

ZASTOSOWANIE METOD SZTUCZNEJ INTELIGENCJI W MODELOWANIU PROCESU WYTOPU MIEDZI

AGNIESZKA ŚLEDZIŃSKA, JOLANTA TALAR, JAN KUSIAK

APPLICATION OF THE ARTIFICIAL INTELLIGENCE METHOD IN MODELLING OF THE COPPER FLASH SMELTING PROCESS

Abstract

The objective of the work is assessment of the effectiveness of the use of artificial intelligence methods in modelling of the copper flash smelting process. Bayesian Network (BN), Artificial Neural Network (ANN) and Expert System (ES) were used in prediction of chosen parameters of the technological process and obtained results are presented.

1. WSTĘP

Celem pracy jest ocena możliwości i skuteczności zastosowania metod sztucznej inteligencji w przewidywaniu pewnych zaburzeń występujących w procesie wytwarzania miedzi w piecu zawieszinowym.

Zawieszinowy proces jednostadialnego wytwarzania miedzi jest procesem ciągłym i jest bardzo złożonym ze względu na dużą ilość istotnych parametrów procesu. Głównym ogniwem w procesie produkcji miedzi jest piec zawieszinowy, który limituje pracę całego ciągu technologicznego. Obecnie, w warunkach przemysłowych, sterowanie pracą pieca zawieszinowego odbywa się w oparciu o podstawowe obliczenia fizyko-chemiczne i, w głównej mierze, o doświadczenie technologów i sterników. Trudności w sterowaniu tym procesem wynikają z jego złożonej struktury a wymogi fizyko-chemiczne procesu oraz względy ekonomiczne skłaniają do poszukiwania skutecznych narzędzi do jego sterowania. W pracy (Talar i in., 2004)

przedstawiono wstępne wyniki zastosowania sztucznych sieci neuronowych w przewidywaniu parametrów wyjściowych pieca. Uzyskane wyniki potwierdziły skuteczność zastosowania sztucznych sieci neuronowych w modelowaniu tak złożonego procesu. Przeprowadzone badania dotyczyły przewidywania kilku krytycznych parametrów wyjściowych pieca, które decydują o jakości produktów finalnych procesu. Jednakże podczas stapiania koncentratów miedzi w piecu zawieszinowym często dochodzi do niekontrolowanych zaburzeń, niepożądanych z uwagi na jakość produktów finalnych procesu. Ponieważ brak jest modeli opisujących te zjawiska a modele dotyczące opisu zachowania się cząstek koncentratu w szybie reakcyjnym (Themelis N.J.1987, Themelis N.J. 1988) są nieużyteczne z punktu widzenia sterowania pracą pieca w czasie rzeczywistym, dlatego też w ramach niniejszej pracy podjęto próbę zastosowania metod sztucznej inteligencji (sieci bayesowskich, sztucznych sieci neuronowych oraz regułowego systemu ekspertowego) do przewidywania jednego z ta-

A. Śledzińska, J. Talar, J. Kusiak, Wydział Metalurgii i Inżynierii Materiałowej, Akademia Górniczo-Hutnicza w Krakowie



kich zaburzeń, nazywanego w skrócie „gotowaniem”. Jego opis i przyczyny powstawania podano w dalszej części pracy.

2. WYTOP MIEDZI W PIECU ZAWIESINOWYM

Istotą procesu zawiesinowego jest utlenianie drobnoziarnistego, suchego koncentratu miedzi w pionowej, współprądowej warstwie zawiesinowej ukształtowanej przez szyb reakcyjny pieca zawiesinowego. Przygotowany wsad musi spełniać następujące warunki:

- dobre uśrednienie wsadu pod względem składu chemicznego,
- odpowiedni skład ziarnowy,
- niska zawartość wody.

Wynikiem stapiania koncentratów w piecu zawiesinowym są następujące produkty:

- miedź blister, zawierająca poniżej 0,3 % Pb i do 0,5 % tlenu,
- żużel zawiesinowy, o wysokiej zawartości miedzi, zwykle od 13 do 16 %,
- pyły, zawierające siarczany: miedzi, wapnia, magnezu, żelaza i innych metali,
- gazy, o wysokim stężeniu SO_2 , zwykle od 12 do 18 % obj.

