

ALGORYTM EKSTRAKЦИИ WIEDZY Z SIECI NEURONOWEJ NA PRZYKŁADZIE PROCESU CYNKOWANIA OGNIOWEGO

SŁAWOMIR GOLAK, FRANCISZEK GROSMAN, TADEUSZ WIECZOREK

ALGORITHM OF A KNOWLEDGE EXTRACTION FROM NEURAL NETWORK ON THE EXAMPLE OF HOT-DIP ZINC COATING PROCESS

Abstract

One of the major disadvantages of neural networks is that they can be considered as black boxes, since no satisfactory explanation of their work. A method for the analysis of regression neural networks, which provides physical interpretation of examined processes, is described in the paper. Method was verified on a base of test and empirical data of hot-dip zinc coating process.

1. WSTĘP

Aplikacje sztucznych sieci neuronowych są często poddawane krytyce z powodu charakteru tego narzędzia określanego mianem "czarnej skrzynki" (ang. black box). Pomimo, że sieć wydaje się stosunkowo prosta w zastosowaniu, to niestety jej wykorzystanie przysparza wielu trudności. Oprócz logistyki zbierania danych uczących, ważnym problemem jest dobór odpowiedniej struktury sieci i określenie optymalnego zbioru cech podawanych na jej wejście. Nawet jeżeli sieć pracuje poprawnie, dla danych testowych zwraca zadawalające wyniki, to nigdy nie wiemy czy utworzony model neuronowy w każdym przypadku będzie pracował poprawnie, nie możemy wyjaśnić zasad jego funkcjonowania, a przede wszystkim skorzystać z zgromadzonej w nim podczas uczenia sieci wiedzy.

Z tych powodów pojawiło się wiele opracowań, które dotyczą analizy i interpretacji działania nauczo-

nej i poprawnie działającej sieci neuronowej. Celem tych działań jest ocena istotności poszczególnych parametrów podawanych na wejścia sieci, określenie sposobu ich oddziaływania oraz ekstrakcja zbioru reguł, opisujących działanie modelu neuronowego. Ogromna większość prac dotyczy sieci neuronowych klasyfikujących, których wyjścia przyjmują jedynie wartości binarne, co znacznie upraszcza proces generacji reguł oraz pozwala na zastosowanie narzędzi z zakresu teorii informacji. W przypadku sieci neuronowych realizujących regresję uogólnioną, które znalazły szerokie zastosowanie m.in. w analizie procesów przemysłowych, nie wypracowano jeszcze uniwersalnych metod ekstrakcji wiedzy zgromadzonej wewnątrz nauczonej sieci neuronowej (Alan i in. 1998). Niniejsza praca zawiera opis techniki ekstrakcji wiedzy w oparciu o analizę wag sieci neuronowej pozwalającej na określenie istotności oddziaływania poszczególnych parametrów, wykazanie ich synergiczności oraz wyznaczenie reguł określających kierunek

oddziaływania poszczególnych czynników.

2. ANALIZA ISTOTNOŚCI PARAMETRÓW WEJŚCIOWYCH


Sieć neuronowa typu MLP (ang. Multi-Layer Perceptron) gromadzi wiedzę uzyskaną w procesie uczenia w strukturze połączeń reprezentowanych przez wartości wag. Założeniem omawianego algorytmu było wykorzystanie zawartej w wagach informacji do interpretacji działania modelu stworzonego przy użyciu sztucznej sieci neuronowej.

Podstawowym elementem SNN (sztuczna sieć neuronowa) jest neuron, który stanowi uproszczony matematyczny model swojego organicznego pierwowzoru. Z matematycznego punktu widzenia neuron realizuje ważoną sumę swoich wejść (połączonych z wyjściami neuronów we wcześniejszych warstwach), którą następnie transformuje przy użyciu funkcji przejścia. Sieć tego typu można przedstawić jako funkcję przetwarzającą wektor wejść na wektor wyjść. Realizowana funkcja przekształcająca jest zakodowana w strukturze wag (Osowski, 1996).

$$\bar{Y} = F(\bar{X}) \quad (1)$$

Podstawą omawianej metody jest stwierdzenie, iż jeżeli pochodna realizowanej przez sieć funkcji po danej składowej wektora wejścia sieci jest w pewnym obszarze przestrzeni wejść różna od zera, to składowa ta ma istotny wpływ na wyjście sieci. Wartość dodatnia pochodnej po wejściu w danym punkcie przestrzeni wejść oznacza, że wzrost wartości tego wejścia spowoduje wzrost wartości wyjścia (rysunek 1).

