



ZASTOSOWANIE SIECI NEURONOWYCH DO WYZNACZANIA WSPÓŁCZYNNIKA TARCIA PODCZAS KSZTAŁTOWANIA BLACH

F. STACHOWICZ, T. TRZEPIECIŃSKI

APPLICATION OF NEURAL NETWORKS FOR DETERMINATION OF FRICTION COEFFICIENT IN SHEET METAL FORMING

Abstract

Friction between the sheet and tools is one of the important factors affecting the quality of drawpiece, so that the clarification of the friction is essential for modeling and analysis of sheet metal forming processes. Friction is a complex variable that results from the interactions between the sheet metal surfaces, the surface of forming tools and the lubricant used. Since analytical expression of the friction coefficient between tool and formed material is difficult to achieve, the Multi-layer Perceptron (MLP) was trained using measured process data of friction test. The MLP had surface roughness parameters and test condition (lubricant, load) as input, and friction coefficient as output. It was confirmed that this system is a valid alternative for the quick responsible method of friction coefficient determination.

1. WPROWADZENIE

Tarcie występujące na powierzchni styku narzędzia z odkształcanym plastycznie metalem wywiera istotny wpływ na przebieg odkształcenia plastycznego, a przez to na własności użytkowe i na trwałość narzędzi. W wyniku istnienia oporów tarcia występuje zużycie narzędzi, przy czym zarówno mechanizm, jak też intensywność zużycia są funkcją oporów i rodzaju tarcia. Główne czynniki wpływające na zjawiska trybologiczne w procesach przeróbki plastycznej to: makro- i mikrogeometria styku, kinematyka ruchu narzędzi, dynamika obciążeń, czynniki fizykochemiczne na powierzchni rozdziału pary trącej oraz temperatura (Darendeiler i in., 2002; Gierzyńska, 1983; Lovell and Deng, 2002; Matuszak, 2000).

W procesie tłoczenia można wyróżnić kilka obszarów zróżnicowanych pod względem stanu naprężeń, stanu odkształceń, prędkości przemieszczeń i warunków tarcia: kołnierz wytłoczki, obszar krawędzi ciągniczej stępła i matrycy, ścianka i dno wytłoczki. Rolę i skutki występowania oporów tarcia trudno jednoznacznie zdefiniować. Do niekorzystnych skutków występowania oporów tarcia należą m.in. (Blau, 2001; Gierzyńska, 1983):

- nierównomierność odkształceń, powodująca zmiany grubości ścianki wytłoczki,
- wzrost nacisku wywieranego przez stempel, spowodowany oporami tarcia w dociskaczu i na krawędzi matrycy, powodującego niebezpieczeństwo oderwania dna wytłoczki,

- wzrost naprężeń promieniowych, zwiększających ryzyko powstania pęknięć w wytłoczce,
- zmniejszenie trwałości narzędzi oraz pogorszenie gładkości powierzchni wytłoczki.

Do korzystnego wpływu oporów tarcia na proces tłoczenia można zaliczyć tarcie odkształcanej blachy o powierzchnię stempla, gdyż zwiększa się dopuszczalna wartość maksymalnej siły wytłaczania. Pod wpływem sił promieniowych wytłoczka jest obciskana na powierzchni bocznej stempla. Powstała w ten sposób na powierzchni styku stempla i blachy siła tarcia powoduje odciążenie, niebezpiecznego ze względu na zerwanie, obszaru przejścia ścianki bocznej w dno wytłoczki. Niekorzystnemu zjawisku tarcia, na powierzchniach kontaktu odkształcanej blachy z matrycą oraz dociskaczem, można przeciwdziałać poprzez stosowanie odpowiednich smarów i zwiększenie twardości narzędzi. W trakcie procesu odkształcania smar powoduje zmianę topografii powierzchni, chropowatości, charakteru płynięcia metalu odkształcanego, zmniejszenie nacisku jednostkowego, zmniejszenie współczynnika tarcia oraz polepszenie jakości powierzchni wyrobu. Ponadto przez zastosowanie odpowiednich smarów uzyskuje się bardziej równomierny poślizg w strefie styku odkształcanego metalu z narzędziem, powstanie poduszki smarowej między współpracującymi powierzchniami. Prowadzi to do prawie całkowitego wyeliminowania połączeń tarciovych, powodując tym samym zmniejszenie oporów tarcia.

Do najważniejszych zadań smarów stosowanych w procesie tłoczenia należy między innymi (Gierzyńska, 1983):

- zmniejszanie oporów tarcia,
- ochrona narzędzia przed zbyt intensywnym zużyciem,
- rozdział powierzchni trących na styku narzędzia i blachy,
- zapobieganie uszkodzeniom powierzchni wytłoczki,
- ułatwianie płynięcia materiału.

Nadto istotną cechą smaru są właściwości antykorozyjne oraz nietoksyczne. Ze względu na ochronę środowiska przy doborze smaru do procesu kształtowania blach należy brać także możliwość utylizacji zużytych smarów.

W modelowaniu plastycznego kształtowania blach najczęściej znajduje zastosowanie prawo tarcia Coulomba, według którego opory tarcia nie zależą od nominalnej wielkości powierzchni styku i są proporcjonalne do obciążenia. Jednakże jest ono słuszne w pewnym ograniczonym zakresie, gdyż tarcie w znacznym stopniu zależy od prędkości poślizgu oraz zmieniającej się geometrii styku. Prawo Coulomba może być stosowane w zakresie naprężeń normalnych

do powierzchni kształtowanej blachy nie przekraczających naprężeń uplastyczniających. Kształt powierzchni styku wpływa na rodzaj i stan naprężeń głównie w warstwie wierzchniej. W rzeczywistości powierzchnie przylegają do siebie tylko wierzchołkami nierówności, które następnie, pod wpływem działania sił nacisku, zostają odkształcone plastycznie aż powstała w ten sposób powierzchnia styku będzie wystarczająca do przeniesienia obciążenia (Zhang i in., 2003).