Stosowany w przemyśle proces zawiesinowy obejmuje następujące podstawowe operacje technologiczne (rysunek 1):

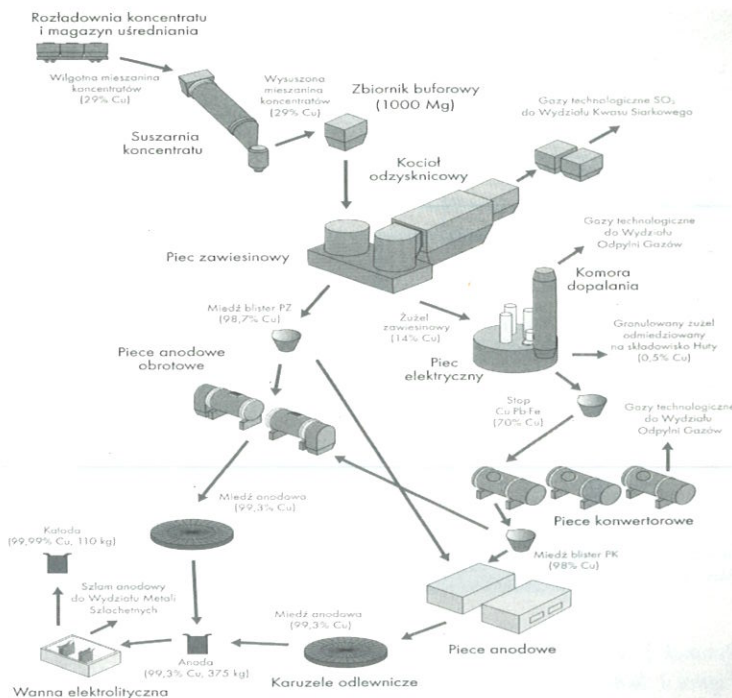
- przygotowanie wsadu, polegające na wysuszeniu koncentratu do zawartości około 0,3 % H_2O i uzyskaniu odpowiedniego składu ziarnowego;
- stapianie koncentratu w piecu zawiesinowym celem uzyskania miedzi o jakości zbliżonej do miedzi konwertorowej i strumienia gazów technologicznych o stężeniu SO_2 , zapewniającym ich utylizację;
- odmiedziowanie żużla z procesu zawiesinowego w piecu elektrycznym do zawartości Cu poniżej 0,6 % w żużlu;
- konwertowanie stopu CuPbFe celem wytworzenia miedzi konwertorowej zawierającej poniżej 0,3 % Pb i poniżej 0,2 % As.

2.1. Schemat budowy pieca zawiesinowego

Piec zawiesinowy składa się z trzech zasadniczych segmentów:

- szybu reakcyjnego,
- wanny odstożowej,
- szybu gazowego.

Budowę pieca zawiesinowego przedstawiono schematycznie na rysunku 2.




Rysunek 1. Schemat technologiczny wytwarzania miedzi (Talar i in., 2004).
Figure 1. Schematic diagram of technological process of copper production.

2.2. Procesy w szybie pieca

Konstrukcja palnika koncentratu, zapewnia dostarczenie dmuchu wzbogaconego w tlen (60–80% obj. O_2), niezbędnego do zajścia reakcji utleniania. Ilość tlenu potrzebna na jednostkę masy koncentratu dla założonego stopnia utlenienia wynika ze składu chemicznego koncentratu.

Stopień przemiany poszczególnych ziaren koncentratu zależy od ich wielkości. Minerale miedzi zawarte w ziarnach najmniejszych ulegają utlenieniu do tlenku miedziowego, w ziarnach średniej wielkości do metalicznej miedzi i tlenku miedziowego, natomiast w ziarnach największych utleniana jest tylko warstwa zewnętrzna. Stąd w wannie odstożowej pieca miedź występuje w postaci metalicznej, utlenionej (Cu_2O) oraz także jako siarczek Cu_2S . Różnicowana wielkość ziaren koncentratu i ich gęstość powodują, że czas ich przebywania w szybie jest różny. Rezultatem tego jest różny stopień utlenienia poszczególnych cząstek (Talar i in., 2004).

