

## ZASTOSOWANIE DYNAMICZNYCH SIECI NEURONOWYCH DO MODELOWANIA PROCESU WYTOPU MIEDZI W PIECU ZAWIESINOWYM

ANDRZEJ STANISŁAWCZYK<sup>1</sup>, JOLANTA TALAR<sup>1</sup>, PIOTR JAROSZ<sup>2</sup>, JAN KUSIAK<sup>1</sup>

<sup>1</sup> Wydział Inżynierii Metali i Informatyki Przemysłowej,  
Akademia Górniczo-Hutnicza w Krakowie

<sup>2</sup> Wydział Metali Nieżelaznych, Akademia Górniczo-Hutnicza w Krakowie

### APPLICATION OF DYNAMIC ARTIFICIAL NEURAL NETWORKS TO MODELLING OF THE COPPER FLASH SMELTING PROCESS

#### Abstract

The main objective of the work is evaluation of effectiveness of the dynamic neural networks in modelling of the copper flash smelting process.

The fundamentals of the dynamic neural networks are presented in the paper. This type of neural networks was tested in solving the theoretical problem with time-lag. Next, the dynamic neural networks were applied to prediction of the chosen output parameters of the copper flash smelting process.

The copper flash smelting process is very complex and there are many input and output parameters which should be considered in modelling and control of the process. Some of the output process parameters are dependent on the history of the changes of the input parameters. Moreover, some parameters can react to the changes of input parameters with delay, but the values of delays are unknown. This situation causes many problems in modelling of this metallurgical process.

The work presents the comparison of the results obtained by dynamic and static neural networks in prediction of the temperature of exhaust gases. The obtained results confirm that the dynamic neural network model can predict output parameters of the copper flash smelting process with high accuracy. Moreover, the dynamic neural networks give the possibility to identify the delays in reaction of the output process parameters to the changes of the input parameters. The obtained results have shown that dynamic neural networks are a very useful tool in modelling of complex metallurgical processes.

**Key words:** dynamic neural networks, modeling of metallurgical process, modeling of flash smelting process

## 1. WPROWADZENIE

Celem pracy jest ocena skuteczności zastosowania dynamicznych sieci neuronowych do modelowania procesu wytopu miedzi w piecu zawieszinowym.

Zawieszinowy proces bezpośredniego wytopu miedzi jest procesem bardzo złożonym. Jego istotą jest spalanie drobnoziarnistego, suchego koncentratu miedzi w szybie reakcyjnym pieca zawieszinowego, w atmosferze silnie utleniającej, zawierającej do 80% tlenu (Talar i in., 2004). Typowy proces zawieszinowy obejmuje następujące operacje technologiczne:

- przygotowanie wsadu, polegające na wysuszeniu koncentratu do zawartości około 0,3% H<sub>2</sub>O i uzyskaniu odpowiedniego składu ziarnowego;
- stapianie koncentratu w piecu zawieszinowym celem uzyskania miedzi o jakości zbliżonej do miedzi konwertorowej i strumienia gazów technologicznych o stężeniu SO<sub>2</sub>, zapewniającym ich utylizację;
- odmiedziowanie żużla z procesu zawieszinowego w piecu elektrycznym do zawartości Cu poniżej 0,6 % w żużlu;

- konwertowanie powstałego stopu celem wytworzenia miedzi konwertorowej zawierającej poniżej 0,3% Pb i poniżej 0,2% As.

Podstawowym ogniwem w całym ciągu technologicznym – z punktu widzenia otrzymywania miedzi o odpowiedniej jakości – jest stapianie koncentratu w piecu zawieszinowym. Szczegółowy opis procesów zachodzących w piecu zawieszinowym można znaleźć w literaturze (Jarosz i in., 2006; Talar i in., 2004).

