

STATYCZNY MODEL KONWERTORA TLENOWEGO OPARTY O SZTUCZNĄ SIĘĆ NEURONOWĄ

JAN FALKUS, PIOTR PIETRZKIEWICZ, WOJCIECH PIETRZYK, JAN KUSIAK

STATIC MODEL OF OXYGEN CONVERTER PROCESS BASED ON THE ARTIFICIAL NEURAL NETWORK

Abstract

The main objective of this work is to develop a new type of static model of oxygen converter process, using artificial neural networks (ANN). The ANN-based static model consists of two parts. First, the temperature of the hot metal is predicted. Secondly, the volume of the oxygen blow is predicted. Training and testing data come from real oxygen converter industrial processes. A series of tests was executed, aimed at defining the optimum network structure that would enable prediction of the parameters of the converter charge. Different configurations of the input variables were tested. The ANN results were compared against the statistical and mass - heat balance models.

1. WPROWADZENIE

Proces konwertorowy jest aktualnie dominującym w przemyśle stalowniczym, czego dowodem jest fakt, że około 80% całej światowej produkcji stali wytwarza się tą metodą. Z tego względu, nawet najdrobniejsze usprawnienia w technologii procesu konwertorowego (LD) prowadzą do olbrzymich oszczędności. Obszarem, który posiada dominujący wpływ na efektywność całego procesu, jest zagadnienie sterowania. Biorąc pod uwagę, że czas cyklu rafinacji stali (czas pojedynczego wytopu) waha się od 15 do 20 minut, niewłaściwy algorytm sterowania może prowadzić do dużych strat i dlatego poszukuje się coraz nowocześniejszych i bardziej sprawnych systemów sterowania.

System sterowania procesem konwertorowym składa się z dwóch podstawowych części. Pierwsza dotyczy sterowania statycznego w układzie off-line, którego celem jest odpowiedni dobór materiałów wsadowych wytopu. Druga część, dynamiczna, obejmuje sam proces od momentu załadunku pieca, poprzez dmuch, do spustu stali z pieca. Model dynamiczny oparty jest o pomiary zawartości węgla i temperatury kąpieli przy pomocy sublancy lub o pomiar składu gazów odlotowych.

Głównym celem niniejszej pracy jest opracowanie statycznego modelu do sterowania procesem konwertorowym, opartego o sztuczną sieć neuronową. Opracowana sztuczna sieć neuronowa pozwala na przewidywanie temperatury kąpieli metalu oraz ilości tlenu w dmuchu głównym na podstawie znajomości takich

wielkości wejściowych jak masa i temperatura ciekłej surówki, masa i rodzaj złomu, masa rudy, itp. Uzyskane wyniki porównano z obliczeniami wykonanymi przy użyciu klasycznych modeli: opartego o analizę liniowej regresji wielokrotnej oraz o bilans materiałowo-ciepłny procesu.

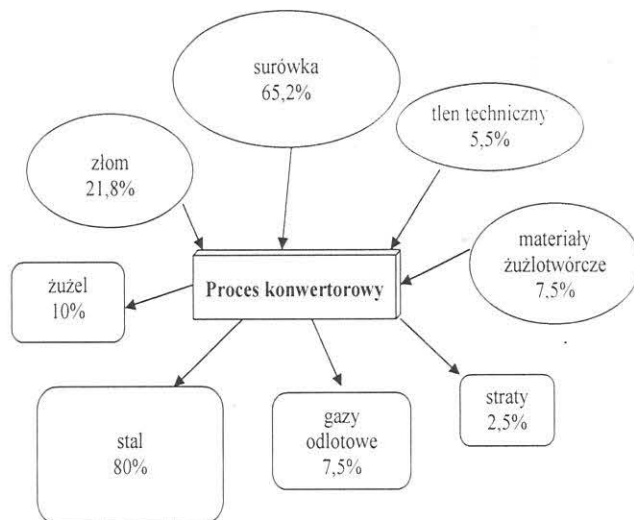
2. BILANS MATERIAŁOWO-CIEPLNY PROCESU

Istotą procesu konwertorowego jest przedmuchanie surówki żelaza technicznie czystym tlenem gazowym. Struga tlenu wdmuchiwana jest z prędkością naddźwiękową, dzięki czemu głęboko wnika w kąpiel. Zachodzące w układzie reakcje zależą od aktualnego składu chemicznego metalu tj. rodzaju i ilości domieszek w kąpeli. Główną domieszkę surówki stanowi węgiel, który utleniając się daje produkt gazowy tworząc w konwertorze tzw. emulsję metalowo-żużlową. Produkty utleniania pozostałych domieszek takich jak Si, Mn, P przechodzą do żużla.

Proces konwertorowy jest procesem, w którym praktycznie brak jest możliwości korekty energii podczas jego trwania. Źródło energii stanowi ciepło fizyczne ciekłej surówki oraz utajone ciepło chemiczne zawartych we wsadzie domieszek. Z tego względu sposób zestawienia wsadu do każdego wytopu ma decydujące znaczenie dla ekonomiki procesu. Ponieważ suma fizycznego ciepła surówki i ciepła chemicznego domieszek jest zbyt duża (byłyby osiągnane zbyt wysokie temperatury końcowe) zachodzi konieczność korekty wsadu metalicznego poprzez dodatek złomu. Ponadto do wsadu wprowadzane są materiały żużłotwórcze: wapno, dolomit itp. Jako czynnik chłodzący niekiedy bywa stosowana ruda żelaza. W okresach niedoboru surówki w celu podniesienia wskaźnika zużycia złomu do procesu wprowadza się koks (Kruściński i Falkus, 1988).