Pojedynczy neuron w sieci neuronowej realizuje następującą funkcję:



Rysunek 1. Związek pochodnych cząstkowych z kierunkiem oddziaływania cech. Oznaczenia: x, z – cechy, Y – wartość wyjściowa

$$y_j^{(i)} = f\left(\sum_{k=1}^{n_{i-1}} y_k^{(i-1)} \cdot w_{j,k}^{(i)} + b_j^{(i)}\right) \quad (2)$$

gdzie:

$y_j^{(i)}$ – wartość wyjścia j-tego neuronu i-tej warstwy,

$w_{j,k}^{(i)}$ – waga k-tego połączenia j-tego neuronu i-tej warstwy,

$b_j^{(i)}$ – próg aktywacji neuronu,

$f()$ – funkcja przejścia,

n_i – liczba neuronów w i-tej warstwie.

Wartość wyjścia całej sieci stanowi wynik wielokrotnego składania funkcji przejść poszczególnych neuronów. Jeżeli funkcja przejścia jest ciągła i różniczkowalna to istnieje możliwość obliczenia pochodnych funkcji realizowanej przez sieć neuronową w oparciu o wartości wag połączeń ze wzoru:

$$\frac{\partial y_j^{(i)}}{\partial x_a} = f' \left(\sum_{k=1}^{n_{i-1}} y_k^{(i-1)} w_{j,k}^{(i)} + b_j^{(i)} \right) \sum_{k=1}^{n_{i-1}} \frac{\partial y_k^{(i-1)}}{\partial x_a} w_{j,k}^{(i)} \quad (3)$$

Ważnym problemem jest dobór właściwej funkcji przejścia, szczególnie neuronów warstwy wyjściowej. Warunkiem jest tutaj istnienie i szybka zbieżność pochodnej funkcji przejścia do zera. W przeciwnym wypadku pochodne funkcji po wejściach nieistotnych będą z trudnością uzyskiwać wartość zerową, co będzie miało niekorzystny wpływ na wyniki analizy istotności. Najczęściej wykorzystywanymi funkcjami przejścia są funkcje sigmoidalna (4) i tangensoidalna (5). Rysunek 2 przedstawia porównanie tych dwóch funkcji przejścia. Ponieważ przedział wartości funkcji tangensoidalnej (-1,1) jest dwukrotnie szerszy niż funkcji sigmoidalnej (0,1) w celach porównawczych wprowadzono współczynnik skalujący 0,5.

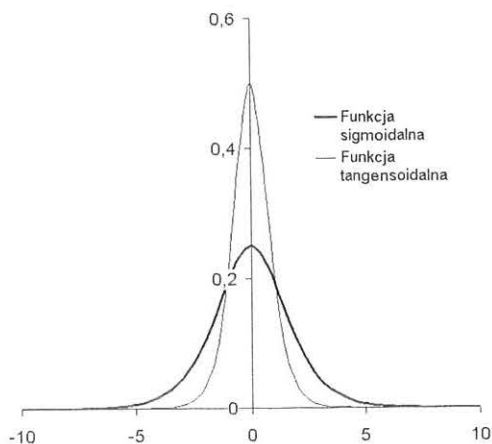
$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

$$f'(x) = \frac{e^{-x}}{(1 + e^{-x})^2}$$

$$f(x) = 0,5 \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

$$f'(x) = 0,5 \left(1 - \left(\frac{e^x - e^{-x}}{e^x + e^{-x}} \right)^2 \right)$$

Z tych powodów bardziej odpowiednia od najczęściej stosowanej funkcji sigmoidalnej wydaje się w przypadku omawianej metody funkcja tangensoidalna.