Wynikiem stapiania koncentratów w piecu zawieszinowym są następujące produkty:

- miedź blister, zawierająca poniżej 0,3% Pb i do 0,5% tlenu;
- żużel zawieszinowy, o wysokiej zawartości miedzi, zwykle od 13 do 16%;
- pyły, zawierające siarczany: miedzi, wapnia, magnezu, żelaza i innych metali;
- gazy, o wysokim stężeniu  $\text{SO}_2$ , zwykle od 12 do 18 % obj.

Trudności w modelowaniu tego procesu wynikają m in. z następujących względów:

- złożona struktura procesu;
- duża ilość istotnych parametrów procesu (ok. 30 parametrów wejściowych i 40 parametrów wyjściowych);
- różna częstotliwość pomiarów dla różnych parametrów (od 1 sek. do 8 godz.);
- występowanie zaburzeń w danych pomiarowych (błędy urządzeń pomiarowych, oraz okresowa (trudna do przewidzenia) kontrola czujników powodująca dodatkowe zaburzenia niektórych wielkości mierzonych);
- stan parametrów wyjściowych może być zależny od historii zmian parametrów wejściowych;
- niektóre parametry wyjściowe procesu mogą reagować z opóźnieniem na zmiany parametrów wejściowych (sterujących);
- nie wszystkie istotne parametry wejściowe są rejestrowane.

Dotychczasowe prace Autorów w zakresie modelowania i sterowania tym procesem skupiały się na zastosowaniu statycznych sieci neuronowych (SSN). W ramach przeprowadzonych badań (Jarosz i in., 2006; Talar i in., 2004; Talar i in., 2005) stwierdzono, że sztuczne sieci neuronowe mogą być skutecznym narzędziem modelowania tego złożonego procesu i mogą być wykorzystane w sterowaniu tym procesem w czasie rzeczywistym, ze względu na krótkie czasy obliczeń. Testowano różne typy sieci neuronowych: MLP – perceptron wielowarstwowy,


RBF – sieci o radialnych funkcjach bazowych, GRNN – sieci realizujące regresję uogólnioną oraz stosowano różne strategie obróbki i filtrowania danych. Najlepsze wyniki uzyskano przy zastosowaniu sieci MLP z logistyczną funkcją aktywacji.

W ramach niniejszej pracy podjęto próbę zastosowania dynamicznych sieci neuronowych do przewidywania wybranego parametru procesu zawieszinowego.

## 2. DYNAMICZNE SIECI NEURONOWE

Jednym z możliwych kryteriów podziału sieci neuronowych jest podział na sieci statyczne i dynamiczne (Madan i in., 2003). Sieci statyczne nie posiadają sprzężeń zwrotnych, ani elementów opóźniających. Stan wyjścia sieci statycznej jest funkcją aktualnego stanu wejścia. W sieciach dynamicznych stan wyjścia sieci zależy nie tylko od aktualnego stanu wejść, ale również od historii zmian parametrów wejściowych. Dynamikę w sieciach neuronowych uzyskuje się poprzez wprowadzenie linii opóźniających (TDL) lub/i sprzężeń zwrotnych.

Linie opóźniające TDL (ang. Tapped Delay Line) mogą być umieszczone na wejściu pierwszej warstwy jak również na wejściach warstw ukrytych. Działanie takiej linii zostało przedstawione schematycznie na rysunku 1, gdzie:  $P$  oznacza sygnał wejściowy,  $D$  - opóźnienie o jeden krok czasowy. Wektor danych wejściowych w kolejnych krokach czasowych jest podawany na wejście rejestru przesuwającego.