Badania symulujące warunki tarcia i smarowania można podzielić na testy symulujące procesy i testy symulujące warunki trybologiczne (Świątkowski, 2000; Zdravecka i in., 2001; Matuszak i Kręcisz, 2003). Testy symulujące procesy mają za zadanie modelowanie operacji przeróbki plastycznej z zachowaniem kinematyki procesu. Testy symulujące warunki trybologiczne modelują określone zjawisko, często bez zachowania kinematyki procesu. Obie grupy testów można podzielić na próby z bezpośrednim lub pośrednim pomiarem współczynnika tarcia. W metodach pośrednich wyznaczania współczynnika tarcia jest wyznaczany na podstawie pomiaru innych wielkości np. siły tarcia i siły normalnej. W oparciu o przyjęty model tarcia następuje obliczenie wartości współczynnika tarcia. Wadą tego typu metod jest to, że umożliwiają wyznaczenie uśrednionej wartości współczynnika tarcia, natomiast nie umożliwiają pomiaru i określenia rzeczywistych oporów tarcia. W próbach bezpośrednich następuje rzeczywisty pomiar naprężeń tarcia na powierzchniach styku. Dla potrzeb plastycznego kształtowania blach opracowano szereg prób modelujących warunki tarcia w poszczególnych obszarach wytłoczki zróżnicowanych pod względem stanu naprężeń, odkształceń i prędkości przemieszczeń. Stosowane są ponadto próby symulujące przy pomocy przyrządów o kinematyce procesu rzeczywistego oraz uniwersalne przyrządy, pozwalające na modelowanie zjawiska tarcia w różnych strefach wyrobu lub w grupie procesów kształtowania blach (Hao i in., 1999; Lee i in., 2002; Wang i in., 1996).

Głównym celem pracy było określenie wartości współczynnika tarcia dla różnego rodzaju blach stosowanych do wykonywania wytłoczek. Ze względu na znaczną ilość czynników mających wpływ na wartość oporów tarcia pojawiających się podczas plastycznego kształtowania blach opracowanie analitycznych zależności służących do wyznaczenia wartości współczynnika tarcia, dla danych warunków realizacji procesów, jest praktycznie niemożliwe. Postanowiono zatem wykorzystać do tego celu sztuczne sieci neuronowe – zarówno modelu regresyjnego jak i modelu prognostycznego.

2. MATERIAŁY I SPOSÓB PRZEPROWADZENIA BADAŃ

Próby tarcia przeprowadzono dla blach mosiężnych i aluminiowych o różnym stopniu umocnienia oraz dla blach stalowych o różnej kategorii tłoczności. Wartość parametrów mechanicznych (tablica 1) wyznaczona w próbie jednoosiowego rozciągania pasków wyciętych z arkusza blachy wskazuje na znaczne zróżnicowanie właściwości materiału blach. Stwierdzono również duże zróżnicowanie badanych blach pod względem topografii powierzchni, największą chropowatością cechowały się blachy stalowe. Analizując wyniki pomiarów średniej arytmetycznej rzędnych profilu chropowatości powierzchni (tablica 1), można zauważyć iż wartości mierzone prostopadle do kierunku walcowania Ra90 mają wartości wyższe aniżeli mierzone wzdłuż do kierunku walcowania Ra0. Świadczy to o istnieniu na kierunkowej topografii powierzchni blach.

Próby tarcia przeprowadzono metodą przeciągania pasa blachy umieszczonego między dwoma walcowymi przeciwpróbkami (rysunek 1). Próbki do testu tarcia o długości około 200 mm i szerokości 20 mm wycięto z arkuszy blach. Przeciwpróbki w postaci rolek o średnicy 20 mm i szerokości 22 mm zostały wykonane ze stali. Do badań użyto czterech kompletów rolek o następujących parametrach chropowatości Ra:

2,5; 1,25; 0,63; 0,32 mm, mierzonych równoległe do osi walców. Podczas badań mierzono za pomocą czujników tensometrycznych wielkość siły docisku oraz siły ciągnięcia. Z uwagi na to, że opory tarcia nie są stałe w czasie całego procesu odkształcenia plastycznego do rejestracji danych zastosowano komputerową aparaturę pomiarową pozwalającą na ciągły zapis wyników. W wyniku przeciągania blachy z prędkością 0,4 mm/s otrzymywano ok. 200 punktów pomiarowych dla każdego eksperymentu, droga tarcia w tych warunkach wynosiła około 7 mm. Stosowane w próbie siły docisku wynosiły 0,4; 0,8; 1,2; 1,6 oraz 2 kN. Wartość siły docisku rolek zwiększano przy zatrzymanym przesuwie próbki. Próbę przeprowadzono w warunkach tarcia technicznie suchego oraz ze smarowaniem olejem L-AN46 obu powierzchni próbek. W celu wyeliminowania wpływu czynników zewnętrznych powierzchnia próbek i rolek została odtłuszczona za pomocą acetonu. Na podstawie przygotowanego zbioru danych wyznaczono za pomocą arkusza kalkulacyjnego Excel wartość współczynnika tarcia według zależności:

$$\mu = \frac{F_T}{2 \cdot F_N}$$


gdzie: F_T – siła ciągnięcia, F_N – siła docisku.

W początkowym okresie przeciągania paska blachy stwierdzono spadek wartości siły docisku i siły

Tablica 1. Wybrane własności mechaniczne i parametry chropowatości blach.

Table 1. Selected mechanical properties and surface roughness parameters of sheets.


Materiał		Granica plastyczności R _{0,2} MPa	Granica wytrzymałości R _m MPa	Parametr chropowatości	
				Ra ⁰ μm	Ra ⁹⁰ μm
Blachy mosiężne	M63 05 r	110	328	0,18	0,28
	M63 07 z4	324	384	0,17	0,20
	M63 05 z6	474	507	0,14	0,22
	M70 04 z6	546	574	0,26	0,38
	M80 10 r	121	282	0,14	0,16
	M90 08 z4	337	352	0,40	0,60
Blachy stalowe	SB 10	196	336	1,40	1,74
	BSB 10	151	282	1,64	1,79
	Z II T 10	196	362	1,26	1,69
Blachy ze stopów aluminium	AA5251 08 H14	212	234	0,22	0,28
	AA5754 08 H14	220	288	0,26	0,41
	AA5754 06 H18	248	295	0,26	0,36
	AA5754 08 H24	173	280	0,22	0,24



Rysunek 1. Schemat przyrządu do badań: 1 - korpus, 2 - przeciwpróbkki, 3 - uchwyt maszyny wytrzymałościowej, 4 - próbka, 5 - kolek blokujący, 6, 7 - tensometry.

Figure 1. Scheme of experimental device: 1 - frame, 2 - working rolls, 3 - grip of testing machine, 4 - specimen, 5 - fixing pin, 6, 7 - load cells.

ciągnięcia, w dalszym etapie siły ulegały stabilizacji (rysunek 2). Obciążenie nieruchomej próbki powoduje powstanie lokalnych odkształceń plastycznych w strefie kontaktu, przez co zwiększa się początkowa powierzchnia styku. Następnie w wyniku przeciągania próbki powierzchnia styku zmniejsza się. Istotny wpływ na zmniejszenie się siły docisku, a co za tym idzie oporów tarcia może mieć zjawisko tarcia kinetycznego.