Rysunek 2. Wykresy pochodnych funkcji przejścia

Przy założeniu dominacji jednego kierunku oddziaływania danego parametru na wyjście sieci neuronowej miarę ważności W tego oddziaływania można wyrazić wzorem (6), który wyraża średnią wartość pochodnej funkcji neuronowej wyznaczoną na podstawie m wygenerowanych wektorów wejściowych leżących wewnątrz obszaru wyznaczonego przez dane uczące. Zbiór przypadków powinien możliwie dokładnie próbować całą przestrzeń argumentów. W najprostszy sposób można to zrealizować przez równomierne próbkowanie zakresów poszczególnych parametrów. Przykładowo dla parametru, którego zakres wartości mieści się w przedziale $[0,1]$, próbkowanie z krokiem 0,01 wygeneruje 100 elementów zbioru. Niestety, gdy analizowany proces jest wieloparametryczny, co najczęściej ma miejsce, metoda ta zawodzi ponieważ, gdy przez N wyrazimy liczbę parametrów, a przez M częstość próbkowania liczba wygenerowanych tą metodą elementów wyraża się wzorem $n = M^N$. Bardzo szybko osiągniemy wówczas niemożliwą do numerycznej realizacji liczbę przypadków. Aby ominąć ten problem stosuje się losową generację przypadków w dozwolonym obszarze argumentów (Zhou i in., 2002).

$$W_i = \frac{1}{m} \sum_{j=1}^m \frac{\partial y_1^{(n)}(X_j)}{\partial x_i} \quad (6)$$

gdzie:

$y_1^{(n)}$ – wartość neuronu wyjściowego,

X_j – wektor j -tego punktu przestrzeni,

m – liczba próbkowanych punktów przestrzeni.

Aby miary oddziaływania poszczególnych cech były ze sobą porównywalne, należy jeszcze przed procesem uczenia sieci neuronowej znormalizować wektor wejściowy.

$$x_i^* = \frac{(x_i - \bar{x}_i)}{\sigma} \quad (7)$$

gdzie:

x_i^* – składowa wektora po normalizacji,

x_i – składowa wektora przed normalizacją,

\bar{x}_i – średnia wartość składowej wektora w zbiorze danych uczących,

σ – odchylenie standardowe składowej wektora w zbiorze danych uczących.

Normalizacja poprawia także jakość aproksymacji uzyskanej przy pomocy sieci neuronowej i przyspiesza proces uczenia.

Kończącą miarę istotności wyznaczono uwzględniając oddziaływania cech liniowo związanych z analizowaną cechą (wzór 8). Nieuwzględnienie takiego przypadku spowodowałoby, że miary ważności dla powiązanych cech uzależnione byłyby od początkowych wartości wag sieci neuronowej ustalanych przed jej uczeniem.

$$I_i = \frac{\sum_{j \in A} a_{ij} W_j}{\sum_{j \in A} |W_j|} \cdot 100 [\%] \quad (8)$$

gdzie:


a_{ij} – współczynnik kierunkowy regresji liniowej pomiędzy cechami i, j ,

A – zbiór cech.

3. ANALIZA SYNERGICZNOŚCI PARAMETRÓW WEJŚCIOWYCH

Przydatna w analizie fizykalnej procesu jest wiedza na temat synergiczności parametrów wejściowych, czyli ich wzajemnym wpływie na siłę oddziaływania. Podobnie jak w analizie istotności punktem wyjścia było potraktowanie sieci neuronowej jako funkcji wielu zmiennych wejść. W metodzie oceny synergiczności oparto się na założeniu, że jeżeli druga pochodna tej funkcji po dwóch różnych wejściach jest różna od zera w pewnym obszarze przestrzeni wejść, to w obszarze tym występuje synergia tych czynników (rysunek 3).