W szybie reakcyjnym mają miejsce reakcje egzotermicznego utleniania składników wsadu tj. węgla oraz siarczków miedzi i innych metali, a także endotermiczne reakcje dysocjacji złożonych siarczków Cu i Fe, węglanów wapnia i magnezu oraz siarczanów. Rozdrobnienie cząstek koncentratu i dobre wymieszanie z otaczającym je gazem powodują, że reakcje utleniania składników koncentratu i wymiana ciepła zachodzą z dużą intensywnością już w górnej części



Rysunek 2. Schemat pieca zawieszinowego (Talar i in., 2004).
Figure 2. Scheme of copper flash smelting furnace.

szybu reakcyjnego. Reakcje te są kontrolowane przez transport tlenu z fazy gazowej do powierzchni siarczków.

2.3. Reakcje w wannie odstojuwej

Cząstki koncentratu zawierające nieutlenione składniki jak FeS , Cu_2S , PbS opadając do warstwy żużla reagują z jego składnikami a głównie z Cu_2O , co powoduje wydzielanie miedzi i SO_2 . W ten sposób żużel zawierający Cu_2O spełnia obok roli kolektora tlenków, także rolę filtra chemicznego, zabezpieczającego metal przed zanieczyszczeniem go siarką, a także metalami o większym powinowactwie do tlenu aniżeli Cu.

Po zajściu reakcji w wannie odstojuwej następuje grawitacyjne oddzielenie wytworzonej miedzi od żużla na skutek dużej różnicy gęstości.

Obecność w kąpieli, w wannie odstojuwej, zarówno tlenków jak i siarczków metali stwarza możliwość przebiegu reakcji pomiędzy nimi, połączonej z emisją z fazy ciekłej SO_2 o wysokiej prężności par. Powoduje to silne mieszanie kąpieli i jej spienianie. W przypadku, gdy procesy zachodzące w szybie reakcyjnym przebiegały przy niedoborze tlenu lub w zbyt niskiej temperaturze (np. w wyniku zbyt dużego udziału składników energochłonnych we wsadzie), może dojść do niekontrolowanego wzrostu udziału tych reakcji w piecu. Powoduje to pojawianie się silnie porowatej warstwy spienionego żużla pomiędzy fazami ciekłymi w wannie odstojuwej. Występuje wówczas gwałtowny, pozorny wzrost poziomu topu. Zjawisko takie nazywane jest „gotowaniem”.

3. DEFINICJA PROBLEMU

Podczas wytwarzania miedzi w piecu zawieszinowym często występuje zjawisko gotowania kąpieli w wannie odstojuwej. Zjawisko to jest niepożądane i powstaje ono na styku warstwy żużla i miedzi blister. Wzrost poziomu gotowania jest zjawiskiem niebezpiecznym, ponieważ może grozić uszkodzeniem sklepienia pieca i jego rozerwaniem. Wymogi technologiczne agregatu powodują, że poziom gotowania musi być kontrolowany. Dlatego też dokonuje się pomiarów po-

ziomu gotowania. Pomiary te wykonywane są co godzinę, natomiast brak jest informacji na temat bieżącego poziomu gotowania kąpieli. Tylko w uzasadnionych i krytycznych sytuacjach pomiary te dokonywane są z większą częstotliwością (np. po zidentyfikowaniu wysokiego poziomu gotowania).

Przewidywanie poziomu gotowania jest bardzo istotne z punktu widzenia sterowania pracą pieca zawieszinowego. Należy wspomnieć, że obecnie w warunkach przemysłowych zjawisko gotowania jest niemożliwe do przewidzenia. Dlatego też w ramach niniejszej pracy podjęto próbę zastosowania metod sztucznej inteligencji w celu opracowania modelu tego złożonego zjawiska, który mógłby być wykorzystany w sterowaniu pracą pieca zawieszinowego w warunkach rzeczywistych.

4. METODY BADAWCZE

Do przewidywania zjawiska gotowania zastosowano następujące metody sztucznej inteligencji:

- Sieci Bayesowskie (SB),
- Sztuczne Sieci Neuronowe (SSN),
- System Ekspertowy (SE).