Rysunek 2. Przebieg siły docisku FN i siły ciągnięcia FT w funkcji przemieszczenia blachy dla M90 07 z6 ($F_N = 1,5 \text{ kN}$, R_a rolki 1,25 mm): a) ze smarowaniem, b) bez smarowania.

Figure 2. The run of the clamping force FN and pulling force FT versus specimen displacement for the M90 07 z6 brass sheet: under "dry" (a) and "oil" (b) conditions.

3. ZASTOSOWANIE MODELU REGRESYJNEGO SZTUCZNYCH SIECI NEURONOWYCH DO OKREŚLANIA WARTOŚCI WSPÓLCZYNNIKA TARCIA

Sieci neuronowe przechodzące w ostatnich latach dynamiczny rozwój są narzędziem umożliwiającym budowę modeli liniowych oraz nieliniowych rozwiązujących złożone zadania klasyfikacyjne i regresyjne. Jedną z podstawowych zalet sieci neuronowych jest fakt, że w wyniku procesu uczenia sieć może nabyć zdolności przewidywania wyjściowych sygnałów na podstawie obserwacji tzw. ciągu uczącego (tj. określonej liczby sekwencji sygnałów wejściowych i odpowiadających im sygnałów wyjściowych) bez konieczności stawiania w sposób jasny hipotez o naturze związku pomiędzy danymi wejściowymi, a przewidywanymi wynikami (Tadeusiewicz, 1998). Sieci neuronowe są szczególnie przydatne w przypadkach, gdy zależność pomiędzy zmiennymi wejściowymi i wyjściowymi jest bardzo złożona. Projektowanie sieci w programie ST Neural Networks sprowadza się do następujących etapów:

- wybór początkowej struktury sieci,
- automatyczne przeprowadzenie szeregu eksperymentów z każdą konfiguracją i zachowanie konfiguracji najlepszej tzn. o najmniejszym błędzie walidacyjnym,
- jeśli sieć nie osiąga zadanego poziomu błędu należy podjąć próbę dodania nowych neuronów do warstwy ukrytej lub dodania nowej warstwy ukrytej,
- w przypadku pojawienia się przeuczenia sieci, należy usunąć pewną liczbę neuronów ukrytych.

Jednym z najważniejszych zadań koniecznych do zbudowania optymalnego modelu sieci neuronowej jest odpowiedni dobór zmiennych wejściowych mających istotny wpływ na wartość zmiennej wyjściowej. Dodanie na wejście sieci kolejnego neuronu powoduje nadmierny rozrost jej struktury, a także stwarza większe wymagania odnośnie liczby punktów uczących. Z kolei nieuwzględnienie na wejściu sieci istotnych z punktu widzenia korelacji ze zmienną wyjściową parametrów, może spowodować obniżenie jakości odpowiedzi sieci neuronowej.

Perceptron wielowarstwowy posiadający odpowiednią liczbę warstw i neuronów może modelować funkcje o prawie dowolnej złożoności. Można wykazać, że przy użyciu sieci neuronowej zawierającej tylko dwie warstwy ukryte można aproksymować z dostateczną dokładnością dowolną funkcję nieliniową wielu zmiennych (Hertz i in., 1993). Zadaniem perceptronu wielowarstwowego realizującego problem regresyjny jest oszacowanie wartości zmiennej wyj-

ściowej, gdy dane są wartości zmiennych na wejściu.

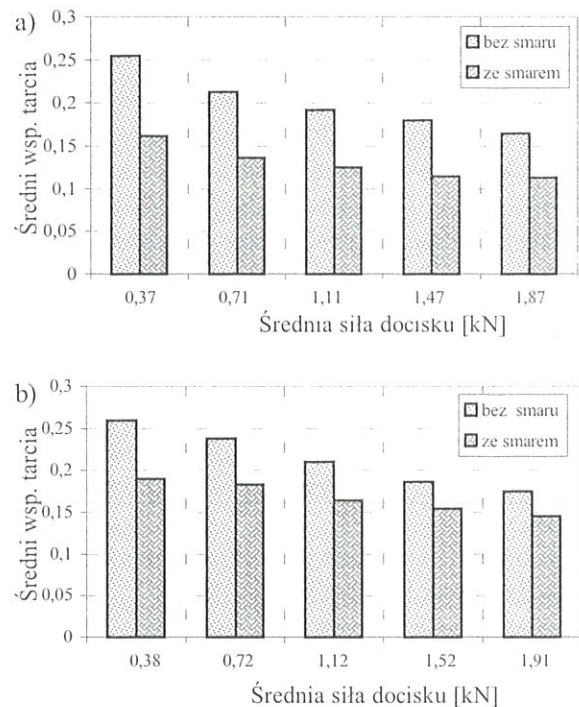
Sztuczna sieć neuronowa pozwala także przewidywać wielkości wyjściowe procesu, których zależność od różnych parametrów tego procesu jest określona przez funkcje o zróżnicowanym przebiegu i kształcie. Intelligent Problem Solver w STATISTICA Neural Networks sam przeprowadza eksperymenty z różną liczbą neuronów ukrytych, wielokrotnie powtarzając proces uczenia dla każdej badanej struktury i dokonuje wyboru najlepszych modeli sieci, kierując się wartością błędu walidacyjnego i wielkością sieci. Najważniejszą informacją uwzględnianą przy ocenie sieci jest wartość błędu walidacyjnego.

Spśród wszystkich par uczących (sygnałów wejściowych i odpowiadających im sygnałów wyjściowych) wydzielono losowo około 10% przypadków, które zaliczono do zbioru walidacyjnego. Dane z tej grupy posłużyły do niezależnej kontroli algorytmu uczenia. Pozostała liczba przypadków została przypisana do zbioru uczącego. Jako parametr opisujący jakość procesu uczenia przyjęto wartość błędu średniokwadratowego RMS. Aby zapobiec procesowi przeuczenia sieci, jako kryterium zakończenia uczenia sieci przyjęto moment, gdy nie następuje już dalsze zmniejszanie się wartości błędu RMS zbioru walidacyjnego. Proces uczenia sieci przebiegał metodą wstecznej propagacji błędu, która jest obecnie najchętniej stosowanym algorytmem uczenia sieci neuronowych.