$$\begin{aligned} \frac{\partial^2 y_j^{(i)}}{\partial x_a \partial x_b} &= f'' \left(\sum_{k=1}^{n_{i-1}} y_k^{(i-1)} w_{j,k}^{(i)} + b_j^{(i)} \right) \\ &+ \sum_{k=1}^{n_{i-1}} \frac{\partial y_k^{(i-1)}}{\partial x_a} w_{j,k}^{(i)} \sum_{k=1}^{n_{i-1}} \frac{\partial y_k^{(i-1)}}{\partial x_b} w_{j,k}^{(i)} + \\ &+ f' \left(\sum_{k=1}^{n_{i-1}} y_k^{(i-1)} w_{j,k}^{(i)} + b_j^{(i)} \right) \sum_{k=1}^{n_{i-1}} \frac{\partial^2 y_k^{(i-1)}}{\partial x_a \partial x_b} w_{j,k}^{(i)} \end{aligned} \quad (9)$$



Rysunek 3. Związek podwójnych pochodnych cząstkowych z synergią cech. Oznaczenia: x, z – cechy, Y – wartość wyjściowa

Podobnie, jak w przypadku analizy istotności, ważnym zagadnieniem jest dobór odpowiedniej funkcji przejścia dla neuronów sieci. Jej druga pochodna powinna być szybko zbieżna do zera. W przeciwnym wypadku napotkamy trudności z wykazaniem braku synerгии dla parametrów nie związanych. Dlatego zaleca się stosowanie funkcji tangensoidalnej przynajmniej dla neuronów wyjściowych (rysunek 4). Postulat ten jest bardziej znaczący dla analizy synergiczności, niż w przypadku istotności, ponieważ uzyskana jakość wyników jest bardzo czuła na wszelkiego rodzaju szumy.

$$f'''(x) = \frac{e^{-x}(e^{-x} - 1)}{(e^{-x} + 1)^3} \quad (10)$$

$$f'''(x) = \left(\frac{e^x - e^{-x}}{e^x + e^{-x}} \right)^3 - \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11)$$

gdzie:

$f()$ – funkcja przejścia neuronu,

$f''()$ – druga pochodna funkcji przejścia,

x – ważona suma wejść.

Miarę oddziaływania dwóch parametrów P_{ij} wyraża wzór (12). Może on być stosowany jedynie przy założeniu stałości kierunku oddziaływania parametrów na siebie.

$$P_{ij} = \frac{1}{m} \sum_{k=1}^m \frac{\partial^2 y_1^{(n)}(X_k)}{\partial x_i \partial x_j} \quad (12)$$

gdzie:

$y_1^{(n)}$ – wartość neuronu wyjściowego,

X_k – wektor k -tego punktu przestrzeni,

m – liczba próbkowanych punktów przestrzeni.

Końcową miarę synerгии S_{ij} wyznaczono z uwzględnieniem parametrów związanych (wzór 13).

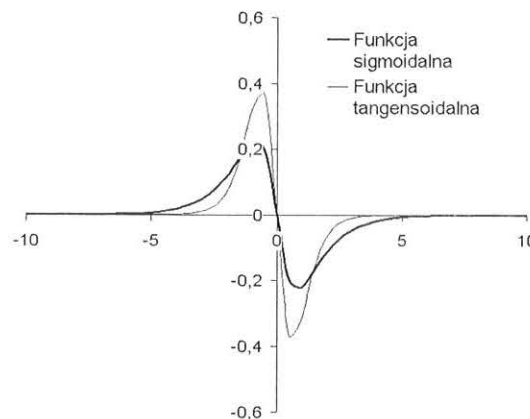
$$S_{ij} = \frac{\sum_{k \in A} a_{ik} P_{kj}}{\max_{\beta \in A \times A} |P_{\beta}|} \quad (13)$$

gdzie:

a_{ik} – współczynnik kierunkowy regresji pomiędzy cechami i, k ,

A – zbiór cech,

P_{kj}, P_{β} – miary oddziaływania par parametrów.



Rysunek 4. Wykresy drugich pochodnych funkcji przejścia

4. ALGORYTM GENERACJI REGUŁ

W przypadku, gdy nie można przyjąć założenia o jednorodnych charakterze oddziaływania danej cechy właściwą metodą postępowania jest generacja oddzielnych reguł dla poszczególnych obszarów monotoniczności (rysunek 5).