4.1. Sieci Bayesowskie

Sieci bayesowskie są szczególnym przypadkiem modeli probabilistycznych. Zwykle są wykorzystywane do modelowania złożonych systemów o niepewnych lub niekompletnych danych. Sieć bayesowska jest skierowanym acyklicznym grafem, którego topologia opisuje zależności między zmiennymi modela-

mi. Przykład prostej sieci bayesowskiej przedstawia rysunek 3.

Węzły sieci Bayesa przedstawiają zmienne (atrybuty baz danych), natomiast połączenie między węzłami reprezentują związki pomiędzy węzłami. Zależności te są wyrażone za pomocą prawdopodobieństw warunkowych. Rodzicem jest węzeł, który wpływa na inny węzeł. Węzeł, który nie ma rodziców nazywany jest korzeniem sieci i opisywany prawdopodobieństwem bezwzględnym (Ribeiro-Neto, Baeza-Yates, 1999).

Istotną zaletą sieci bayesowskich jest przejrzystość oraz czytelność obrazu modelu. Graficzne przedstawienie struktury grafu pozwala na łatwe tworzenie lub modyfikację sieci przez eksperta, dzięki czemu można wykorzystywać jego specjalistyczną wiedzę w prosty sposób. Struktury sieci można odkrywać na podstawie danych także w sposób automatyczny; jest to zadanie złożone obliczeniowo, lecz wykonywalne za pomocą szerokiej gamy skutecznych algorytmów oraz strategii heurystycznych.


Tym, co odróżnia sieci bayesowskie od innych metod reprezentowania wiedzy, jest duża zdolność wnioskowania. Skupiając się tylko na opisie jakościowym (graficznej strukturze sieci), możemy odkrywać warunkowe zależności zmiennych. Uwzględniając opisy jakościowe (parametryczne modele przypisane węzłom), możemy znaleźć najbardziej prawdopodobną (w świetle dostępnych obserwacji) konfigurację nieobserwowalnych zmiennych. Możemy również obliczyć prawdopodobieństwo hipotezy, biorąc pod uwagę konkretne obserwacje albo określić poziom pewności wyrażen logicznych.

W oparciu o sieci bayesowskie możemy budować klasyfikatory modyfikujące naszą aprioryczną wiedzę o klasyfikacji obiektów, wykorzystując przy tym informację zawartą w konkretnym modelu danych.

Do uczenia zastosowano Naiwny klasyfikator bayesowski, który reprezentuje hipotezy za pomocą oszacowań pewnych prawdopodobieństw tworzonych na podstawie zbioru trenującego i klasyfikuje przykłady, wybierając dla nich kategorie najbardziej prawdopodobne w świetle tych oszacowań.

Naiwny klasyfikator Bayesa jest jedną z metod uczenia maszynowego, stosowaną do rozwiązywania problemu sortowania i klasyfikowania. Zadaniem klasyfikatora Bayesa jest przyporządkowanie nowego przypadku do jednej z klas decyzyjnych, przy czym zbiór klas decyzyjnych musi być skończony i zdefiniowany a priori. Do przypisania przypadku do określonej klasy klasyfikator wykorzystuje twierdzenie Bayesa (Cichosz 2000).

Twierdzenie Bayesa mówi, że dla dwóch niezależnych zdarzeń A i B prawdopodobieństwo wystąpienia B, jeśli wystąpiło A wynosi:



$$P(X_1, X_2, X_3, X_4, X_5) = P(X_1) \cdot P(X_2, X_3) \cdot P(X_4 | X_2, X_3) \cdot P(X_5 | X_3)$$

Rysunek 3. Prosta Sieć Bayesa (Ribeiro-Neto., Baeza-Yates, 1999).
Figure 3. Simple Bayesian Network.

$$P(B|A) = \frac{P(A) \cdot P(A|B)}{P(A)} \quad (1)$$

gdzie:

$P(A)$ oznacza prawdopodobieństwo że wystąpi A, $P(A|B)$ oznacza prawdopodobieństwo że wystąpi A pod warunkiem, że wystąpiło już B.