Produktem procesu konwertorowego jest kąpiel metalowa o założonym składzie chemicznym i temperaturze. Produkt uboczny stanowi żużel oraz gazy odlotowe. Przykładowy bilans materiałowy procesu LD przedstawiono na rysunku 1.

Przyjęcie pewnych założeń upraszczających dotyczących określenia procentowej wielkości strat żelaza przechodzącego do żużla, strat na parowanie i wyrzuty metalu, poziomu utlenienia CO do CO₂, itp., umożliwi wyliczenie wektora wielkości wyjściowych (kąpiel metalowa, żużel, gazy odlotowe) na podstawie znajomości wielkości wejściowych (surówka, złom, wapno, tlen, etc.). Dokładna znajomość poszczególnych pozycji bilansu materiałowego stanowi podstawę do sporządzenia bilansu cieplnego. Równanie bilansu cieplnego ma postać:



Rys. 1. Przykładowy bilans materiałowy wytopu w konwertorze tlenowym.

$$Q_{\text{przychodów}} = Q_{\text{rozchodów}} \quad (1)$$

Równanie (1) stanowi model matematyczny procesu. Niewiadomą równania jest temperatura kąpeli metalowej, która występuje w niektórych członach składających się na $Q_{\text{rozchodów}}$. Dużym problemem bilansu cieplnego jest oszacowanie strat cieplnych wchodzących w skład $Q_{\text{rozchodów}}$. Bardzo często ich wartość szacowana jest na podstawie wytopów już wykonanych, dla których dokonuje się minimalizacji sumy kwadratów różnic temperatury obliczonej i temperatury rzeczywistej.

Zgodnie z podanym opisem procesu, bilans cieplny wytopu obejmuje po stronie przychodów dwie główne pozycje: ciepło fizyczne surówki oraz ciepło utleniania domieszek. Ciepło fizyczne surówki Q_{sur} liczone jest według następującej zależności:

$$Q_{\text{sur}} = m_{\text{sur}} \left[c_{\text{wsur}_s} T_{\text{top}} + c_{\text{wsur}_l} (T_{\text{sur}} - T_{\text{top}}) + c_{\text{tsur}} \right] \quad (2)$$

gdzie:

m_{sur} – masa surówki

c_{wsur_s} – średnie ciepło właściwe surówki stałej, kJ/kg·K ($c_{\text{wsur}_s} = 0,744$ kJ/kg·K)

T_{top} – temperatura topnienia surówki, °C

c_{tsur} – utajone ciepło topnienia surówki, kJ/kg·K ($c_{\text{tsur}} = 217,36$ kJ/kg·K)

T_{sur} – temperatura surówki, °C

c_{wsur_l} – średnie ciepło właściwe surówki ciekłej, kJ/kg·K ($c_{\text{wsur}_l} = 0,836$ kJ/kg·K)

Druga istotna pozycja bilansu, czyli ciepło utleniania domieszek liczone jest w oparciu o znajomość ciepła reakcji cząstkowych, które dla poszczególnych domieszek wynoszą odpowiednio: $Q_{\text{C/CO}} = 10443$ kJ/kg CO, $Q_{\text{C/CO}_2} = 34014$ kJ/kg CO₂, $Q_{\text{Si}} = 31029$ kJ/kg Si, $Q_{\text{Mn}} = 7350$ kJ/kg Mn, $Q_{\text{P}} = 24945$ kJ/kg P. Ważną

pozycję stanowi również proces utlenianie żelaza, który należy minimalizować z uwagi na jego negatywny wpływ na osiągany uzysk stali oraz zużycie żelazostopów przy odtlenianiu. Efekty cieplne tych reakcji zamieszczono w Tabeli 1.

Tabela 1. Efekty cieplne reakcji utleniania żelaza.

Rodzaj reakcji	Efekt cieplny
$Fe \rightarrow FeO$	$Q = 4198 \text{ kJ/kg Fe}$
$Fe \rightarrow Fe_2O_3$	$Q = 7349 \text{ kJ/kg Fe}$

Po stronie rozchodów najważniejsze pozycje bilansu cieplnego to ciepło fizyczne stali Q_{stal} , żużła $Q_{żużel}$ oraz ciepło gazów odlotowych Q_{gazy} liczone odpowiednio według wzorów:

$$Q_{stal} = m_{stal} \left[c_{wst_s} T_{top_st} + c_{wst_l} \left(T_{stali} - T_{top_st} \right) + c_{t_stali} \right] \quad (3)$$

$$Q_{żużel} = m_{żużel} \left[c_{w_żużel} T_{stal} + c_{t_żużel} \right] \quad (4)$$

$$Q_{gazy} = 2,357V_{CO_2} T_{spalin} + 2,357V_{CO} T_{spalin} + 1,83V_{H_2O} T_{spalin} \quad (5)$$

gdzie:

m_{stal} – masa stali, kg

c_{wstal_s} – średnie ciepło właściwe stali stałej, kJ/kg K ($c_{wstal_s} = 0,698 \text{ kJ/kg}\cdot\text{K}$)

T_{top_st} – temperatura topnienia stali, °C

c_{wstal_l} – średnie ciepło właściwe stali ciekłej, kJ/kg·K ($c_{wstal_l} = 0,836 \text{ kJ/kg}\cdot\text{K}$)

T_{stal} – temperatura stali, °C

c_{t_stali} – utajone ciepło topnienia stali, kJ/kg·K ($c_{t_stali} = 271,7 \text{ kJ/kg}\cdot\text{K}$)

$m_{żużel}$ – masa żużła, kg

$c_{w_żużel}$ – średnie ciepło właściwe żużła, kJ/kg·K ($c_{w_żużel} = 1,246 \text{ kJ/kg}\cdot\text{K}$)