W niniejszej pracy do generacji reguł wykorzystano algorytm genetyczny (Arabas, 2001). Chromosomy osobników populacji zawierają zakodowaną lingwistyczną regułę postaci:

JEŻELI $x_1 \in (d_1, u_1) \mid x_2 \in (d_2, u_2) \mid x_n \in (d_n, u_n)$ TO
 x_a {powoduje spadek,
 jest neutralne,
 powoduje wzrost}

Taka postać reguły ułatwia interpretację wiedzy fizycznej zgromadzonej przez nauczoną sieć neuronową.

Przedziały poszczególnych argumentów są kodowane wewnątrz chromosomu w sposób rzeczywisty, natomiast klasa oddziaływania argumentu x_i (spadek, neutralne, wzrost) dyskretnie.

Funkcja przystosowania wyrażająca precyzję reguły reprezentowanej przez osobnika w populacji w

omawianej pracy zostały wyznaczona według wzoru (14).

$$P = n_{poprawne} - n_{bledne} \quad (14)$$

Gdzie $n_{poprawne}$ wyraża liczbę przypadków poprawnie opisanych przez regułę, natomiast n_{bledne} oznacza przypadki błędnie sklasyfikowane przez reprezentowaną w postaci chromosomu osobnika regułę. Jak widać ewolucja będzie dążyć do jak największej ogólności reguł, jeżeli nie spowoduje to spadku ich ścisłości. Po wyznaczeniu reguły ze zbioru przypadków eliminowane są te elementy, które zostały poprawnie scharakteryzowane przez wyznaczoną regułę. Następnie proces ewolucji jest przeprowadzany ponownie. Algorytm kończy się po wyczerpaniu zbioru przypadków, lub gdy stopień szczegółowości generowanych reguł będzie zbyt duży (rysunek 6). Opisany algorytm jest realizowany odrębnie dla każdego parametru x_i (Herrera i in., 1995).

Jeżeli charakter wzajemnego oddziaływania parametrów jest różny w różnych obszarach, wówczas podobnie, jak dla istotności stosuje się omówiony wcześniej algorytm genetyczny do generacji reguł lingwistycznych postaci:

JEŻELI $x_1 \in (d_1, u_1) \mid x_2 \in (d_2, u_2) \mid x_n \in (d_n, u_n)$ TO
 x_a, x_b {znoszą się,
są neutralne,
wzmacniają się}

5. WYNIKI ANALIZY TESTOWEGO MODELU NEURONOWEGO

W ramach weryfikacji metody przeprowadzono analizę sieci neuronowej posiadającej 71 wejść, w której treningu wykorzystano dane wygenerowane według zależności (15).

$$y = 2x_1 + \sin(\pi x_2) + \cos(\pi x_3) + 3x_4 x_5 + x_6 \cos(x_7) \quad (15)$$


gdzie $x_i \in [0,1]$

W wykorzystanej zależności występuje zarówno synergia pomiędzy $x_4 x_5$, $x_6 x_7$, jak i niejednorodny charakter wpływu x_3 .

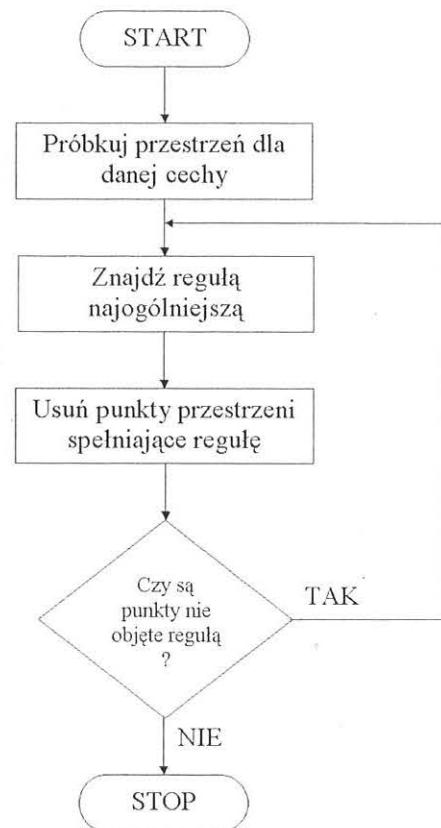
Wyniki uzyskane w analizie istotności wpływu poszczególnych wejść zostały przedstawione w tabeli.