3.1. Wyniki dla blach mosiężnych

Jak wynika z przeprowadzonych badań dla blach mosiężnych w większości przypadków wartość współczynnika tarcia maleje wraz ze wzrostem siły docisku rolek. Wartości współczynnika tarcia wahają się w granicach $m = 0,08 \div 0,22$ w warunkach smarowania olejem oraz $m = 0,14 \div 0,33$ w warunkach tarcia technicznie suchego. Zastosowanie środka smarnego zmniejsza opory tarcia o około 17÷40% w zależności od parametru Ra chropowatości zastosowanych rolek oraz od siły docisku rolek. W zakresie małych sił docisku zastosowany smar w większym stopniu obniżał opory tarcia (rysunek 3).

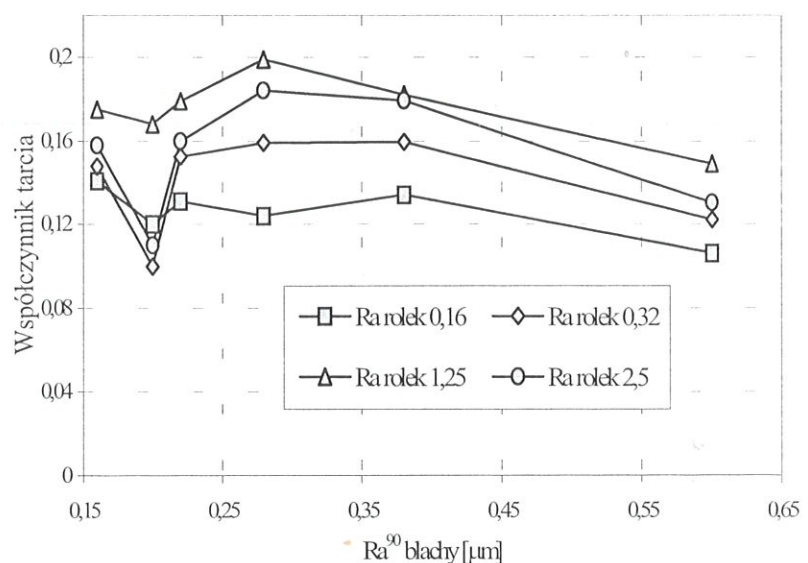
Czynnikami istotnie wpływającym na opory tarcia jest chropowatość powierzchni blach. W praktyce wiele uwagi poświęca się ukonstytuowaniu takiej topografii powierzchni blach, która umożliwi utrzymywanie filmu smarnego w procesie tłoczenia. Wartości współczynnika tarcia wyznaczone w warunkach smarowania dla



Rysunek 3. Zależność średniego współczynnika tarcia wyznaczonego dla serii blach mosiężnych od średniej siły docisku rolek: a) Ra rolek 0,63 mm, b) Ra rolek 1,25 mm.

Figure 3. Mean friction coefficient versus mean clamping force for series of brass sheets: surface roughness of rolls $Ra = 0,63$ mm (a) and $Ra = 1,25$ mm (b).

różnej chropowatości rolek wykazują nieliniową zależność od parametru Ra^{90} (rysunek 4). Lokalne minimum wartości współczynnika tarcia obserwowane dla blachy o chropowatości $Ra^{90} = 0,20 \mu\text{m}$ wynikać może z odmiennej topografii powierzchni, cechującej się innym rozkładem kieszeni smarnych wyrażanym po-



Rysunek 4. Zależność współczynnika tarcia od parametru Ra^{90} blach mosiężnych dla średniej siły do-cisku 0,71 kN rolek o różnej chropowatości, w warunkach smarowania olejem

Figure 4. Friction coefficient as a function of the surface roughness parameter Ra^{90} of brass sheets under clamping force of 0,71 kN for various surface roughness of rolls, under lubrication condition.




przez wartość wskaźnika WC (Wihlborg and Craford, 2001).

Typując czynniki wpływające na opory tarcia blachy należy uwzględnić takie czynniki, które istotnie wpływają na tarcie, a jednocześnie są względem siebie niezależne. Wybór zmiennych wpływających na wielkość współczynnika tarcia jest bardzo trudny ze względu na złożony wpływ wielu parametrów (często ze sobą skorelowanych) na opory tarcia. Jako sygnały wejściowe do sieci wytypowano następujący zestaw zmiennych:

- parametr Ra^0 oraz Ra^{90} chropowatości powierzchni blach mierzona odpowiednio w kierunku wzdłużnym i poprzecznym do kierunku walcowania,
- parametr Ra chropowatości rolek mierzony w kierunku równoległym do osi rolek,
- warunki smarowania reprezentowane przez cyfrę 1 dla tarcia technicznie suchego i cyfrę 2 w przypadku smarowania olejem,
- siła docisku rolek.

Po przeanalizowaniu zadanego zestawu danych uczących Intelligent Problem Solver wyznaczył zbiór „najlepszych sieci”. Jako model predykcji wykorzystano sieć o pięciu neuronach w warstwie wejściowej, dziewięciu neuronach w warstwie ukrytej oraz jednym neuronie w warstwie wyjściowej (rysunek 5).

Uczenie sieci przeprowadzono w oparciu o wbudowany w ST Neural Networks algorytm wstecznej propagacji błędów. Współczynnik uczenia był równy 0,1. Procesowi uczenia nadano pewną bezwładność przez zastosowanie członu tzw. momentum równego 0,3. Zastosowanie małej wartości współczynnika uczenia wydłuża czas obliczeń, ale jednocześnie powoduje precyzyjne „skoki” po powierzchni błędu w celu osiągnięcia minimum. Duże wartości współczynnika uczenia prowadzą do gwałtownych zmian parametrów sieci, co może doprowadzić do niestabilności procesu uczenia. Wprowadzenie członu momentum powoduje, że wartości wag nie zmieniają się zbyt gwałtownie i często, co przyspiesza i stabilizuje proces uczenia. Wartości współczynnika uczenia i momentum były jednakowe dla wszystkich sieci przedstawionych w niniejszej pracy. W trakcie kolejnych prezentacji zbioru trenującego podczas uczenia dane uczące były randomizowane, tak aby nie były wielokrotnie prezentowane w tej samej kolejności. Ilość rekordów danych pokazywanych sieci wyniosła dla zbioru uczącego – 200. Zbiór walidacyjny zawierał 20 rekordów danych. Proces uczenia charakteryzował się ciągłym spadkiem błędu RMS zbioru uczącego. Na uwagę zasługuje fakt, że w całej fazie procesu uczenia błąd RMS zbioru weryfikującego był większy o ok. 17÷25% od błędu RMS uczenia. Proces uczenia trwał 140000 iteracji i został przerwany po zaobserwowaniu pierwszych objawów przeuczenia w



Rysunek 5. Struktura sieci neuronowej modelu regresyjnego dla blach mosiężnych


Figure 5. Architecture of the regression network for brass strips.

postaci braku dalszego spadku błędu RMS zbioru walidacyjnego. Wartości błędu RMS wyniosły 0,011 dla zbioru uczącego i 0,013 dla zbioru weryfikującego.