Rysunek 1. Schemat linii opóźniającej (TDL)

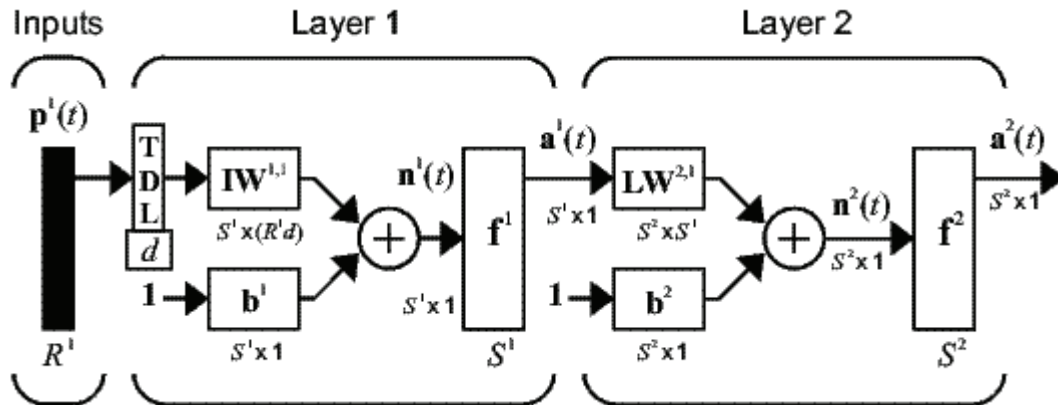
Figure 1. Flow chart of the Tapped Delay Line (TDL)

Dynamiczne sieci neuronowe, posiadające wyłącznie linie opóźniające, charakteryzują się jednokierunkowym przepływem sygnałów od wejścia do



wyjścia. Najprostszą taką siecią jest sieć FTDNN (ang. Focused Time-Delay Neural Network), która składa się ze statycznej SSN z dołączoną na wejściu linią opóźniającą. Schemat dwuwarstwowej sieci FTDNN został przedstawiony na rysunku 2.

- neurony statyczne, sprzężenia zwrotne między neuronami;
- warstwy statyczne, sprzężenia zwrotne między warstwami;
- sieć statyczna, zewnętrzne sprzężenia zwrotne.



Rysunek 2. Schemat sztucznej sieci neuronowej typu FTDNN (Demuth, 2006)

Figure 2. Flow chart of the FTDNN neural network (Demuth, 2006)

Przedstawiona na rysunku 2 sieć jest przedstawiona w notacji skróconej stosowanej w pakiecie Neural Network programu Matlab. Kolejne symbole oznaczają:

- $p^1(t)$  – wektor danych wejściowych o wymiarze  $R^1$  w kroku czasowym  $t$
- $d$  – liczba opóźnień w linii opóźniającej (licząc z opóźnieniem równym 0)
- $S^1$  – liczba neuronów w warstwie pierwszej
- $IW^{1,1}$  – macierz wag dla warstwy pierwszej, o wymiarze  $S^1 \times (R^1 \cdot d)$
- $b^1$  – przesunięcie w warstwie pierwszej
- $f^1$  – funkcja aktywacji w warstwie pierwszej
- $a^1(t)$  – wektor sygnałów wyjściowych z pierwszej warstwy w kroku czasowym  $t$ .

Analogiczne znaczenie mają symbole w kolejnych warstwach.

Sieci, w których występują sprzężenia zwrotne wyjścia z wejściem nazywa się sieciami rekurencyjnymi (Madan i in., 2003; Tadeusiewicz, 1993). Zależności dynamiczne jakie panują w sieci są widoczne na każdym etapie działania (w każdym kroku czasowym).

Możemy wyróżnić następujące typy sprzężeń zwrotnych:

- neurony dynamiczne (lokalne sprzężenia zwrotne wewnątrz neuronów);

Przykładem sieci neuronowej rekurencyjnej jest sieć NARX (ang. Nonlinear Autoregressive Network). Jest ona siecią dynamiczną posiadającą sprzężenie zwrotne wyjścia warstwy wyjściowej z wejściem warstwy wejściowej sieci, przy czym sprzężenie odbywa się poprzez linie opóźniające. Sieć taka jest często wykorzystywana do modelowania szeregów czasowych. Schemat sieci NARX został przedstawiony na rysunku 3.