Analiza istotności wykazała rzeczywisty wpływ wejść x_{1-7} , które znalazły się na początku tabeli istotności. Przyjęcie jako miary istotności wartości średniej (8) spowodowało sklasyfikowanie wyjścia x_2 dopiero na 6 pozycji z powodu pełnej symetrii charakteru jego oddziaływania.

Następnie zastosowano algorytm generacji reguł. Kolejne reguły były generowane przy pomocy algorytmu genetycznego wykorzystującego populację 100



Rysunek 5. Podział przestrzeni na obszary obowiązywania reguł



Rysunek 6. Algorytm generacji reguł

osobników. Jako operatory genetyczne wykorzystano mutację rzeczywistą o rozkładzie Cauchy'ego z prawdopodobieństwem 0,05 i krzyżowanie uśredniające z prawdopodobieństwem równym 0,4. Nowe pokolenia były budowane w oparciu o reprodukcję rangową.

Dopiero zastosowanie algorytmu genetycznego generacji spowodowało wygenerowanie następujących reguł:

JEŻELI $x_2 < 0,5$ TO x_6 powoduje wzrost

JEŻELI $x_2 > 0,5$ TO x_6 powoduje spadek

Analiza synergiczności parametrów wskazała na synergii pomiędzy wejściami $x_4 x_5$ oraz $x_6 x_7$. Miara S_{ab}

Tabela 1. Analiza istotności dla modelu testowego.

Lp	Parametr	Kierunek	Istotność $ I_a $
1	X ₃	-	15,82 %
2	X ₁	+	14,04 %
3	X ₄	+	13,30 %
4	X ₅	+	12,33 %
5	X ₆	+	5,31 %
6	X ₂	+	4,00 %
7	X ₇	-	1,98 %
8	x ₃₄	+	1,79 %
9	x ₁₀	-	1,31 %
10	x ₃₃	+	1,20 %

Tabela 2. Analiza synergiczności dla modelu test.

Lp	Parametr	Synergia $ S_{ab} $
1	x ₄ x ₅	1,00
2	x ₆ x ₇	0,36
3	x ₂ x ₆	0,11
4	x ₂ x ₄	0,08
5	x ₂ x ₅	0,08

uzyskała największą wartość dla tych dwóch parametrów (patrz tabela 2).

6. WYNIKI ANALIZY MODELU NEURONOWEGO PROCESU CYNKOWANIA OGNIOWEGO

Badania objęły analizę modelu neuronowego realizującego predykcję właściwości mechanicznych rdzenia blachy wytwarzanej w procesie cynkowania ogniowego (Grosman i in., 2001). Zadaniem sieci neuronowej było prognozowanie wytrzymałości mechanicznej, granicy plastyczności oraz wydłużenia. Model oparto o sieć neuronową posiadającą dwie warstwy ukryte, które zawierały kolejno 15 i 7 neuronów o tangensoidalnych funkcjach przejścia. W uczeniu sieci wykorzystano metodę propagacji wstecznej Levenberg-Marquardt. Jakość uzyskanych z sieci wyników można uznać za zadawalającą (tabela 3).

Celem dalszych prac było określenie przy użyciu

Tabela 3. Błędy prognoz sieci neuronowej.

	Błąd bezwzględny	Błąd względny
GRANICA PLASTYCZNOŚCI		
Średni błąd	12,05 MPa	3,8 %
Odchylenie std.	10,20 MPa	3,2 %
WYTRZYMAŁOŚĆ		
Średni błąd	8,82 MPa	2,3 %
Odchylenie std.	12,52 MPa	3,2 %
WYDŁUŻENIE		
Średni błąd	1,98 %	6,6 %
Odchylenie std.	1,75 %	5,8 %

omówionej wyżej metody istotności poszczególnych czynników. Tabele 4, 5, 6 przedstawiają uzyskane wyniki – 10 najbardziej istotnych parametrów zśród 70 wykorzystywanych w procesie prognozowania czynników.

