

MODELOWANIE I STEROWANIE TLENOWYM PROCESEM KONWERTOROWYM

M. DŁUGOSZ, W. MITKOWSKI, W. PIETRZYK

MODELLING AND CONTROL OF STEELMAKING CONVERTER PROCESS

Abstract

The static model of steelmaking oxygen converter process, based on the artificial neural network approach, is presented in the paper. Remarks about the dynamic models and control of the process are presented, as well. The models were tested on the real industrial data measured in one of the Polish steel plants.

1. WPROWADZENIE


Tlenowy proces konwertorowy jest jednym z podstawowych procesów metalurgicznych. Obecnie około 80% stali na świecie uzyskuje się w procesie konwertorowym. Jakość stali oraz jej parametry fizyczne zależą od temperatury spustu surówki oraz ilości dostarczonego tlenu. Opracowanie dokładnych modeli matematycznych pozwoliłoby na określenie temperatury spustu surówki oraz na określenie zapotrzebowania na tlen podczas dmuchu. Posiadając takie dane można tak dobrać zarówno wsad jak i ilość tlenu, aby otrzymać stal o z góry założonych parametrach fizycznych. Zazwyczaj modele tworzy się w oparciu o odpowiednio dokładne bilanse materiałowe i cieplne (Mamro i Mazanek 1968, s. 212, 171; Kruciński 1986, s. 105 i dalej; Kruciński i Falkus 1988, s. 50 i dalej). Natomiast algorytm sterowania praktycznie sprowadza się do dokładnego określenia momentu przerwania dmuchu. Rysunek 1 przedstawia przykładową budowę pieca konwertorowego.

W pierwszej części pracy podjęto próbę zamodelowania konwertora tlenowego za pomocą sztucznych sieci neuronowych. Zaproponowano dwa typy sieci neuronowych o różnych architekturach, które dla tych samych danych wejściowych generują podobny błąd wyjściowy. Jest to najmniejszy błąd jaki otrzymano w wyniku przeprowadzonych eksperymentów. Proponowane sieci neuronowe przetestowano pod kątem wrażliwości na zmianę parametrów wejściowych. Podjęto także próbę zredukowania rozmiaru wektora wejściowego i opracowania modelu konwertora tlenowego dla tak zmodyfikowanych danych.

W dalszej części pracy omówiono dynamikę procesu i możliwości sterowania. W szczególności podano algorytm sterowania wykorzystujący znajomość składu gazów odlotowych nad gardzielą konwertora.

2. NEURONOWY MODEL STATYCZNY

Zazwyczaj stosuje się dwa modele statyczne procesu konwertorowego o następującej postaci:



Rysunek 1. Schemat konwertora tlenowego.

$$y_1 = F_1(u_1), \quad y_2 = F_2(u_2), \quad u_i \in R^n \quad (1)$$

Modele (1) pozwalają na przewidywanie temperatury y_1 kąpieli metalu oraz ilości tlenu y_2 w dmuchu głównym w danym wytopie na podstawie znajomości takich wielkości wejściowych $u_i \in R^n$ (Falkus, Pietrzekiewicz, Pietrzyk i Kusiak 2002) jak masa i temperatura ciekłej surówki, masa i rodzaj złomu, masa rudy, itp. Modele (1) otrzymuje się zwykle z odpowiednich bilansów cieplnych i materiałowych (Mamro i Mazanek 1968, s. 161–196; Kruciński 1986, s. 175). W zależności (1) zestawy parametrów wejściowych są różne i dlatego oznaczono je symbolem u_1 i u_2 .


Do zamodelowania zależności (1) wykorzystano sztuczne sieci neuronowe. Do konstruowania, uczenia i symulacji działania sieci użyto pakietu MATLAB wersja 6.0 wraz z toolbox-em *Neural Network* wersja 4.0.

2.1. Sieć wielowarstwowa liniowa

Pierwsza z proponowanych sieci neuronowych jest to sieć wielowarstwowa liniowa. Rysunek 2 przedstawia budowę takiej sieci neuronowej.