Wyjście sieci NARX opisane jest równaniem:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t), u(t-1), \dots, u(t-n_u)) \quad (1)$$

gdzie:

- $f$  – funkcja zależna od budowy wewnętrznej sieci oraz od ustalonych wag
- $y$  – wyjście sieci NARX
- $u$  – wejście sieci NARX
- $n_y$  – rozmiar linii opóźniającej w sprzężeniu zwrotnym
- $n_u$  – rozmiar linii opóźniającej wejściowej.

Sieci dynamiczne są bardziej uniwersalne od sieci statycznych. Znajdują one zastosowania między innymi w następujących zagadnieniach (Madan i in., 2003; Tadeusiewicz 1993):

- modelowanie liniowych i nieliniowych układów dynamicznych;
- sterowanie adaptacyjne;
- filtrowanie sygnałów;



- pamięci skojarzeniowe (asocjacyjne);
- optymalizacja globalna.

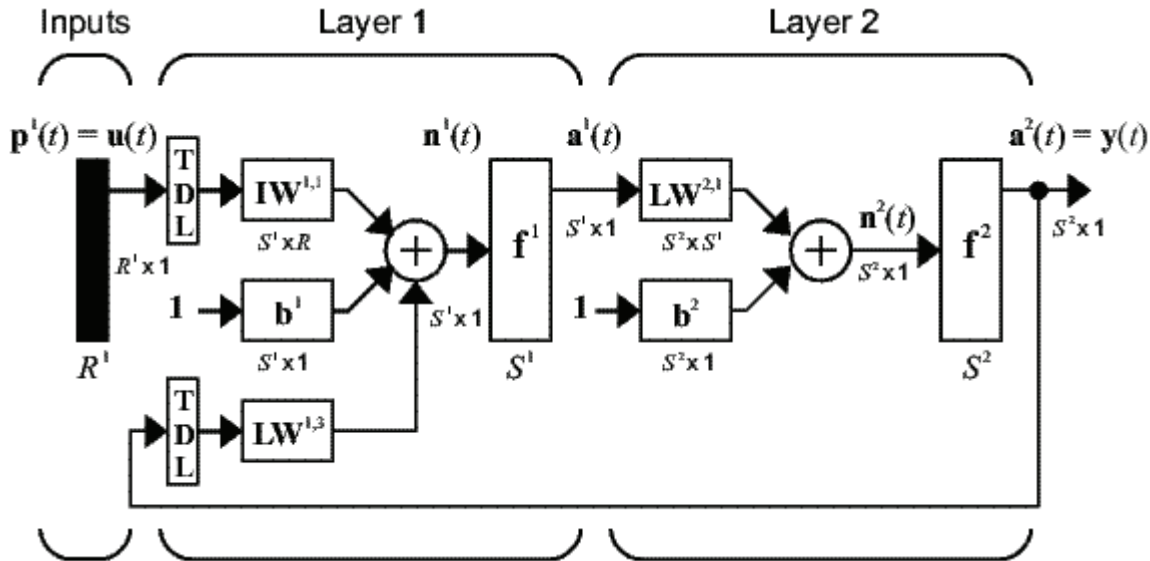
Niezwykle istotną cechą sieci dynamicznych jest możliwość realizacji pamięci skojarzeniowej. Na drodze badań naukowych zbudowano różne modele sieci spełniających funkcję pamięci skojarzeniowej. Do najbardziej znanych sieci rekurencyjnych, mających zastosowanie jako pamięci skojarzeniowe należą sieć Hopfielda oraz sieć BAM (Tadeusiewicz, 1993).

$$A = \begin{bmatrix} 2 & 1 & -4 \end{bmatrix},$$

$we1, we2, we3$  – wejścia obiektu,  
 $wy$  – wyjście obiektu.

Do modelowania obiektu opisanego równaniem 2 wykorzystano liniową sieć FTDNN, której schemat przedstawiono na rysunku 4, gdzie  $we(t) = [we1(t) we2(t) we3(t)]$ .

