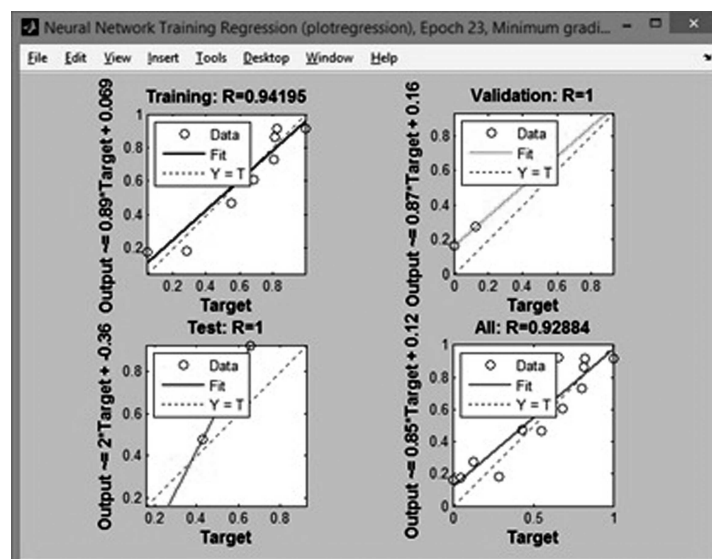
Tab. 2. Znormalizowane dane wejściowe i wyjściowe dla próbek z Inconel 718



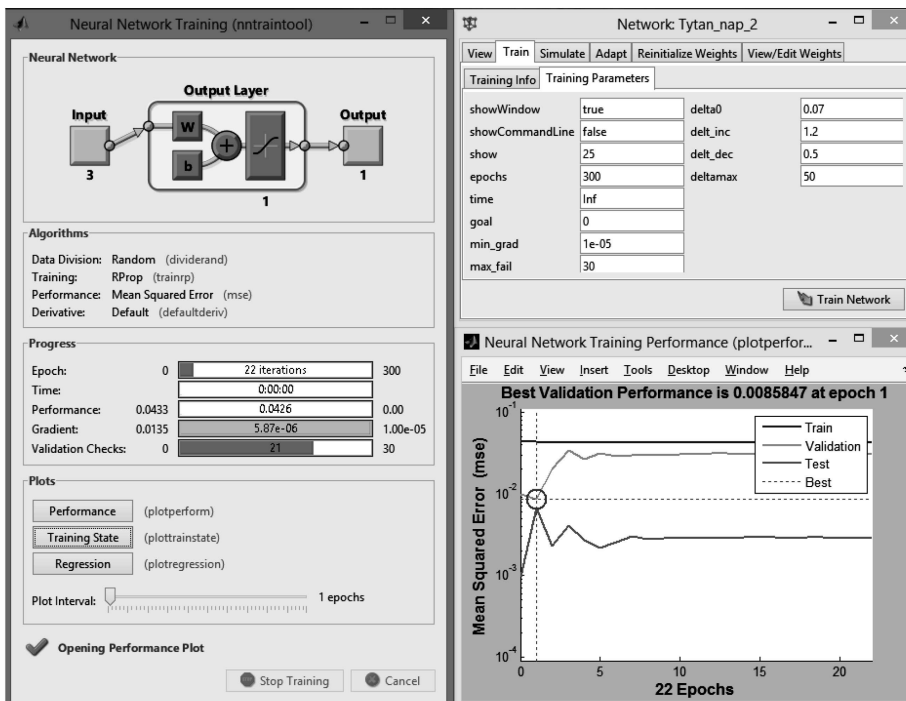
Rys. 4. Zbiory danych do uczenia sieci neuronowych [4]