Naiwny klasyfikator bayesowski na podstawie zbioru trenującego dokonuje szacowania prawdopodobieństwa poszczególnych kategorii pojęcia docelowego oraz prawdopodobieństwa poszczególnych wartości wszystkich atrybutów dla przykładów różnych kategorii (Cichosz 2000).

Szacowanie prawdopodobieństw dokonuje się zgodnie z równaniami:

$$\Pr_{x \in \Omega}(c(x) = d) = \frac{|T^d| + 1}{|T| + |C|} \quad (2)$$

$$\Pr_{x \in \Omega}(a_i(x) = \vartheta | c(x) = d) = \frac{|T_{a_i \vartheta}^d| + 1}{|T^d| + |A_i|} \quad (3)$$

gdzie:

T – liczba wszystkich przykładów w zbiorze trenującym,

T^d – ilość w zbiorze trenującym przykładów poszczególnych kategorii,

$T_{a_i, \vartheta}^d$ – ilość przykładów każdej kategorii dla poszczególnych wartości każdego atrybutu,

A_i – przeciwność atrybutu a_i ,

C – zbiór pojęć docelowych.

Naiwny klasyfikator bayesowski zakłada, że wartości poszczególnych atrybutów są od siebie warunkowo (względem kategorii) niezależne, czyli że zachodzi następująca równość:

$$P(a_1, a_2, \dots, a_n | \vartheta_i) = \prod_i P(a_i | \vartheta_i) \quad (4)$$

Naiwność klasyfikatora polega na założeniu, że zmienne losowe odpowiadające poszczególnym wymiarom przestrzeni są niezależne, co znacznie ułatwia

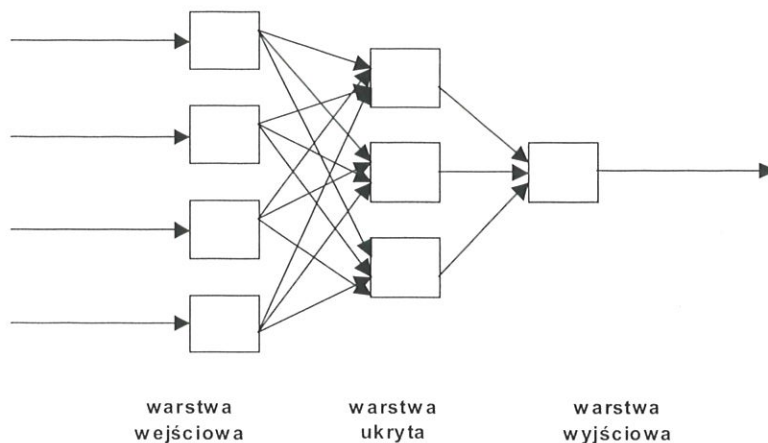


wyliczenie prawdopodobieństw przynależności do poszczególnych klas. W przypadku przestrzeni cech dyskretnych prawdopodobieństwa mogą być z łatwością wyliczone na podstawie danych treningowych (Grabczewski, 2003).