Oceniając model regresyjny należy zwrócić szczególną uwagę na następujące mierniki jakości sieci (Lula, 2004):


- iloraz odchylenia standardowego błędów i odchylenia standardowego wartości zmiennej objaśnianej – S. D. Ratio,
- współczynnik korelacji Pearsona.

Mierniki te są wyznaczane niezależnie dla każdego ze zbiorów danych. Dla bardzo dobrego modelu wartość S.D. Ratio wynosi poniżej 0,1. Współczynnik korelacji Pearsona liczony pomiędzy rzeczywistymi i obliczonymi przez sieć neuronową wartościami zmiennej objaśnianej wynosi: dla zbioru uczącego 0,9871, dla zbioru weryfikującego 0,9611. S. D. Ratio dla powyższych zbiorów wynosił odpowiednio: 0,1794 i 0,2437. Wysoka wartość miernika korelacji przy niskiej wartości S. D. Ratio dla zbioru uczącego świadczy o dobrych własnościach aproksymacyjnych sieci neuronowej. Znalazło to zatem swoje odzwierciedlenie w bardzo dobrym dopasowaniu przewidywań sieci do danych doświadczalnych w całym przedziale siły docisku (rysunek 6), zwłaszcza dla rolki o $Ra = 0,63$ oraz 1,25 mm, gdzie błąd popełniany przez sieć w punktach prezentowanych podczas uczenia jest mniejszy niż 0,004. Rysunek 7 przedstawia przebieg zmienności współczynnika tarcia blachy M63 05 r w funkcji parametru Ra chropowatości rolki w warunkach smarowania powierzchni blachy olejem dla danych doświadczalnych oraz wyznaczonych przez model neuronowy. Widoczna jest zdolność sieci do dopasowywania się do danych uczących mających charakter wyraźnie nieliniowy. Jak należało oczekiwać wartość współczynnika tarcia wzrasta wraz ze wzrostem chropowatości rolek, ale tylko do pewnej wartości. W zakresie mniejszych chropowatości wpływ wielkości siły docisku rolek jest mniej widoczny. Spadek wartości współczynnika tarcia dla rolek o największej chropowatości wynikać może z lepszej adhezji cząstek smaru do powierzchni narzędzi.




Rysunek 6. Porównanie danych doświadczalnych oraz wyznaczonych przez sieć neuronową dla blachy M63 05 r – test ze smarowaniem (górny) oraz bez smarowania (dolny).

Figure 6. The friction coefficient for the M63 05 r sheet metal, obtained under lubricant condition (top) and dry friction (bottom) – comparison between experimental data and the MLP's regression model.



Rysunek 7. Zależność współczynnika tarcia od chropowatości oraz siły docisku rolek – dla danych doświadczalnych oraz wyznaczonego przez sieć neuronową dla mosiądzu M63 05 r, test ze smarowaniem.

Figure 7. Friction coefficient dependence on the surface roughness of rolls and clamping force – experimental data and neural network prediction for the M63 05 r sheet metal, lubrication condition test.



Rysunek 8. Zależność średniego współczynnika tarcia wyznaczonego dla serii blach stalowych od średniej siły docisku rolek: a) Ra rolek 0,63 mm, b) Ra rolek 1,25 mm.

Figure 8. Mean friction coefficient versus mean clamping force for series of steel sheets: surface roughness of rolls $Ra = 0,63$ mm (a) and $Ra = 1,25$ mm (b).

3.2. Wyniki dla blach stalowych

Badania przeprowadzone dla próbek stalowych wykazały, podobnie jak w przypadku próbek mosiężnych spadek wartości współczynnika tarcia wraz ze wzrostem siły docisku. W warunkach smarowania powierzchni próbek olejem wartości współczynnika tarcia wahają się w granicach $m = 0,09 \div 0,19$, natomiast przy braku smarowania $m = 0,14 \div 0,27$ w zależności od kategorii blach, parametru Ra chropowatości powierzchni blachy i rolek, siły docisku rolek. Zastosowanie smaru zmniejsza opory tarcia o ok. 18÷37%. Zauważono jednocześnie, że przy wzroście siły docisku smaru w mniejszym stopniu zmniejsza opory tarcia (rysunek 8).

Wybrane przebiegi zmian wielkości współczynnika tarcia w zależności od zmiennej siły docisku oraz parametru Ra chropowatości blach stalowych (rysunek 9) mają inny charakter niż w przypadku blach mosiężnych. Należy jednak zauważyć, iż chropowatość blach stalowych była znacznie większa. Dla blach o najwyższej wartości parametru chropowatości Ra mogło dochodzić do zazębienia się nierówności na powierzchni blachy oraz powierzchni narzędzi, co powodowało wzrost oporów przy przemieszczaniu się próbek.

Podobnie jak w przypadku blach mosiężnych zestaw sygnałów wejściowych oraz strukturę sieci neuronowej określono przy pomocy modułu Intelligent Problem Solver. Do modelowania współczynnika tarcia blach stalowych wykorzystano sieć o 5 neuronach w warstwie wejściowej, siedmiu neuronach




w warstwie ukrytej oraz jednym neurone w warstwie wyjściowej. Zbiór walidacyjny zawierał 12 rekordów danych.

Proces uczenia charakteryzował się szybkim spadkiem błędu RMS uczenia i weryfikacji w pierwszych 25000 epokach uczenia. W ciągu dalszych 55000 iteracji zaobserwowano równomierny spadek obu błędów. Po wykonaniu ok. 80000 prezentacji zbioru uczącego przez algorytm uczenia wartość błędu RMS weryfikującego ustabilizowała się na poziomie 0,0058, wartość błędu RMS uczenia wyniosła 0,0079. Otrzymane mierniki jakości sieci (tablica 2), szczególnie współczynnik korelacji Pearsona świadczą o wysokiej zgodności otrzymanego modelu z danymi doświadczalnymi.