Losowo wygenerowano sygnały wejściowe  $we1, we2$  i  $we3$ , a następnie dla tych sygnałów obliczono



Rysunek 3. Schemat sztucznej sieci neuronowej typu NARX (Demuth, 2006)  
 Figure 3. Flow chart of the NARX neural network (Demuth, 2006)

## 2. PRZYKŁAD ZASTOSOWANIA DYNAMICZNEJ SIĘCI NEURONOWEJ DO ROZWIĄZANIA PROSTEGO PROBLEMU TEORETYCZNEGO Z OPÓŹNIENIAMI

W modelowaniu procesu zawieszinowego wytopu między jednym z poważniejszych problemów jest występowanie opóźnień czasowych w reakcjach parametrów wyjściowych na zmiany parametrów wejściowych. Przesunięcia te zazwyczaj nie są znane, więc przydatna byłaby możliwość ich wyznaczenia. Aby sprawdzić możliwość zastosowania dynamicznych sieci neuronowych do znajdowania przesunięć czasowych pod uwagę wzięto prosty model teoretyczny, opisany równaniem:

$$wy = A \cdot \begin{bmatrix} we1(t) \\ we2(t-1) \\ we3(t-2) \end{bmatrix} \quad (2)$$

gdzie:

wyjście obiektu  $wy$ . Na tak przygotowanych danych dokonano procesu uczenia SSN. Wyznaczone w procesie uczenia wartości wag zamieszczono w macierzy  $W$ :


$$W = \begin{bmatrix} 2,004 & -0,005 & -0,007 \\ 0,001 & 0,999 & -0,001 \\ -0,005 & 0,006 & -3,992 \\ 0,000 & 0,000 & 0,000 \\ 0,000 & 0,000 & 0,000 \end{bmatrix} \begin{matrix} \leftarrow D = 0 \\ \leftarrow D = 1 \\ \leftarrow D = 2 \\ \leftarrow D = 3 \\ \leftarrow D = 4 \end{matrix} \quad (3)$$

Kolejne wiersze macierzy  $W$  odpowiadają kolejnym opóźnieniom sygnałów wejściowych, natomiast kolumny odpowiadają kolejnym parametrom wejściowym. W procesie uczenia wagi odpowiadające założonym opóźnieniom zostały ustalone zgodnie z odpowiednimi wartościami wektora  $A$ . Pozostałe wagi zostały wyznaczone jako wartości bliskie zeru. Z postaci macierzy  $W$  można odczytać opóźnienia dla kolejnych sygnałów wejściowych. Uzyskane wyniki potwierdzają przydatność sieci dynamicznych w przewidywaniu wielkości wyjściowych





funkcji (sygnałów wyjściowych procesu) w przypadku, gdy wielkości (sygnały) wejściowe są przesunięte w czasie względem sygnałów wyjściowych.



Rysunek 4. Schemat liniowej sieci FTDNN (Demuth, 2006)


Figure 4. Flow chart of the linear FTDNN neural network (Demuth, 2006)

### 3. ZASTOSOWANIE SIECI DYNAMICZNYCH DO MODELOWANIA RZECZYWISTEGO PROCESU METALURGICZNEGO

Opisana w poprzednim rozdziale metodyka została użyta do znalezienia opóźnień oddziaływania jednego z parametrów wejściowych pieca zawieszinowego na wybrany parametr wyjściowy. W tym przypadku rozpatrywanym parametrem wejściowym była nadawa koncentratu do pieca zawieszinowego, natomiast parametrem wyjściowym była temperatura gazów za kotłem odzysknicowym. Z uwagi na to, iż reakcje chemiczne w piecu zachodzą w pewnym niezerowym czasie i pomiar temperatury odbywa się w znacznej odległości od szybu reakcyjnego, zmiany występujące w nadawie działają z pewnym opóźnieniem na rozpatrywaną temperaturę. Do wyznaczenia tego opóźnienia została wykorzystana sieć liniowa FTDNN (rysunek 4). Na rysunku 5 zamieszczono wykres wartości wag dla różnych kolejnych opóźnień. Widać, że maksimum tego wykresu występuje dla wartości opóźnienia  $D = 5$  min. Stąd też możemy wywnioskować, że średni czas reakcji temperatury gazów za kotłem na zmiany nadawy koncentratu wynosi 5 min.