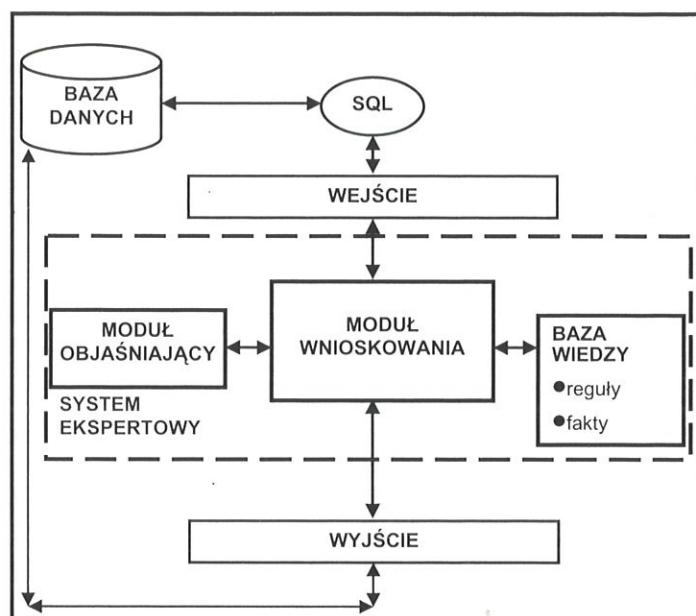
4.2. Sztuczne Sieci Neuronowe

W pracy wykorzystano sztuczne sieci neuronowe typu MLP (perceptron wielowarstwowy). Sztuczne sieci neuronowe (SSN) (Tadeusiewicz, 1993; Osowski, 1996) powstały na gruncie wiedzy o działaniu systemu nerwowego istot żywych i stanowią próbę wykorzystania zjawisk zachodzących w systemach nerwowych do rozwiązywania złożonych zadań, w tym również problemów przemysłowych. Podstawową własnością SSN jest zdolność do przyswajania wiedzy na podstawie prezentowanych przykładów, oraz zdolność do uogólnień, które pozwalają na ich zastosowanie do nowych sytuacji - przypadków, niewystępujących w zbiorze uczącym. Ponadto SSN dobrze radzą sobie z danymi niekompletnymi i zakłóconymi. Charakteryzują się także dużą szybkością działania, co kwalifikuje je do zastosowań w systemach czasu rzeczywistego. SSN stanowią również skuteczne narzędzie do modelowania procesów, zdolne do odwzorowywania złożonych funkcji, mających również charakter nieliniowy, co daje duże możliwości ich zastosowań.

Sieci wielowarstwowe są najczęściej stosowanym modelem sieci neuronowej. Sieć tego typu jest przykładem sieci jednokierunkowej i składa się z warstwy wejściowej, wyjściowej oraz warstw ukrytych. Schemat przykładowej struktury sieci wielowarstwowej przedstawiono na rysunku 4.



Rysunek 4. Schemat struktury sieci wielowarstwowej.
Figure 4. Scheme of the Multilayer Perceptron structure.



Rysunek 5. Schemat budowy systemu ekspertowego.
Figure 5. Scheme of Expert System.

4.3. System Ekspertowy

W pracy zastosowano regułowy system ekspertowy (SE) (Mulawka, 1996; Hopgood, 2000). Opracowany system ekspertowy składał się z bazy wiedzy zawierającej zestaw reguł i faktów, modułu wnioskowania i modułu objaśniającego podjęte decyzje. System ekspertowy został sprzężony z bazą danych poprzez instrukcje zapytań SQL. Schemat budowy systemu ekspertowego przedstawiono na rysunku 5.

Bazę wiedzy systemu ekspertowego opracowano na podstawie algorytmu generowania drzew decyzyjnych C4.5 (Quinlan, 1986; 1993). Szczegółowe omówienie metodyki tworzenia bazy wiedzy systemu ekspertowego na podstawie algorytmu Quinlana można znaleźć w pracy (Talar, 2003).

5. ZASTOSOWANIE METOD SZTUCZNEJ INTELIGENCJI DO PRZEWIDYWANIA POZIOMU GOTOWANIA

Do budowy modeli wykorzystano dane zebrane w warunkach przemysłowych, pochodzące z różnych okresów pracy pieca.

Problem przewidywania poziomu gotowania w piecu zawieszinowym sprowadzono do zagadnienia klasyfikacji. Pomiary poziomu gotowania charakteryzowały się małą dokładnością (ze względu na sposób ich wykonywania, zależny od czynnika ludzkiego), dlatego też poziom gotowania podzielono na następujące kategorie: poziom gotowania poniżej 300 mm traktowany był jako odpowiedni i przypisano mu kategorie „OK”, poziom gotowania większy lub równy

300 i mniejszy od 600 mm traktowany był jako „OSTRZEŻENIE”, natomiast większy lub równy 600 mm traktowany był jako zjawisko niepożądane i przypisano mu kategorii „ŻLE”.

Dla opracowania modelu opisującego zjawisko gotowania w piecu zawieszinowym uwzględniono 57 parametrów wejściowych procesu (rysunek 6).