Wartości współczynnika tarcia blachy ze stali SB o powierzchnię rolek o różnej chropowatości, uzyskane z danych doświadczalnych pomiaru siły docisku i siły ciągnięcia oraz wyznaczone przez perceptron, wykazują duży stopień korelacji (rysunek 10). Charakter zmian wartości współczynnika tarcia w zależności od wskaźnika topografii powierzchni rolek jest podobny jak w przypadku blach mosiężnych, z tą różnicą że dla całego zakresu parametru chropowatości rolek Ra , wpływ wielkości docisku rolek w przybliżony sposób wpływa na wielkość oporów tarcia.

3.3. Wyniki dla blach aluminiowych

Wyniki badań blach aluminiowych, podobnie jak w przypadku blach mosiężnych i stalowych świadczą o istnieniu analogicznej zależności między siłą docisku a wielkością współczynnika tarcia. Wzrost siły docisku rolek powoduje zmniejszenie współczynnika tarcia. Wartość współczynnika tarcia zmienia się w granicach $m = 0,09 \div 0,18$ przy smarowaniu olejem oraz $m = 0,12 \div 0,29$ w warunkach tarcia suchego. Smarowanie powierzchni próbek aluminiowych zmniejsza opory tarcia o $21 \div 38\%$, z tym, że największą redukcję wielkości współczynnika tarcia w związku ze zmianą warunków tarcia obserwuje się dla mniejszych sił docisku (rysunek 11).




Rysunek 9. Zależność współczynnika tarcia od parametru Ra^0 blach stalowych dla różnych sił docisku rolki o chropowatości $Ra = 0,63$ mm, w warunkach smarowania olejem.

Figure 9. Friction coefficient as a function of the surface roughness parameter Ra^0 of steel sheets for different clamping force, surface roughness of rolls $Ra = 0,63$ mm, under lubrication condition.

Tablica 2. Wybrane statystyki regresji modelu regresyjnego dla blach stalowych.

Table 2. Select statistic data of regression model of steel sheets.

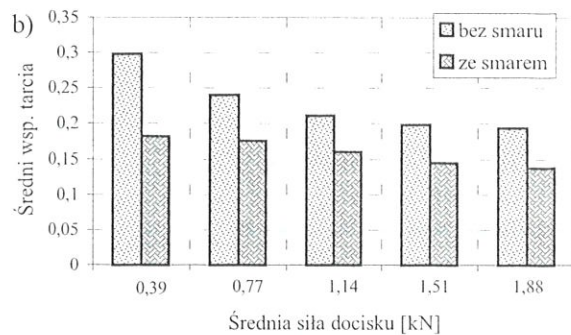

	Zbiór uczący	Zbiór walidacyjny
Iloraz odchylenia	0,1714	0,1688
Korelacja	0,9889	0,9904



Rysunek 10. Zależność współczynnika tarcia od chropowatości oraz siły docisku rolek, dla danych doświadczalnych oraz wyznaczonego przez sieć neuronową, dla stali SB w warunkach smarowania.

Figure 10. Friction coefficient dependence on the surface roughness of rolls and clamping force, experimental data and neural network prediction for the SB steel sheet, under lubrication condition.

Zmiany wartości współczynnika tarcia ze wzrostem chropowatości blach aluminiowych mają różną intensywność dla różnych chropowatości powierzchni rolek (rysunek 12), trudno jest znaleźć wyraźnych za-



Rysunek 11. Zależność średniego współczynnika tarcia wyznaczonego dla serii blach aluminiowych od średniej siły docisku rolek: a) Ra rolek 0,63 mm, b) Ra rolek 1,25 mm.

Figure 11. Mean friction coefficient versus mean clamping force for series of aluminium sheets: surface roughness of rolls $Ra = 0,63$ mm (a) and $Ra = 1,25$ mm (b).

leżności pomiędzy tymi parametrami – stąd zasadne jest zastosowanie do tego celu sieci neuronowych.

Sieć neuronowa wykorzystana do określania współczynnika tarcia blach aluminiowych miała pięć neuronów w warstwie wejściowej, osiem neuronów w warstwie ukrytej oraz jeden neuron w warstwie wyjściowej. Ilość rekordów danych pokazywanych sieci wyniosła dla zbioru uczącego - 144. Zbiór walidacyjny zawierał 16 rekordów danych. W trakcie procesu uczenia trwającego 130000 epok wartość błędu RMS zbioru weryfikującego ustabilizowała się na poziomie 0,0083. Błąd RMS zbioru uczącego wyniósł 0,0073. Tablica 3 przedstawia wybrane statystyki regresji modelu neuronowego.

Na rysunku 13 można zaobserwować bardzo dobre właściwości aproksymacyjne zastosowanej sieci neuronowej do określania zależności współczynnika tarcia od wybranych parametrów testu w warunkach tarcia technicznie suchego. Średni błąd popełniony przez sieć w punktach prezentowanych podczas ucze-

Tablica 3. Wybrane statystyki regresji modelu regresyjnego dla blach aluminiowych.

Table 3. Selected statistical data of regression model for aluminium sheets.

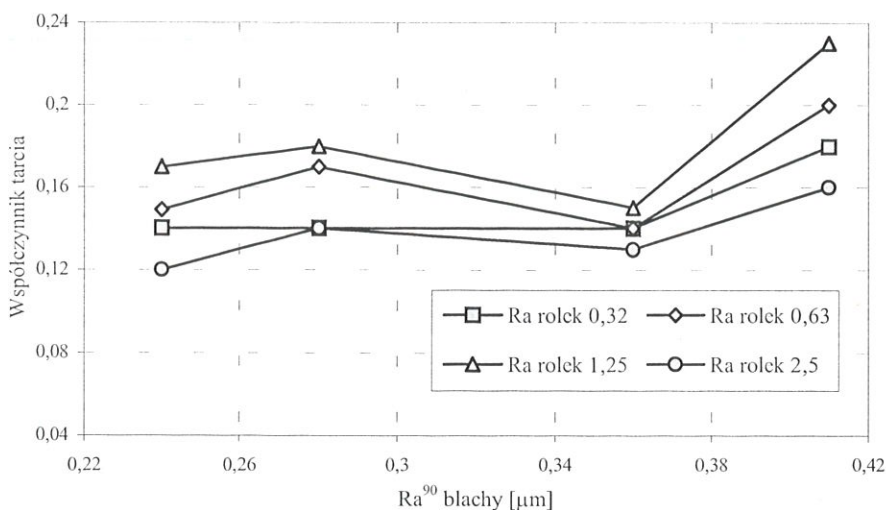
	Zbiór uczący	Zbiór walidacyjny
Iloraz odchylenia	0,1452	0,1495
Korelacja	0,9896	0,9892

nia dla rolek o $Ra = 0,32$ mm wynosi $RMS = 0,0010$, podobnie dla rolek o $Ra = 1,25$ mm $RMS = 0,0012$.