Sieci dynamiczne (w szczególności sieci rekurencyjne) mogą być również przydatne w przypadkach, kiedy nie wszystkie sygnały wejściowe istotne z punktu widzenia modelowanego procesu, mogą być podawane na wejścia sieci. Sytuacja taka występuje przy modelowaniu temperatury gazów za kotłem odzysknicowym pieca zawieszinowego z uwagi na nie rejestrowanie w bazie danych ważnego parametru, jakim jest chłodzenie kotła. Chłodzenie pieca rozpoczyna się wtedy, gdy temperatura przekroczy pewną krytyczną wartość, natomiast kończy się, gdy

temperatura spadnie poniżej innej ustalonej wartości. Z uwagi na to, iż chłodzenie jest inicjowane i kończone decyzją sternika, te dwie temperatury (rozpoczęcia i zakończenia procesu chłodzenia) nie są zawsze dokładnie takie same. Statyczna sieć nie jest w stanie uwzględnić procesu chłodzenia, ponieważ informacja o tym nie jest reprezentowana w danych wejściowych. W przypadku zastosowania sieci dynamicznej rekurencyjnej (np. sieć NARX), sieć taka w trakcie procesu uczenia może „nauczyć się”, przy jakich temperaturach średnio następuje początek i koniec chłodzenia i dzięki sprzężeniu zwrotnemu wykorzystać tę informację w trakcie symulacji.




Rysunek 5. Wykres wartości wag odpowiadających kolejnym opóźnieniom nadawy koncentratu

Figure 5. Plot of the weight coefficients for sequence delays of the concentrate charge

Dla opracowania modelu procesu zawieszinowego wykorzystano dane minutowe, zebrane w warunkach przemysłowych jednej z hut. Analizowany zbiór danych zawierał pomiary z różnych okresów pracy pieca. Dane wejściowe opisywały parametry materiałów wsadowych oraz parametry termodynamiczne charakterystyczne dla procesu. Zbiór uczący obejmował 10000 rekordów danych pomiarowych, natomiast zbiór testowy 5000 rekordów. Do opracowania modelu zastosowano dynamiczne sieci neuronowe NARX (rysunek 3) o architekturze 5-1, z funkcją aktywacji  $arctg$  w warstwie wejściowej i liniową w warstwie wyjściowej. Rozmiar linii opóźniającej danych wejściowych wynosił 7 (opóźnienia od 0 do 6 min), a linia opóźniająca w sprzężeniu zwrotnym miała rozmiar 4 (opóźnienia od 1 do 4). Działanie sieci NARX porównano z siecią statyczną o architekturze 5-1 o analogicznych funkcjach aktywacji. Wyniki przewidywania SSN tempe-



ratury gazów za kotłem odzysknicowym przedstawiono na rysunku 6.



**Rysunek 6.** Wyniki przewidywania temperatury gazów odlotowych przez (a) – statyczną sieć neuronową oraz (b) – dynamiczną sieć neuronową typu NARX

**Figure 6.** The results of prediction of the temperature of exhaust gases using (a) – static neural network and (b) – dynamic neural network

Dla oceny uzyskanych wyników zastosowano błąd  $\Phi$  opisany równaniem (4):

$$\Phi = \sqrt{\frac{1}{m} \sum_{i=1}^m \left( \frac{T_{SSN} - T_{pom}}{T_{pom}} \right)^2} \quad (4)$$

gdzie:

$T_{SSN}$  – obliczona wartość parametru,  
 $T_{pom}$  – zmierzona wartość parametru,  
 $m$  – liczba danych pomiarowych.