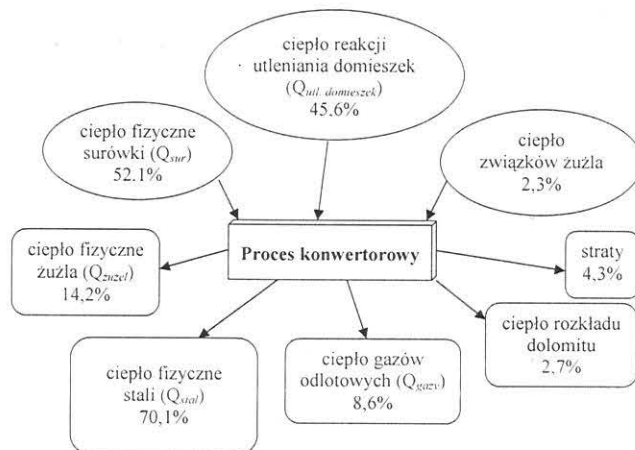
$c_{t_żużel}$ – utajone ciepło topnienia żużła, kJ/kg·K ($c_{t_żużel} = 209 \text{ kJ/kg}\cdot\text{K}$)

$V_{CO_2}, V_{CO}, V_{H_2O}$ – odpowiednio objętości CO_2, CO i H_2O w gazach odlotowych, Nm^3

T_{spalin} – temperatura spalin, °C

Schemat przykładowego bilansu cieplnego wytopu w konwertorze tlenowym przedstawiono na rysunku 2.

Zastosowanie modelu opartego o bilans materiałowo-cieplny pozwala obliczyć temperaturę końcową stali oraz zapotrzebowanie na tlen. Celem sterowania jest zapewnienie odpowiedniej temperatury końcowej



Rys. 2. Przykładowy bilans cieplny wytopu w konwertorze tlenowym.

kapieli, która jest wielkością zadaną. Zadaniem statycznego systemu sterowania jest iteracyjne modyfikowanie udziałów surowki i złomu we wsadzie aż do momentu uzyskania założonej dokładności temperatury zadanej. W takim wypadku o skuteczności systemu sterowania decyduje wiarygodność modelu obliczającego wymienione parametry. Po ustaleniu udziałów surowki i złomu we wsadzie kolejną decyzją podejmowaną przed rozpoczęciem wytopu jest ustalenie ilości tlenu potrzebnego do przeprowadzenia procesu. W przypadku modeli bilansowych informacja o zapotrzebowaniu na tlen wyznaczana jest w oparciu o bilans cząstkowy wymagający przyjęcia dodatkowych założeń (poziom utlenienia pyłów konwertorowych, stopień utlenienia żużła oraz poziom dopalenia CO do CO_2).

Tabela 2. Średni błąd kwadratowy (RMS) uzyskany dla modeli opartych o bilans materiałowo-cieplny.

Numer kampanii	Średni błąd kwadratowy (RMS)	
	Model temperatury, [°C]	Model dmuchu głównego, [Nm^3]
Kampania I	101	1252
Kampania II	95	1129
Kampania III	91	1104

W tabeli 2 przedstawiono porównanie wartości średniego błędu kwadratowego pomiędzy wynikami obliczeń modeli opartych o bilans materiałowo-cieplny, przewidujących temperaturę oraz zapotrzebowania na tlen i wartościami zmierzonymi w rzeczywistym procesie przemysłowym. Średni błąd kwadratowy (RMS) wyznaczony jest według wzoru:

$$RMS = \sqrt{\frac{\sum_{i=1}^N (Y_{Model}^i - Y_{Rzecz}^i)^2}{N}} \quad (6)$$

gdzie:

Y_{Model} – wartość zmiennej wyjściowej wyliczonej z modelu,

Y_{Rzecz} – rzeczywista wartość zmiennej wyjściowej,

N – liczba analizowanych przypadków.

3. ANALIZA REGRESYJNA PROCESU KONWERTOROWEGO

W klasycznym podejściu do zagadnienia modelowania, jednym z częściej stosowanych narzędzi jest analiza regresyjna, której celem jest opracowanie modelu (równania), pozwalającego na przewidywanie wartości sygnału wyjściowego procesu w oparciu o znajomość sygnałów wejściowych. W ramach niniejszej pracy podjęto próbę opracowania statycznego modelu przewidującego temperaturę kąpieli metalu oraz zapotrzebowanie na tlen w procesie konwertorowym. Dla każdego z tych modeli zadaniem analizy opartej o regresję wielokrotną jest wyznaczenie współczynników b_i równania o postaci:

$$\hat{Y} = b_n x_n + b_{n-1} x_{n-1} + \dots + b_1 x_1 + b_0 \quad (7)$$

gdzie:

\hat{Y} – odpowiednio: temperatura końcowa kąpieli metalowej lub wielkość zapotrzebowania na tlen w dmuchu głównym,

x_1, \dots, x_n – zmienne wejściowe procesu (wykaz najważniejszych zmiennych wejściowych wykorzystywanych w modelu znajduje się w tabelach 3–5),

b_0, \dots, b_n – współczynniki regresji, które są wynikiem analizy regresyjnej.