W wypadku trzech prognozowanych właściwości można zauważyć, że istotny wpływ na finalne właściwości wyrobu mają przede wszystkim temperatury stref pieca wyżarzania, oraz temperatury blachy w tych strefach.

Dla poszczególnych cech wyjściowych zyskały przewagę temperatury różnych stref tego pieca. Jednak duży stopień korelacji pomiędzy wartościami tych temperatur oraz „rozmytość” modelu reprezentowanego przez sieć neuronową uzasadniają to zjawisko. W przypadku granicy plastyczności i wytrzymałości analiza wykazała istotny wpływ temperatury blachy w piecu wyżarzania.

Uzyskano trudne w interpretacji wyniki w wypadku analizy wpływu parametrów technologicznych na wydłużenie. Powodem może być ogólnie gorsza w jego przypadku jakość prognoz modelu neuronowego.

Z grupy parametrów opisujących właściwości materiału wsadowego ponownie ujawnił swoje znaczenie magnez oraz w mniejszym stopniu węgiel. Prawdopodobnie z powodu przyczyn omówionych już wcześniej dla wydłużenia uzyskano tutaj odmienne wyniki.

Opisany powyżej algorytm generacji reguł wykazał, że w całym obszarze dziedziny parametrów charakter oddziaływania poszczególnych czynników jest jednorodny. Zastosowano algorytm genetyczny o takich samych parametrach, jak dla modelu testowego.

Metoda nie pozwoliła na wykazanie wzajemnej synergiczności wykorzystywanych parametrów. Przyczyną może być rzeczywisty brak takiej zależności, lub zbyt duża czułość zastosowanej metody na pewne niedostatki modelu neuronowego.

7. PODSUMOWANIE

Omówiony algorytm ekstrakcji wiedzy z nauczanej sieci neuronowej pozwala interpretować działanie modeli neuronowych realizujących regresję uogólnioną. Opisane narzędzie może być stosowane dla dowolnej sieci MLP, jeżeli wszystkie jej neurony realizują podwójnie różniczkowalną funkcję przejścia.

Miary istotności I_a i synergiczności S_{ab} pozwalają w większości rzeczywistych procesów scharakteryzować oddziaływanie parametrów wejściowych.

Procesy, w których kierunki wzajemnego oddziaływania parametrów i wpływu na wyjście są różne w poszczególnych obszarach przestrzeni atrybutów mogą być opisane przy pomocy reguł wygenerowanych przy użyciu omówionego algorytmu genetycznego.

Tabela 4. Istotności wpływu parametrów na granicę plastyczności.

Re			
Lp	Parametr	Kierunek	Istotność I _a
1	Zawartość Mo [%]	+	8,30 %
2	Zawartość Mn [%]	+	7,56 %
3	Zawartość V [%]	+	7,45 %
4	Temperatura blachy na piecu wyżarzania <i>PIRO2</i>	-	6,88 %
5	Temperatura strefy nr 9 T_{STR9}	-	6,50 %
6	Temperatura strefy nr 10 T_{STR10}	-	6,10 %
7	Temperatura blachy na piecu wytrzymałości <i>PIRO3</i>	-	5,71 %
8	Zawartość Si [%]	+	5,15 %
9	Zawartość C [%]	+	5,08 %
10	Temperatura blachy na piecu wstępnym <i>PIRO1</i>	-	4,91 %

Tabela 5. Istotności wpływu parametrów na wytrzymałość.