Sieci Bayesowskie

Do klasyfikacji parametru gotowania wykorzystano program WEKA (Kirkby, 2002), który zawiera zbiór algorytmów do uczenia maszyn. Algorytmy mogą być stosowane bezpośrednio ze zbioru „Data” lub własne napisane w kodzie Javy. Program udostępnia oprócz zestawu algorytmów również w miarę funkcjonalne środowisko graficzne GUI. WEKA zawiera narzędzia dla danych – przetwarzania, klasyfikacji, stosowania reguł i wizualizacji. W pracy zastosowano naiwny klasyfikator bayesowski, który szacuje prawdopodobieństwa zgodnie z równaniami (2) i (3).


Do uczenia wykorzystano 1500 rekordów danych pomiarowych oraz 500 rekordów danych do testowania.

Sztuczne Sieci Neuronowe

Do przewidywania zjawiska gotowania zastosowano sztuczną sieć neuronową typu MLP o topologii 57-43-3. Sygnałami wejściowymi sieci były parametry wejściowe pieca, natomiast sygnały wyjściowe odpowiadały trzem kategoriom poziomu gotowania: „OK”, „OSTRZEŻENIE”, „ŻLE”. Do uczenia sieci wykorzystano metodę wstecznej propagacji błędów. Zbiór uczący obejmował 1000 rekordów danych pomiarowych, natomiast zbiory walidacyjny i testowy zawierały po 500 rekordów danych. W obliczeniach wykorzystano pakiet Statistica Neural Networks PL (wersja 4.0 F).

System Ekspertowy

Algorytm C4.5 Quinlana posłużył do opracowania bazy wiedzy regułowego systemu ekspertowego. Zbiór uczący obejmował 1500 rekordów danych pomiarowych, natomiast zbiór testowy 500. Baza wie-



Rysunek 6. Model pieca zawieszinowego.
Figure 6. Model of copper flash smelting furnace.

dzy zawierała 77 reguły decyzyjne. Do opracowania systemu ekspertowego wykorzystano pakiet sztucznej inteligencji SPHINX firmy AITECH.

6. WYNIKI PRZEWIDYWANIA POZIOMU GOTOWANIA

Wyniki przewidywania poziomu gotowania metodami sztucznej inteligencji zamieszczono w tabeli 1. Przedstawione wyniki dotyczą zbioru testowego zawierającego 500 rekordów danych pomiarowych. Graficzną interpretację uzyskanych wyników przedstawiono na rysunku 7.

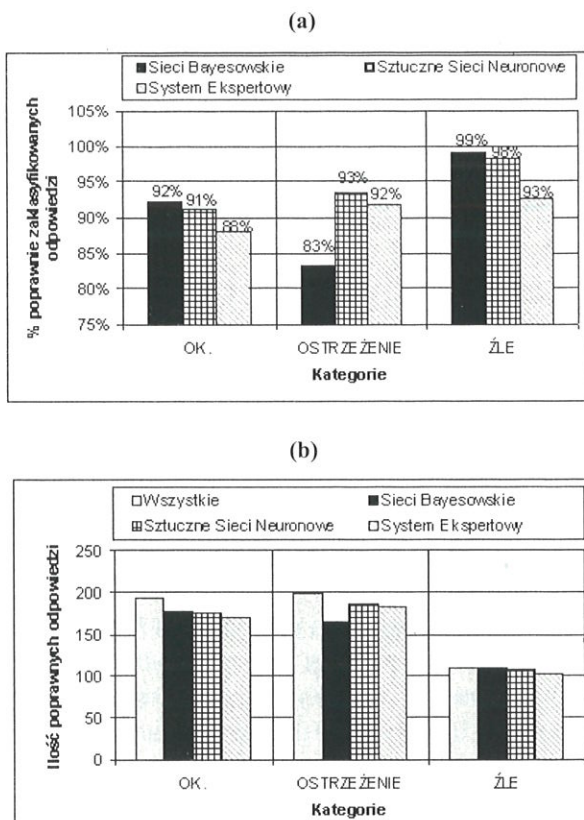
Tabela 1. Wyniki przewidywania poziomu gotowania metodami sztucznej inteligencji.
Table 1. Results of prediction of the boiling level obtained from the artificial intelligence methods.