W pracy przeprowadzono analizę regresyjną w oparciu o 3 różne podejścia:

- **regresję standardową** polegającą na tym, że wszystkie zmienne brane pod uwagę w analizie regresyjnej zostają włączone do niej w jednym kroku. Aby sprawdzić, które ze zmiennych niezależnych mają największy udział w przewidywaniu zmiennej zależnej, obliczone zostały współczynniki regresji b_i oraz standaryzowane współczynniki regresji \hat{b}_i . Współczynniki \hat{b}_i są współczynnikami, dla standaryzowanych wszystkich zmiennych do wartości średniej równej 0 oraz odchylenia standardowego równego 1. Wielkość tych współczynników pozwala porównać wkład, jaki każda ze zmiennych niezależnych wnosi w predykcję zmiennej zależnej. Im wyższa jest wartość bezwzględna współczynnika \hat{b}_i dla danej zmiennej, tym większa rola tej zmiennej jako predyktora zmiennej zależnej. Współczynniki b_i wyznaczają poszukiwane równanie regresji wielokrotnej.
- **regresję krokową postępującą** w której w każdym kroku wprowadzana jest do równania kolej-

no każda ze zmiennych. Przed rozpoczęciem obliczeń należy ustalić statystykę F_w , która określa na ile istotny jest wkład kolejnej zmiennej, aby można ją wprowadzić do równania. Następnie ustalana jest wartość F_u , która określa wartość progową, na podstawie której można przyjąć na ile „mało istotna” jest analizowana zmienna, aby można ją było usunąć z równania. Oczywiście jest, że $F_w > F_u$. W pierwszym kroku wybrana zostaje ta zmienna niezależna, dla której F_w jest największe (przy jednoczesnym spełnieniu warunku, że F_w jest większe od zadeklarowanej wartości progowej F_{w0}). W każdym następnym kroku, przy dodawaniu rozważanej zmiennej do modelu, musi być sprawdzony warunek, czy któraś ze zmiennych już wprowadzonych do modelu nie powinna być usunięta z równania w oparciu o warunek F_u . Po wykonaniu pewnej liczby iteracji, gdy okazuje się, że już żadna z pozostałych zmiennych nie spełnia warunku koniecznego by znaleźć się w poszukiwanym modelu, wyznacza się współczynniki β_i dla wszystkich zmiennych uwzględnionych w modelu. Dzięki nim, można stwierdzić, które ze zmiennych niezależnych mają największy wpływ na zmienną zależną. Wyznaczając następnie współczynniki b_i można uzyskać końcowe równanie regresji.

- **regresję krokową wsteczną**. Metoda ta polega na tym, że zmienne niezależne będą usuwane z równania regresji w każdym kroku (w zależności od wartości progowej F_w bądź F_u) aż uzyska się „najlepsze” równanie regresji. W pierwszym kroku wszystkie zmienne są zawarte w równaniu regresji. W każdym kolejnym kroku (przy ustalonym F_u o wiele wyższym niż w metodzie regresji krokowej postępującej) usunięte zostają zmienne, których F_u jest niższe od ustalonego.

Celem prowadzonej analizy regresyjnej było opracowanie dwóch modeli opisujących proces konwertorowy. Pierwszy z nich pozwala na przewidywanie temperatury kąpieli, natomiast celem drugiego jest oszacowanie objętości tlenu w dmuchu głównym w oparciu o dane wejściowe procesu. Jako podstawowy zbiór danych, który posłużył do weryfikacji modelu regresyjnego, uznano pojedynczą kampanię konwertora. Termin kampania konwertora oznacza zbiór wszystkich wytopów, które wykonano w konwertorze bez wymiany wyłożenia ogniotrwałego. Liczba wytopów w kampanii równoznaczna jest z wyjściową liczbą rekordów wykorzystywanych do celów weryfikacji modelu.

Analizowane dane, zarejestrowane w warunkach przemysłowych jednej z krajowych stalowni konwertorowych, obejmowały wytopy wykonane w ciągu 3 kampanii stalowniczych. Zbiór danych zawierał 4529 rekordów (kampanie I–III odpowiednio 1708, 1499 i

Tabela 3. Współczynniki równań regresji wielokrotnej oraz wartość średniego błędu kwadratowego (RMS) dla temperatury kąpieli metalu oraz objętości tlenu w dmuchu głównym – kampania I.

Nazwa zmiennej	Model temperatury		Model dmuchu głównego	
	Standardowa liniowa regresja wieloraka	Regresja krokowa wsteczna	Standardowa liniowa regresja wieloraka	Regresja krokowa wsteczna
wyraz wolny	1251,893	1295,033	-4329,300	-3962,779
masa surówki, kg	0,000	-0,001	0,020	0,023
temperatura surówki, °C	0,237	0,242	-2,764	-3,176
zawartość C w surówce, %	10,275		-228,671	
zawartość Mn w surówce, %	202,870	239,950	-1074,917	
zawartość Si w surówce, %	27,352		-1373,017	-1258,051
zawartość P w surówce, %	-490,976	-374,643	7990,561	
zawartość S w surówce, %	359,510		-1806,975	
masa ciężkiego złomu, kg	-0,001	-0,001	0,032	0,029
masa lekkiego złomu, kg	-0,002	-0,002	0,045	0,041
masa złomu walcowniczego, kg	-0,002	-0,002	0,062	0,062
masa złomu W15, kg	-0,002	-0,002	0,039	0,035
masa złomu surówkowego, kg	-0,003	-0,002	0,096	0,093
masa złomu z niedolewu płynnego, kg	-0,001		0,033	
wapno, kg	-0,001		0,124	0,115
dolomit, kg	-0,002		0,045	
kamień dolomitowy, kg	-0,004		0,110	
ruda, kg	-0,001		-0,085	-0,095
koks, kg	-0,010	-0,010	0,558	0,549
tlen w dmuchu głównym, Nm ³	0,017	0,016	9,866	
temperatura po dmuchu głównym, °C			9,87	9,404
błąd RMS	27,6	27,8	672,5	677,8

Tabela 4. Współczynniki równań regresji wielokrotnej oraz wartość średniego błędu kwadratowego (RMS) dla temperatury kąpieli metalu oraz objętości tlenu w dmuchu głównym – kampania II.