4. PROGNOZOWANIE WIELKOŚCI WSPÓLCZYNNIKA TARCIA DLA BLACH MOSIĘŻNYCH

W eksperymencie neuronowym mającym na celu sprawdzenie możliwości zastosowanie sieci neuronowej do przewidywania wielkości współczynnika tarcia wykorzystano zbiór trenujący zawierający wyniki prób tarcia pięciu blach mosiężnych (200 rekordów uczących). Zgodność wartości na wyjściu sieci testowano na podstawie wyników próby tarcia dla blachy mosiężnej M70 04 z6 (nieobecnej w zbiorze uczącym) w liczbie 40 rekordów. W celu weryfikacji zbieżności algorytmu uczenia dodatkowo ze zbioru trenującego wydzielono losowo zbiór walidacyjny zawierający 10% rekordów uczących. Uczenie sieci przeprowadzono dla kilku sieci zawierających 5 neuronów w warstwie wejściowej, 1 neuron w warstwie wyjściowej i 8–13 neuronów w warstwie ukrytej z powodu otrzymanych zbyt dużych błędów RMS dla zbioru testującego posta-

nia dla rolek o $Ra = 0,32$ mm wynosi $RMS = 0,0010$, podobnie dla rolek o $Ra = 1,25$ mm $RMS = 0,0012$.



Rysunek 12. Zależność współczynnika tarcia od parametru $Ra90$ blach aluminiowych wyznaczonego dla siły docisku 0,4 kN rolek o różnej chropowatości, w warunkach smarowania olejem.

Figure 12. Friction coefficient as a function of the surface roughness parameter $Ra90$ of aluminium sheets under clamping force of 0,4 kN for various surface roughness of rolls, under lubrication condition.

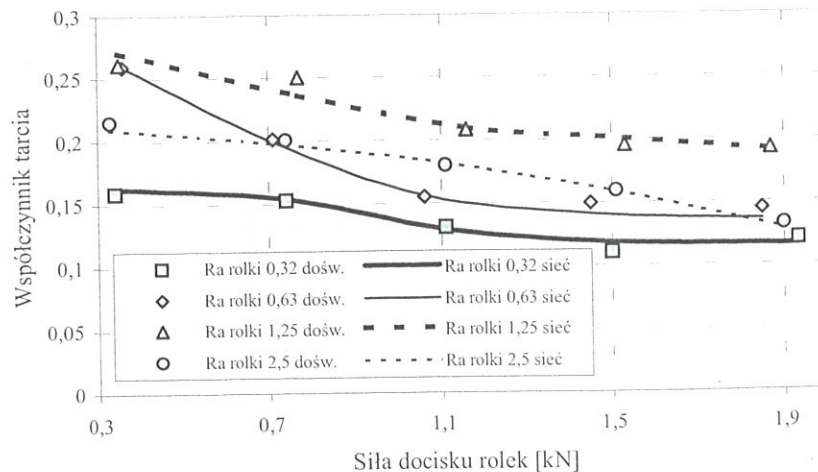
nowiono dodać warstwę ukrytą do sieci. Strukturę sieci dobranej z zastosowaniem modułu Intelligent Problem Solver przedstawia rysunek 14.

Należy podkreślić, że parametry użyte do testowania mieściły się w zakresie parametrów użytych do uczenia sieci. Proces uczenia przy pomocy algorytmu wstecznej propagacji błędów przerwano w chwili braku dalszego spadku błędów RMS dla zbioru walidacyjnego po około 20000 iteracji. Wartość błędów RMS zbioru weryfikującego ustabilizowała się na poziomie 0,0104, wartość błędów RMS uczenia wyniosła 0,01122. W przypadku zbioru testowego błąd RMS wyniósł 0,01414. Potwierdzeniem dobrej jakości prognozowania sieci jest niska wartość błędów RMS oraz średniego błędów testowania. Tablica 4 przedstawia wybrane statystyki regresji nauczonej sieci.

Porównanie wartości współczynnika tarcia przewidywanego przez perceptron wielowarstwowy i obliczonego na podstawie przeprowadzonych prób tarcia (rysunek 15) wykazuje wysoki stopień zgodności. Uwidocznione są różnice poziomu oraz charakteru zmian wartości współczynnika tarcia dla testu realizowanego bez smarowania powierzchni kontaktowych oraz w warunkach smarowania olejem maszynowym. Zastosowanie smaru zmniejsza opory tarcia wszystkich rolek o różnej topografii powierzchni, a szczególnie w przypadku rolek o największej chropowatości. W warunkach tarcia na sucho wartość współczynnika tarcia wzrasta monotonicznie wraz ze zwiększaniem się chropowatości rolek.


5. PODSUMOWANIE

Brak uniwersalnego matematycznego modelu do opisu zjawisk tarcia, a zatem obliczania wartości współczynnika tarcia, wynika z trudności jednoznacznego zdefiniowania i opisu szeregu złożonych nieliniowych zjawisk w strefie kontaktu dwóch ciał. Model neuronowy pozwala na wyeliminowanie poszukiwania skomplikowanych zależności między różnymi parametrami wpływającymi na opory tarcia,



Rysunek 13. Porównanie danych doświadczalnych oraz wyznaczonych przez sieć neuronową wartości współczynnika tarcia dla blachy AA5251 08 H14, a) ze smarowaniem, b) bez smarowania.

Figure 13. Comparison between experimental data and neural network prediction of friction coefficient for the AA5251 08 H14 aluminium alloy sheet, under lubricant conditions (a) and dry friction (b).