Analizując uzyskane wyniki można stwierdzić, iż obydwa typy sieci neuronowych przewidują wartości temperatury z zadowalająco niskim błędem  $\Phi$ . W przypadku sieci statycznej błąd ten wynosił  $\Phi = 0.05$ , natomiast dla sieci dynamicznej wartość błędu

była ponad dwukrotnie mniejsza:  $\Phi = 0.022$ . Jednakże sieć statyczna nie potrafiła odwzorować charakteru zmian analizowanego parametru wyjściowego. Sieć dynamiczna uzyskała znaczącą poprawę wyników zarówno pod względem ilościowym, jak i jakościowym. Sieci statyczne praktycznie podają uśrednioną wartość temperatury, natomiast sieci dynamiczne starają się odwzorować rzeczywisty przebieg zmian temperatury.

#### 4. PODSUMOWANIE

W pracy przedstawiono przykłady wykorzystania dynamicznych SSN do modelowania złożonych procesów przemysłowych, w których obserwuje się opóźnienie sygnałów wyjściowych w stosunku do zmiany sygnałów wejściowych. Uzyskane wyniki przewidywania wielkości wyjściowych opóźnionych w stosunku do sygnałów wejściowych dla prostej funkcji zainspirowały Autorów do podjęcia próby wykorzystania sieci dynamicznych do modelowania rzeczywistego, złożonego procesu przemysłowego. Przedmiotem analizy był zawieszinowy proces wytopu miedzi. Analizie poddano wpływ opóźnienia pomiaru nadawy koncentratu na temperaturę gazów za kotłem odzysknicowym. Uzyskane wyniki modelowania tego procesu z wykorzystaniem sieci dynamicznych potwierdzają ich przydatność do tego rodzaju zastosowań. Sieci dynamiczne lepiej odwzorowują rzeczywisty przebieg zmian temperatury niż sieci statyczne. Analizowany problem potwierdza fakt, że sieci dynamiczne są bardziej uniwersalne od sieci statycznych w przypadku modelowania procesów z opóźnieniami.

#### UWAGA

Praca finansowana ze środków na naukę w latach 2006-2009 jako projekt badawczy nr 3 T08B 034 30.

#### LITERATURA

- Demuth, H., Beale, M., Hagan, M., 2006, *Neural Network Toolbox use with Matlab*, MathWorks, Natick.
- Jaros, P., Talar, J., Kondek, T., Kusiak, J., Dobrzański, J., Staszak, J., 2006, Modelowanie składu fazy gazowej procesu zawieszinowego wytopu miedzi z wykorzystaniem sztucznych sieci neuronowych, *KomPlasTech 2006*, ed., Szeliga, D., Pietrzyk, M., Kusiak, J., Szczawnica, Wydawnictwo Akapit, Kraków, 201-208.
- Madan, M.G., Liang, J., Noriyasu, H., 2003, *Static and Dynamic Neural Networks*, Wiley-Interscience, New Jersey.
- Tadeusiewicz, R., 1993, *Sieci Neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa.



- Tadeusiewicz, R., 1997, Wprowadzenie do sieci neuronowych, w: Zastosowanie sztucznych sieci neuronowych w symulacji i sterowaniu procesami metalurgicznymi, ed., Pietrzyk, M., *Materiały I. Seminarium*, Wydawnictwo Akapit, Kraków.
- Talar, J., Jarosz, P., Kondek, T., Kusiak, J., Staszak, J., 2004, Zastosowanie sztucznych sieci neuronowych do sterowania zawieszinowym przetopem koncentratów miedzi, *KomPlasTech 2004*, ed. Pietrzyk M., Kusiak, J., Grosman, F., Piela, A., Zakopane, Wydawnictwo Akapit, Kraków, 291–300.
- Talar, J., Kondek, T., Jarosz, P., Kusiak, J., Dobrzański, J., Staszak, J., Byszyński, L., 2005, Artificial intelligence control system of the copper flash smelting process, *11th IFSC: International Flash Smelting Congress*, Bulgaria & Spain, 1–11.

---

*Received: July 15, 2006*

*Received in a revised form: September 18, 2006*

*Accepted: September 20, 2006*