Nazwa zmiennej	Model temperatury		Model dmuchu głównego	
	Standardowa liniowa regresja wieloraka	Regresja krokowa wsteczna	Standardowa liniowa regresja wieloraka	Regresja krokowa wsteczna
wyraz wolny	1153,590	1151,729	2214,142	2941,975
masa surówki, kg	-0,001	-0,001	0,022	0,020
temperatura surówki, °C	0,368	0,368	-9,093	-9,027
zawartość C w surówce, %	3,357		286,199	289,796
zawartość Mn w surówce, %	-0,557		6188,409	6006,850
zawartość Si w surówce, %	36,980	49,526	-649,322	-586,786
zawartość P w surówce, %	135,911		-10656,487	-10506,060
zawartość S w surówce, %	-646,088		3872,444	
masa ciężkiego złomu, kg	-0,002	-0,001	0,032	0,030
masa lekkiego złomu, kg	-0,002	-0,002	0,043	0,041
masa złomu walcowniczego, kg	-0,002	-0,002	0,052	0,050
masa złomu W15, kg	-0,002	-0,002	0,033	0,032
masa złomu surówkowego, kg	-0,001		0,052	
masa złomu z niedolewu płynnego, kg	-0,002		0,023	
wapno, kg	0,001		0,016	
dolomit, kg	-0,001		0,009	
kamień dolomitowy, kg	0,000		0,389	
ruda, kg	0,004	0,004	-0,016	
koks, kg	-0,010	-0,010	0,565	0,565
tlen w dmuchu głównym, Nm ³	0,020	0,020	10,101	
temperatura po dmuchu głównym, °C			10,1	10,120
błąd RMS	27,5	27,7	612,3	616,4



Tabela 5. Współczynniki równań regresji wielokrotnej oraz wartość średniego błędu kwadratowego (RMS) dla temperatury kąpieli metalu oraz objętości tlenu w dmuchu głównym – kampania III.

Nazwa zmiennej	Model temperatury		Model dmuchu głównego	
	Standardowa liniowa regresja wieloraka	Regresja krokowa wsteczna	Standardowa liniowa regresja wieloraka	Regresja krokowa wsteczna
wyraz wolny	1097,460	1104,521	1861,237	2889,200
masa surówki, kg	-0,001	-0,001	0,022	0,021
temperatura surówki, °C	0,370	0,372	-8,748	-8,764
zawartość C w surówce, %	3,744		314,095	320,477
zawartość Mn w surówce, %	37,676		6091,347	5828,749
zawartość Si w surówce, %	32,304	49,360	-525,791	-524,786
zawartość P w surówce, %	185,395		-11555,341	-11226,247
zawartość S w surówce, %	-725,962		7746,230	
masa ciężkiego złomu, kg	-0,002	-0,001	0,034	0,032
masa lekkiego złomu, kg	-0,002	-0,002	0,043	0,041
masa złomu walcowniczego, kg	-0,002	-0,001	0,051	0,048
masa złomu W15, kg	-0,002	-0,002	0,034	0,033
masa złomu surówkowego, kg	-0,001		0,054	
masa złomu z niedolewu płynnego, kg	-0,002		0,026	
wapno, kg	0,001		0,013	
dolomit, kg	-0,001		-0,002	
kamień dolomitowy, kg	-0,001		0,396	
ruda, kg	0,003	0,003	-0,012	
koks, kg	-0,009	-0,009	0,566	0,565
tlen w dmuchu głównym, Nm ³	0,020	0,020	9,761	
temperatura po dmuchu głównym, °C			9,8	9,753
błąd RMS	27,3	27,6	602,3	606,9

1322 rekordów). Pojedynczy rekord zmierzonych parametrów procesu zawierał 47 zmiennych wejściowych procesu, uwzględniających parametry masy, temperatury i składu chemicznego surówki, masy i rodzaju złomu, dodatków stopowych, itp. Wiele zmiennych wejściowych posiadających niski współczynnik korelacji z sygnałami wyjściowymi, zostało pominiętych i w ostatecznej analizie wzięto pod uwagę jedynie 21 zmiennych wejściowych.

Z uwagi na fakt, że dane rejestrowane były w trakcie rzeczywistych procesów przemysłowych, wiele z nich obarczonych było błędami pomiarowymi. Dlatego też dane te zostały poddane wstępnej obróbce, która pozwoliła na wyeliminowanie błędnych danych. W rezultacie, liczba rekordów została zmniejszona do 3818 rekordów (kampanie I–III odpowiednio 1446, 1263, 1109 rekordów).