Na rysunku 2 przyjęto następujące oznaczenia:

- x_1, \dots, x_n – składowe wektora wejściowego
- w_{ij} – waga przez którą jest mnożone j -te wejście w i -tej warstwie



Rysunek 2. Model sieci neuronowej wielowarstwowej liniowej.

- b_j – przesunięcie funkcji aktywacji j -tej warstwy


- y – wyjście sieci

Sieć składa się z 3 warstw, liczba neuronów w poszczególnych warstwach wynosi (w skrócie sieć wielowarstwowa liniowa o strukturze 1:1:1):


- wejściowa – 1 neuron (wielowejsiowy)
- ukryta – 1 neuron
- wyjściowa – 1 neuron

Funkcje aktywacji f_1, f_2, f_3 są funkcjami liniowymi. Rysunek 3 przedstawia kształt funkcji liniowej.

Z przeprowadzonych eksperymentów wynika, że jest to wystarczająca struktura do wstępnego modelowania konwertora tlenowego. W porównaniu z przedstawioną strukturą w pracy (Falkus, Pietrzekiewicz, Pietrzyk i Kusiak 2002) gdzie między innymi stosowano sieci wielowarstwowe liniowe o strukturze 14:9:1, rozważana tu struktura jest prostsza w tym znaczeniu, że zawiera w warstwie ukrytej jedynie jeden neuron, a w przypadku dalej rozważanym jedynie dwie warstwy. Dalsze zwiększanie warstw czy też liczby neuronów w warstwach nie prowadzi do poprawy wyników (błąd uczenia sieci nie ulega znacznej poprawie). Dodatkowo zbytnio rozbudowana sieć neuronowa uczy się znacznie dłużej, a czasem może nawet gorzej modelować obiekt (większy błąd uczenia).



Rysunek 3. Kształt funkcji liniowej, n – wejście funkcji, a – wyjście funkcji.



Rysunek 5. Kształt funkcji tangens hiperboliczny, n – wejście funkcji, a – wyjście funkcji.


2.2. Sieć nieliniowa

Drugą z proponowanych sieci jest sieć nieliniowa. Rysunek 4 przedstawia blokowy schemat użytej nieliniowej sieci neuronowej.

Na rysunku 4 przyjęto następujące oznaczenia:

- x_1, \dots, x_n – składowe wektora wejściowego
- w_{ij} – waga przez którą jest mnożone j -te wejście w i -tej warstwie
- b_j – przesunięcie funkcji aktywacji j -tej warstwy
- y – wyjście sieci

Sieć składa się z dwóch warstw, a liczba neuronów w poszczególnych warstwach wynosi:



Rysunek 4. Model nieliniowej sieci neuronowej.

- wejściowa – 1 neuron (wielowejściowy)
 - wyjściowa – 1 neuron
- Funkcje aktywacji f_1 i f_2 są różne:
- f_1 – funkcja tangens hiperboliczny
 - f_2 – funkcja liniowa

Rysunek 5 przedstawia kształt funkcji tangens hiperboliczny.

Z przeprowadzonej symulacji komputerowych wynika, że taka sieć nieliniowa modeluje temperaturę wyjściową surówki równie dobrze, jak poprzednia sieć wielowarstwowa liniowa (zob. (1)). Niestety tak zbudowana sieć nie za dobrze modeluje zapotrzebowanie na tlen konwertora tlenowego. W celu polepszenia parametrów modelowania zapotrzebowania na tlen sieci nieliniowej zwiększono liczbę neuronów wejściowych z 1 do 13. Tak zbudowana sieć neuronowa dużo lepiej modeluje zapotrzebowanie na tlen konwertora (mniejszy błąd uczenia sieci).

3. DANE POMIAROWE

Zarówno do uczenia jak i do późniejszego symulowania działania sieci potrzebne są dane. Dane wykorzystane w artykule pochodzą z jednej z hut polskich. W sumie dostępne były dane z 6 kampanii. Kampania, to ciąg wytopów przy jednym wyłożeniu wnętrza konwertora. Wykorzystano dane z dwóch kampanii, przy czym jednym zestawem danych uczono sieć (kampania 1), natomiast drugi zestaw danych (kampania 2) służył do sprawdzenia poprawności działania sieci.