Metody Badawcze	% poprawnie zaklasyfikowanych odpowiedzi do kategorii		
	OK	OSTRZEŻENIE	ŻLE
<i>Sieci Bayesowskie</i>	92%	83%	99%
<i>Sztuczne Sieci Neuronowe</i>	91%	93%	98%
<i>System Ekspertowy</i>	89%	91%	95%

7. PODSUMOWANIE

W pracy podjęto próbę zastosowania metod sztucznej inteligencji do przewidywania istotnego dla sterowania procesem wytopu miedzi parametru wyjściowego, jakim jest poziom „gotowania”. Celem było opracowanie trzech metod badawczych (SB, SSN, SE), które w oparciu o parametry wejściowe potrafią przewidzieć poziom gotowania. Poziom gotowania jest parametrem wyjściowym a zarazem niepożądanym zjawiskiem w procesie wytopu miedzi. W pracy wykorzystano dane przemysłowe.

Przeprowadzona analiza uzyskanych wyników wskazuje, że zaprezentowane w pracy metody sztucznej inteligencji (sieci bayesowskie, sztuczne sieci neuronowe i system ekspertowy), mogą być z powodzeniem wykorzystane do modelowania procesu zawieszinowego wytopu miedzi. W przypadku analizy



Rysunek 7. Porównanie wyników zastosowania metod sztucznej inteligencji w przewidywaniu poziomu gotowania: (a) - procent poprawnych odpowiedzi, (b) - ilość poprawnych odpowiedzi.

Figure 7. Comparison of the results of artificial intelligence methods in prediction of the boiling level: (a) - percentage of correct answers, (b) - quantity of correct answers.

zjawiska gotowania sieci bayesowskie dają lepsze wyniki w zaklasyfikowaniu przykładów do kategorii „OK” i „ŹLE”, w porównaniu z dwoma pozostałymi metodami. Natomiast dokładniejsze wartości przewidywania poziomu gotowania zaklasyfikowanych do kategorii „OSTRZEŻENIE”, uzyskano przy wykorzystaniu sieci neuronowych oraz systemów ekspertowych.

Uzyskane wyniki pozwalają stwierdzić, że SB, SSN oraz SE są efektywnym narzędziem do przewidywania parametrów wyjściowych złożonych procesów przemysłowych.

Praca wykonana w ramach badań statutowych nr 11.11.110.575.

LITERATURA

- Cichosz, P., 2000, *Systemy uczące się*, WNT, Warszawa.
- Grąbczewski, K., 2003, *Zastosowanie kryterium separowalności do generowania reguł klasyfikacji na podstawie baz danych*, Praca doktorska, Warszawa.
- Hopgood, A.A., 2000, *Intelligent Systems for Engineers and Scientists*, CRC Press.
- Kirkby, R., 2002, *WEKA Explorer User Guide for Version 3-3-4*.
- Mulawka, J., 1996, *Systemy ekspertowe*, WNT, Warszawa.
- Osowski, S., 1996, *Sieci neuronowe*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Quinlan, J.R., 1986, Induction of decision trees, *Machine Learning*, 1, 81-106.
- Quinlan, J.R., 1993, *C4.5: Programs for Machine Learning*, Morgan Kaufmann.
- Ribeiro-Neto B., Baeza-Yates, R., 1999, *Modern Information Retrieval*, Addison Wesley.
- Tadeusiewicz R., 1993, *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa.
- Talar, J., 2003, *Komputerowy model wspomaganie operacyjnych decyzji technologicznych w walcowni zimnej blach*, Praca doktorska, AGH, Kraków.
- Talar, J., Jarosz, P., Kondek, T., Kusiak, J., Staszak, J., 2004, Zastosowanie sztucznych sieci neuronowych do sterowania zawieszinowym przetopem koncentratów miedzi, *Mat. 11. Konf. Informatyka w Technologii Metali KomPlasTech'2004*, ed., Grosman, F., Piela., A., Pietrzyk, M., Kusiak, J., Zakopane, Akapit, 291-300.
- Themelis, N.J., 1987, Transport phenomena in high-intensity smelting furnaces, Inst. Mining and Metallurgy, *Pyrometallurgy '87*, London.
- Themelis, N.J., 1988, Entry and Phase transition phenomena in flash smelting reactors, *Proc. of MEFOS Symposium*, Lulea.

Artykuł otrzymano 6 września 2005 r.