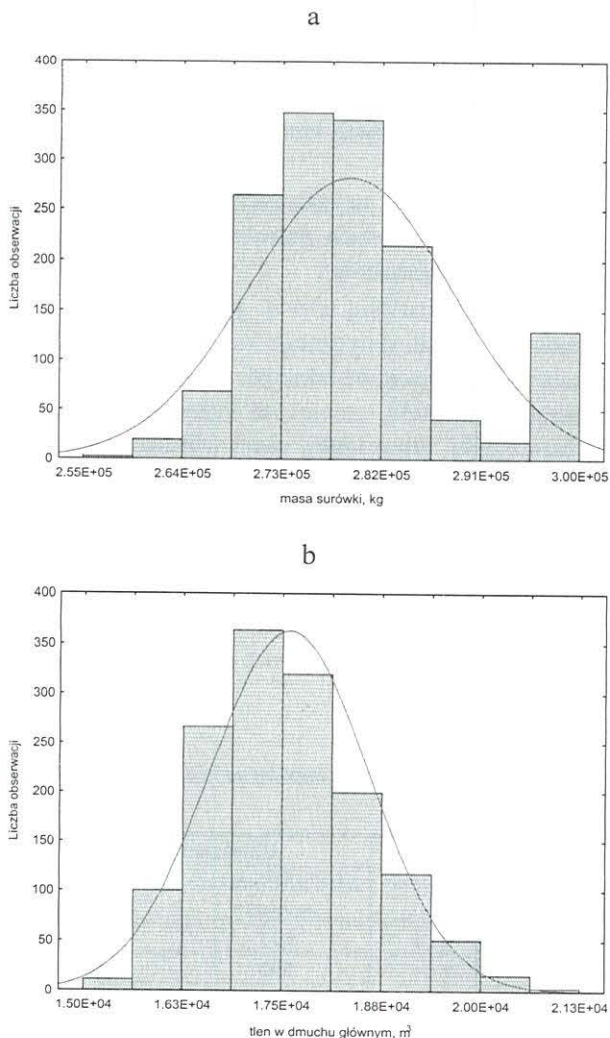
W tabelach 3–5 zamieszczono wartości współczynników równań regresji wielokrotnej (standardowej i krokowej wstecznej) oraz wartość średniego błędu kwadratowego (RMS) temperatury kąpieli metalu oraz objętości tlenu dmuchu głównego otrzymanych dla analizowanych trzech kampanii stalowniczych.

Ze względu na fakt, że zarejestrowane w warunkach przemysłowych dane dla procesu konwertorowego zawierają wiele zmiennych wejściowych o zróż-

nicowanym oddziaływaniu na sygnał wyjściowy, należy dokonać wstępnej analizy pozwalającej na wyeliminowanie zbędnych wielkości. W tym celu należy dla każdej zmiennej niezależnej określić tolerancję $\tau = 1 - K^2$ (K jest współczynnikiem korelacji analizowanej zmiennej ze wszystkimi pozostałymi zmiennymi niezależnymi równania regresji). Jeżeli wartość tolerancji τ dla zadanej zmiennej jest niższa od ustalonej wcześniej wielkości, wówczas rozpatrywana zmienna nie jest brana pod uwagę w równaniu regresji. Im wartość współczynnika korelacji jest większa, a równocześnie tolerancja mniejsza, tym znaczenie danej zmiennej dla obrazu równania regresji jest mniejsze.

Przed rozpoczęciem dalszych obliczeń wskazane jest stworzenie histogramów obrazujących rozkłady liczebności interesujących nas zmiennych (np. zmiennej zależnej). Najlepiej jest wtedy, gdy ów histogram nie różni się znacznie od rozkładu normalnego. Istotne jest również zaobserwowanie macierzy korelacji pomiędzy poszczególnymi zmiennymi, a także ilustrujący te korelacje wykres rozrzutu.

Na rysunku 3 przedstawiono przykładowe histogramy wybranych wielkości wejściowych procesu konwertorowego – masy surówki (rys. 3a) oraz objętości tlenu w dmuchu głównym (rys. 3b) dla kampa-



Rys. 3. Histogramy wybranych wielkości wejściowych procesu konwertorowego wykorzystanych do budowy modelu statycznego: masa surowki (a) i objętość tlenu w dmuchu głównym (b).

nii I. Widać wyraźnie, że rozkład masy surowki odbiega od rozkładu normalnego, co może być przyczyną błędów obliczeń z wykorzystaniem modeli statycznych. Modele oparte o sztuczne sieci neuronowe są mniej wrażliwe na rozkład zmiennych wejściowych.

Analiza wyników uzyskanych metodą regresji standardowej pozwala na wyciągnięcie następujących wniosków:

- najwyższy współczynnik $\beta_i = 0,87$ osiągnęła zmienna określająca zawartość złomu lekkiego we wsadzie,
- wysokie $|\beta_i| > 0,1$ osiągnęły również zmienne dotyczące zawartości złomu ciężkiego oraz objętości tlenu w dmuchu głównym,
- istotne są również temperatura surowki, zawartość złomu walcowniczego, zawartość siarki w surowce oraz masa surowki.

Wymienione powyżej zmienne niezależne okazują się być najlepszymi predyktorami temperatury kąpieli po dmuchu głównym. Analiza regresyjna oparta o metodę krokową wsteczną spowodowała wyeliminowanie

zmiennych, które nie uzyskały wymaganej wartości F_w , co spowodowało zmniejszenie liczby zmiennych wejściowych modelu.

4. SZTUCZNA SIĘĆ NEURONOWA

Sztuczne sieci neuronowe są z dużym powodzeniem coraz częściej stosowane w modelowaniu procesów metalurgicznych. Pierwsze prace Autorów dotyczyły zastosowań sztucznych sieci neuronowych w modelowaniu procesów plastycznej przeróbki metali i modelowania własności metali (Roberts i in., 1998; Roberts i in., 2001; Kusiak i in., 2001; Pietrzyk i in., 2001). Uzyskane interesujące wyniki badań zainspirowały Autorów do dalszych badań nad wykorzystaniem sieci neuronowych w metalurgii, w obszarze procesów stalowniczych. Przykładowe wyniki badań w zakresie sterowania pracą piecokadzi, wielkim piecem oraz procesem próżniowej rafinacji stali typu RH zostały opublikowane w pracy (Falkus i Pietrkiewicz, 2001). W niniejszej pracy podjęto próbę wykorzystania sieci do modelowania procesu konwertorowego. Opracowano dwa modele oparte o sztuczną sieć neuronową. Pierwszy z nich przewiduje temperaturę kąpieli metalu po dmuchu głównym, a zadaniem drugiego jest określenie objętości tlenu dla dmuchu głównego. W procesie uczenia i testowania wykorzystano wcześniej wybrane dla trzech wytypowanych kampanii.