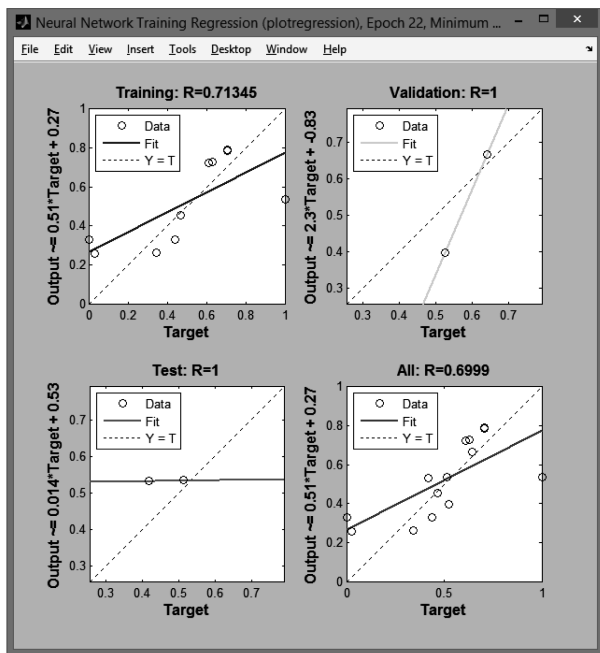
Rys. 5. Parametry, trenowania oraz wykres wydajności dla sieci do wyznaczania naprężeń dla próbek wykonanych ze stopu niklu – Inconel 718 [7]



Rys. 6. Wykresy regresji dla sieci do wyznaczania naprężeń dla próbek wykonanych ze stopu niklu – Inconel 718 [7]



Rys. 7. Parametry, trenowania oraz wykres wydajności dla sieci do wyznaczania naprężeń dla próbek wykonanych z Ti6Al4V [7]



Rys. 8. Wykresy regresji dla sieci do wyznaczania naprężeń dla próbek wykonanych z Ti6Al4V [7]

Literatura:

[1] Birger A. I., *Residual stresses (in Russian)*. Mashgiz, Moskwa 1963.
 [2] Burakowski T., *Areologia, Podstawy Teoretyczne*. Wydawnictwo Naukowe Instytutu Technologii Eksploatacji - PIB, 2013.
 [3] Gawlik J., *Prognozowanie stanu zużycia ostrzy w procesie skrawania*. Monografia nr 66, Wydawnictwo Politechniki Krakowskiej, Kraków 1988.

[4] Gawlik J., Karbowski K., *Matematyczne modelowanie procesu zużycia narzędzi skrawających. Nadzorowanie stanu narzędzi*. Monografia 231, Wydawnictwo Politechniki Krakowskiej, Kraków 1998.
 [5] Giriraj B, Prabhu Raja V., Gandhinadhan R., Ganeshkumar R., *Prediction of tool wear in high speed machining using acoustic emission technique and neural network*. "Indian Journal of Engineering & Materials Sciences", 2006, Vol. 13.
 [6] Grzesik W., *Wpływ topografii powierzchni na właściwości eksploatacyjne części maszyn*. „Mechanik” nr 8/2015.
 [7] Krajewska-Śpiewak J., *Identyfikacja wskaźników warstwy wierzchniej materiałów trudno-skrawalnych*. Praca doktorska. Politechnika Krakowska, Kraków 2016.

[8] Krajewska-Śpiewak J., Gawlik J., Piekoszewski W., Stachura K., *Identification of residual stresses in a surface layer of Ti6Al4V and Inconel 718 after process of peripheral milling*. International Conference on Surface Metrology, Poznań 2016.
 [9] Osowski S., *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006.
 [10] Senczyk D., *Naprężenia własne. Wstęp do generowania, sterowania i wykorzystania*. Wydawnictwo Politechniki Poznańskiej, Poznań 1996.
 [11] Senczyk D., *Polikrystaliczny dyfraktometr rentgenowski*. Wydawnictwo Politechniki Poznańskiej, Poznań 1999.

THE USE OF NEURAL NETWORKS FOR MODELING THE STATE OF THE SURFACE LAYER

Key words:

difficult-to-cut materials, neural networks, residual stresses, surface layer

Abstract:

The article presents result of residual stresses measured in the samples which were firstly subjected to peripheral milling. The samples were made out of difficult-to-cut materials (titanium based alloys – Ti6Al4V and nickel based alloys – Inconel 718). Milling process was carried out under different cutting parameters (cutting speed, feed and depth of cut). In order to check the possibility of neural networks for forecasting of residual stresses in case of machining of difficult-to-cut materials obtained result were implemented in neural networks.

Dr inż. Joanna KRAJEWSKA-ŚPIEWAK

Wydział Mechaniczny
 Politechnika Krakowska
 joannakrajewska.pk@gmail.com