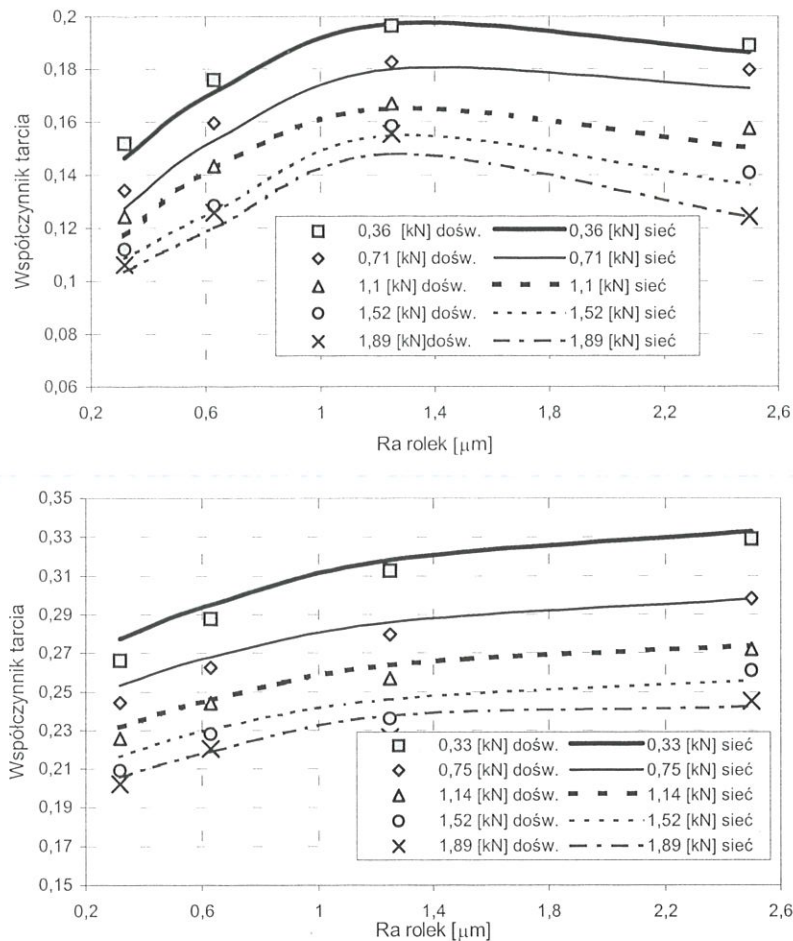
Rysunek 14. Struktura sieci neuronowej dla modelu prognostycznego.
Figure 14. The prognostic network architecture.

Tablica 4. Wybrane statystyki regresji modelu prognostycznego.
Table 4. Selected regression statistics of prognostic model.

	Zbiór uczący	Zbiór walidacyjny	Zbiór testowy
Średni błąd	-0,0074	-0,0057	-0,0002
Odch. błędów	0,0084	0,0088	0,0143
Śr. błąd bezwzgl.	0,0092	0,0087	0,0112
Iloraz odchylenia	0,1555	0,2211	0,2481
Korelacja	0,9878	0,9764	0,9833

a wartością współczynnika tarcia.

Wyniki przeprowadzonych eksperymentów neuronowych charakteryzują się wysoką zgodnością z danymi doświadczalnymi w zakresie wartości parametrów użytych do uczenia sieci. Utworzony za pomocą perceptronu wielowarstwowego model tarcia można wykorzystać w symulacji komputerowej procesu kształtowania blach poprzez implementację w pakiecie MES. Istotną zaletą stosowania sieci neuronowej, jako modelu prognostycznego współczynnika tarcia, jest ograniczenie lub brak konieczności stosowania czasochłonnych i niejednokrotnie kosztownych badań



Rysunek 15. Wpływ chropowatości oraz siły docisku rolek na wartość współczynnika tarcia - porównanie danych doświadczalnych oraz prognozowanych przez sieć neuronową dla blachy M70 04 z6 - ze smarowaniem (górny) oraz bez smarowania (dolny).
 Figure 15. Effect of surface roughness and clamping force on the value of friction coefficient - comparison between the experimental data and the neural network prediction for the M70 04 z6 brass sheet metal - oil lubricant conditions (top) and dry friction (bottom).

doświadczalnych w celu analitycznego wyznaczenia zależności funkcyjnych między parametrami procesu, a wartością współczynnika tarcia.

LITERATURA

Darendeiler, H., Akkok, M., Yucesoy, C. A., 2002, Effect of variable coefficient on sheet metal drawing, *Tribol. Int.*, 35, 97-104.

Gierzyńska, M., 1983, *Tarcie, zużycie i smarowanie w obróbce plastycznej metali*, WNT, Warszawa.

Lovell, M.R., Deng, Z., 2002, Characterization of interfacial friction in coated sheet steels: influence of stamping parameters and wear mechanisms, *Tribol. Int.*, 35, 85-95.

Matuszak, A., 2000, Factors influencing friction in steel sheet forming, *J. Mat. Proc. Technol.*, 106, 250-253.

Blau, P.J., 2001, The significance and use of the friction coefficient, *Tribol. Int.*, 34, 585-591.

Zhang, S., Hodgson, P.D., Cardew-Hall, M.J., Kalyanasundaram, S., 2003, A finite element simulation of micro-mechanical frictional behaviour in metal forming, *J. Mat. Proc. Technol.*, 134, 81-91.

Świątkowski, K., 2000, Sposoby oceny wielkości tarcia na powierzchniach kontaktu niemetalicznego materiału modelowego i narzędzia, *Obróbka Plastyczna Metali*, 7, 21-30.

Matuszak, A., Kręcisz, D., 2003, Badanie oporów przejścia blachy przez progi ciągowo, *Obróbka Plastyczna Metali*, 10, 17-25.

Zdravecka, E., Suchanek, J., Lubiščak, J., Greškovič, F., Spišak, E., 2002, Examination of surface characteristics in tribological system by AFM, *Tribologia*, 33, 1713-1722.

Hao, S., Klamecki, B.E., Ramalingam, S., 1999, Friction measurement apparatus for sheet metal forming, *Wear*, 224, 1-7.

Lee, B.H., Keum, Y.T., Wagoner, R.H., 2002, Modeling of the friction caused by lubrication and surface roughness in sheet metal forming, *J. Mat. Proc. Technol.*, 130-131, 60-63.

Wang, X. J., Tang, D., Tang, X. A., Liu, J., 1996, Development of a new universal friction test for sheet forming, *Proc. 3th Int. Conf. Numisheet'96*, Dearborn, Michigan, 55-60.

Tadeusiewicz, R., 1998, *Sieci neuronowe*, WNT, Warszawa.

Hertz, J., Krogh, A., Palmer, R. G., 1993, *Wstęp do teorii obliczeń neuronowych*, WNT, Warszawa.

Wihlborg, A., Craford, R., 2001, Steel surface topography and its influence on friction in a bending under tension friction test, *Int. J. Mach. Tools Manufact.*, 41, 1953-1959.

Lula, P., 2004, Wybrane możliwości zastosowań sieci neuronowych i programu STATISTICA, *Neural Networks*, www.statsoft.pl/czytelnia/.

Artykuł otrzymano 17 maja 2004 r.