W pracy wykorzystano pakiet Statistica Neural Networks zawierający moduł automatycznego projektanta sieci. Moduł ten pozwala użytkownikowi dokładnie kontrolować proces projektowania, włączając dodatkowo podział zbioru danych na podzbiory: uczący, walidacyjny i testowy; określanie progów dla klasyfikacji oraz wybór typu i struktury sieci.

Wykorzystując moduł automatycznego projektanta sieci podjęto próbę ustalenia istotności parametrów wejściowych, przy których obliczone przez sieć wartości wyjściowe obciążone są jak najmniejszym błędem. Wektor parametrów wejściowych dla trzech kampanii wykorzystanych w procesie uczenia zawierał 20 parametrów (patrz kolumna parametrów wejściowych do sieci neuronowej w Tabelicy 7). Kampania I zawierała w swojej bazie 1446 rekordów (723 uczących, 361 walidacyjnych i 362 testowych), kampania II zawierała 1263 rekordy (632 uczące, 316 walidacyjnych i 315 testowych), a baza kampanii III zawierała 1109 rekordów (555 uczących, 277 walidacyjnych i 277 testowych). W wyniku obliczeń każdorazowo wybranych zostało dziesięć najlepszych sieci o różnej strukturze. Struktura sieci wahała się w granicach od 11 do 19 neuronów w warstwie wejściowej, od 5 do 16 neuronów w warstwie ukrytej oraz jednego wyjścia tj. temperatury kąpieli metalowej po dmuchu głównym lub

objętość tlenu dla dmuchu głównego. Błąd testowy temperatury kąpieli metalowej po dmuchu głównym dla wybranych sieci posiadał wartość w granicach od 26,7°C do 32°C, natomiast błąd testowy dla objętości tlenu w dmuchu głównym wahał się w granicach od 620 Nm³ do 701 Nm³.

Za kryteria pozwalające dokonać wyboru optymalnej struktury sieci dla każdej z kampanii przy zachowaniu prostej struktury i małego błędu dla zbioru testowego, przyjęto analizę wrażliwości sieci. Analiza wrażliwości daje wgląd w użyteczność poszczególnych zmiennych wejściowych. Wskazuje zmienne kluczowe, których nie wolno pomijać oraz zmienne, które mogą być wyeliminowane bez straty jakości sieci.

W oparciu o wyżej wymienione kryteria wybrano najlepsze sieci przewidujące temperaturę kąpieli metalowej po dmuchu podstawowym oraz objętość tlenu dmuchu głównego. Struktury sieci oraz błędy przewidywania wielkości wyjściowych zamieszczono w Tabeli 6.

Najniższą wartość błędu przewidywania temperatury oraz objętości tlenu w dmuchu głównym uzyskano dla kampanii III. Wektor parametrów wejściowych sieci dla poszczególnych kampanii przedstawiono w Tabeli 7.

Analiza wyników uzyskanych za pomocą sztucznych sieci neuronowych pozwala na wyciągnięcie następujących wniosków:

- sieć z jedną warstwą ukrytą jest wystarczająca do budowy modelu statycznego konwertora tlenowego,
- parametry wejściowe takie jak: masa surówki, temperatura surówki, zawartość krzemu w surówce, złom ciężki, złom lekki, złom wlewnicowy, złom W15, złom surówkowy, ruda, koks, tlen w dmuchu głównym oraz temperatura po dmuchu głównym zawierają najwięcej informacji wykorzystanej w procesie uczenia,
- wielkość błędu RMS jest dla modeli opartych o sieci porównywalna z błędami z metody regresyjnej.

Tabela 6. Struktury sieci neuronowych oraz błędy przewidywania temperatury i objętości tlenu w dmuchu głównym poszczególnych kampanii.

Lp.	Typ sieci	Struktura sieci	Temperatura, °C		Struktura sieci	Objętość tlenu, Nm ³	
			Błąd RMS zbioru uczącego	Błąd RMS zbioru testowego		Błąd RMS zbioru uczącego	Błąd RMS zbioru testowego
Kampania I	MLP	14 : 8 : 1	27,4	26,9	15 : 8 : 1	623	686
Kampania II	MLP	13 : 9 : 1	24,1	29,9	17 : 9 : 1	592	661
Kampania III	MLP	18 : 11 : 1	24,8	26,7	16 : 10 : 1	590	629

Tabela 7. Wektor parametrów wejściowych dla sieci neuronowych z podziałem na kampanie.


Nazwa zmiennej	Temperatura na wyjściu z sieci			Ilość tlenu w dmuchu głównym na wyjściu z sieci		
	Kamp. I	Kamp. II	Kamp. III	Kamp. I	Kamp. II	Kamp. III
numer wytopu	X		X	X	X	
masa surówki, kg	X	X	X	X	X	X
temperatura surówki, °C	X	X	X	X	X	X
zawartość C w surówce, %			X		X	X
zawartość Mn w surówce, %	X		X	X	X	X
zawartość Si w surówce, %	X	X	X	X	X	X
zawartość P w surówce, %	X	X	X		X	X
zawartość S w surówce, %		X	X			
masa ciężkiego złomu, kg	X	X	X	X	X	X
masa lekkiego złomu, kg	X	X	X	X	X	X
masa złomu walcowniczego, kg	X	X	X	X	X	X
masa złomu W15, kg	X	X	X	X	X	X
masa złomu surówkowego, kg	X		X	X	X	X
masa złomu z niedolewu płynnego, kg			X	X		
wapno, kg		X		X	X	X
dolomit, kg					X	X
Kamień dolomitowy, kg			X			X
ruda, kg	X	X	X	X	X	
koks, kg	X	X	X	X	X	X
tlen w dmuchu głównym, Nm ³	X	X	X			
temperatura po dmuchu głównym, °C				X	X	X