Rm			
Lp	Parametr	Kierunek	Istotność I _a
1	Zawartość Mn [%]	+	11,43 %
2	Zawartość C [%]	+	10,54 %
3	Temperatura strefy nr 9 T_{STR9}	-	10,05 %
4	Zawartość Mo [%]	+	9,93 %
5	Temperatura blachy na piecu wyżarzania <i>PIRO2</i>	-	9,91 %
6	Temperatura strefy nr 10 T_{STR10}	-	9,81 %
7	Zawartość V [%]	-	8,48 %
8	Temperatura blachy na piecu wstępnym <i>PIRO1</i>	+	8,19 %
9	Temperatura blachy na górnej rolce (wieży chłodniczej 38m) <i>PIRO5</i>	+	7,45 %
10	Zawartość As [%]	-	6,94 %

Tabela 6. Istotności wpływu parametrów na wydłużenie.

A			
Lp	Parametr	Kierunek	Istotność I _a
1	Zawartość Al [%]	+	6,47%
2	Temperatura strefy nr 6 T_{STR6}	-	6,25 %
3	Moc jeta nr 8 P_{JET8}	-	6,15 %
4	Temperatura strefy nr 4 T_{STR4}	-	6,11 %
5	Temperatura dopalacza nr 1 pieca wstępnego T_{DOP_PW}	-	6,08 %
6	Temperatura przekroczenia strefy nr 4 T_{pSTR4}	-	6,00 %
7	Temperatura przekroczenia strefy nr 6 T_{pSTR6}	-	5,97 %
8	Temperatura strefy nr 5 T_{STR5}	-	5,89 %
9	Grubość g	-	5,70 %
10	Temperatura przekroczenia strefy nr 2 T_{pSTR2}	-	5,41 %

Analiza procesu cynkowania ogniowego przy wykorzystaniu omówionej metody pozwoliła na uzyskanie informacji o istotności oraz kierunku oddziaływania poszczególnych parametrów procesu. Natomiast analiza synergiczności dla tego procesu nie wskazała na występowanie synergii pomiędzy parametrami technologicznymi uwzględnianymi przez model neuronowy.

Uwaga końcowa: Pracę wykonano w ramach projektu PC-10/T08 054 2000/5339

LITERATURA

- Alan B. Tickle, R. Anders, 1998, The Truth Will Come to Light: Directions and Challenges in Extracting the Knowledge Embedded Within Trained Artificial Neural Networks, *IEEE Transactions on Neural Networks*, vol. 9, no. 6, pp. 1057-1068.
- Arabas J., 2001, Wykłady z algorytmów ewolucyjnych, Wydawnictwo Naukowo-Techniczne, Warszawa.
- Grosman F, Wieczorek T., Golak S., 2001, Application of Neural Network for Analysis of Hot-Dip Zinc Coating Process Influence on Mechanical Properties of Metal Sheets, *Sächsische Fachtagung Umformtechnik*, Freiberg, pp. 93-98.
- Grosman F., Wieczorek T., Golak S., 2002, Próba interpretacji procesu cynkowania ogniowego w oparciu o parametry struktury nauczanej sieci neuronowej, *KomPlasTech X*, Wisła, pp. 11-18.
- Herrera F, Lozano M., Verdegay J. L., 1995, Generating Fuzzy Rules from Examples using Genetic Algorithms, *Fuzzy Logic And Soft Computing*, World Scientific.
- Marder A.R., 2000, A Review of the Metallurgy of Zinc Coated Steel, *Progress in Materials Science*, vol. 45/3, pp. 191.
- Osowski S., 1996, *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwo Naukowo-Techniczne, Warszawa.
- Saito K, Nakano R., 2002, Extracting regression rules from neural networks, *Neural Networks*, 15, pp. 1279-1288.
- Tanaka K., Nii M., Ishibuchi H., 1999, Learning from Linguistic Rules and Rule Extraction for Function Approximation by Neural Networks, *SEAL'98, LNCS 1585*, pp. 317-324.
- Zhi-Hua Zhou, Yuan Jiang, Shi-Fu Chen, 2002, Extracting Symbolic Rules from Trained Neural Network Ensembles, *AI Communications*, IOS Press.
- Zurada J., Malinowski A., Usui S., 1997 Perturbation Method for Deleting Redundant Inputs of Perceptron Networks, *Neurocomputing* 14, pp. 177-193.

Artykuł otrzymano 19 maja 2003 r.