5. ANALIZA WYNIKÓW I PODSUMOWANIE


Rysunki 4 i 5 przedstawiają porównanie wyników błędów przewidywania temperatury oraz objętości tlenu w dmuchu głównym dla kampanii III. Z rysunku 4 można ustalić jaki procent wytopów, dla których przeprowadzono symulację temperatury po dmuchu głównym, osiąga założoną dokładność obliczeń modelowych. Dla przykładu dokładność na poziomie $\pm 10^{\circ}\text{C}$

osiąga 35% przypadków z wykorzystaniem modelu opartego o sieci neuronowe, 31% przypadków dla modelu regresyjnego oraz 10% przypadków dla modelu bilansowego. Podobnie należy interpretować rys. 5 w odniesieniu do ilości zapotrzebowania na tlen w dmuchu głównym.

W przypadku modeli opartych o bilans masy i energii liczba koniecznych do wykorzystania danych jest większa i prawdopodobnie niektóre z nich, będąc obciążone większymi błędami, generują duży błąd wyni-



Rys. 4. Porównanie modeli symulacji temperatury kąpielii metalowej dla kampanii III.



Rys. 5. Porównanie modeli symulacji zapotrzebowania tlenu dmuchu głównego dla kampanii III.

ku końcowego. Konsekwencją jest fakt, że model oparty o bilans materiałowo-ciepłny bardzo odbiega jakością od dwóch pozostałych. Sytuacja ta sugeruje, że jakość dostępnych do obliczeń danych przemysłowych powinna w przyszłości ulec znacznej poprawie. Dodatkowo, modele oparte o bilans masy i energii nie uwzględniają zmienności wielu niemierzalnych parametrów procesu przyjmując ich wartość na poziomie stałym. Dotyczy to np. takich wielkości jak straty metalu z wyrzutami i pyłami, wielkość strat ciepłych na promieniowanie, skład chemiczny złomu itp.

Powyższą tezę potwierdza porównanie średniego błędu kwadratowego wszystkich analizowanych przypadków. Dla modelu opartego o bilans materiałowo-ciepłny średni błąd kwadratowy waha się odpowiednio dla temperatury od 91 do 101°C, a dla objętości tlenu od 1104 do 1252 Nm³. Wartość tych błędów praktycznie dyskwalifikuje prognozy uzyskane z pomocą modeli bilansowych. W przeciwieństwie do nich zarówno modele regresyjne jak i modele oparte o sztuczne sieci neuronowe posiadają znacznie wyższą zdolność przewidywania szukanych wielkości. Średni błąd kwadratowy dla temperatury jest niższy o około 70°C, a dla objętości tlenu o 500 Nm³. Tak duże zmniejszenie wartości obu błędów nie zapewnia jednak jeszcze zadowalającej dokładności predykcji tych modeli.

Wyniki wszystkich trzech analizowanych typów modeli wskazują, że dokładność predykcji temperatury i zapotrzebowania na tlen są jeszcze mało zadowalające.

Pełna ocena porównawcza modelu regresyjnego i modelu opartego o sztuczne sieci neuronowe możliwa będzie po uzyskaniu danych przemysłowych o istotnie poprawionej wiarygodności. Przeprowadzone badania stanowią jednak podstawę do stworzenia sieci neuronowych o uniwersalnej strukturze do statycznej symulacji procesu konwertorowego.

UWAGA KOŃCOWA

Praca finansowana przez Komitet Badań Naukowy, projekt Nr 7T08B 06220.

LITERATURA

- Chen J., 2001, A predictive system for blast furnace by integrating a neural network with qualitative analysis. *Eng. Appl. of Artificial Intelligence*, 14, 77-85.
- Falkus J., Pietrkiewicz P., 2001, Neural networks in statical controlling of oxygen converter process. *Proc. Conf. "High Technologies in Advanced Metal Science and Engineering"*. St. Petersburg, Russia.
- Kusiak J., Sviatlichnyj D., Pietrzyk M., 2001, Application of Artificial Neural Networks in the On-Line Control of Hot-Flat Rolling Processes. *Int. J. Engineering Simulation*, 1, 3, 17-23.
- Kuziak R., Zalecki W., Kusiak J., 2001, Zastosowanie sieci neuronowych do oceny wpływu pierwiastków domieszkowych na własności mechaniczne wyrobów stalowych. *Informatyka w Technologii Materiałów*, 1, 44-51.
- Krucziński M., Falkus J., 1988, Materiały do ćwiczeń audytoryjnych i projektowych z metalurgii stali. Skrypt 1140 AGH, Kraków.
- Pietrzyk M., Kusiak J., Roberts S.M., 2001, A history dependent constitutive model for the hot forming of Waspaloy. *Proc. Conf. ECCM-2001*, Kraków, CD-ROM.
- Roberts S.M., Kusiak J., Liu Y.L., Forcellese, A., Withers, P.J., 1998, Prediction of damage evolution in forged aluminium metal matrix composites using a neural network approach, *J. Materials Processing and Technology*, 80-81, 507-512.
- Roberts S.M., Kusiak J., 2001, The application of artificial intelligence to the constitutive and microstructural behaviour of nickel-base superalloys. *Proc. Conf. ESAFORM2001*, Liege, 441-444.

Artykuł otrzymano 20 czerwca 2002 r.