Początkowy rozmiar wektora wejściowego (zobacz (1)) wynosił $n = 21$. Dane wejściowe poddano odpowiedniej obróbce. Początkowy rozmiar wektora wejściowego zredukowano do $n = 13$ parametrów. W tabeli 1 zamieszczono opis poszczególnych składowych wektora wejściowego.

Ostatnim parametrem wejściowym jest ilość tlenu w dmuchu lub temperatura surówki po zakończeniu dmuchu. Zależy to od wyjścia sieci. Jeśli modelujemy temperaturę wyjściową, to wtedy ostatnim parametrem wejściowym jest ilość tlenu w $[m^3]$. Jeśli wyjściem z sieci jest ilość tlenu, to wtedy ostatnim parametrem jest temperatura po zakończeniu dmuchu. Odrzucono pomiary niekompletne oraz dodatkowo odrzucono wszystkie pomiary z tych wytopów, które zawierały więcej niż jeden dmuch. Dodatkowe dodmuchy są wykonywane wtedy, gdy okaże się że po dmuchu głównym temperatura surówki lub jej skład chemiczny są nieod-

Tabela 1. Składowe wejściowe.

Lp.	Nazwa	Jednostka
1.	Masa surówki	[kg]
2.	Temperatura surówki	[°C]
3.	Zawartość węgla (C) w surówce	[%]
4.	Zawartość manganu (Mn) w surówce	[%]
5.	Zawartość krzemu (Si) w surówce	[%]
6.	Zawartość fosforu (P) w surówce	[%]
7.	Zawartość siarki (S) w surówce	[%]
8.	Złom ciężki	[kg]
9.	Złom lekki	[kg]
10.	Wapno (Ca)	[kg]
11.	Dolomit	[kg]
12.	Koks	[kg]

powiednie. Można więc przyjąć, że wytopy z dodatkowymi dmuchami są w pewnym sensie „złymi wytopami”, to znaczy takim, które mają źle dobrane parametry wejściowe. Ponieważ do nauki sieci neuronowych należy wykorzystywać dane, które prawidłowo opisują proces, takie błędne dane należy odrzucić. W wyniku tak przeprowadzonej selekcji ostateczna liczba serii pomiarów z pierwszej kampanii wynosi 936, a z drugiej: 679. Serię pomiarów stanowią pomiary z jednego wytopu.

4. UCZENIE SIECI I WYNIKI SYMULACJI

Podstawowym parametrem oceniającym jakość nauczonej sieci jest średni błąd kwadratowy. Błąd ten dla sieci neuronowych zdefiniowany jest następująco:

$$e = \sqrt{\frac{1}{Q} \sum_{k=1}^Q (y_{zad}(k) - y_{sym}(k))^2} \quad (2)$$

gdzie y_{zad} jest zadaną wartością wyjścia, y_{sym} jest wartością wyjścia z sieci neuronowej, Q jest liczbą próbek.

Mając przygotowane odpowiednie dane oraz struktury sieci można rozpocząć proces nauczania odpowiedniej sieci. Do uczenia sieci wykorzystano algorytm propagacji wstecznej, znajdujący się w odpowiednim pakiecie programowym Matlaba. Proces nauczania polega na minimalizacji błędu (2). Tabela 2 przedstawia wartości błędu (2) dla dwóch rodzajów sieci.

Tabela 2 przedstawia błędy nauczania i testowania sieci. Sieci były uczone danymi zebranymi podczas kampanii 1. Testowanie sieci odbywało się przy wykorzystaniu danych z kampanii 2.

Z wyników przedstawionych w tabeli 2 widać, że obydwie sieci w miarę dobrze modelują proces konwertorowego wytopu stali. W porównaniu z wynikami z pracy Falkus i inni (2002, s. 62), gdzie stosowano sieci o bardziej złożonej strukturze, uzyskano dla temperatury błędy tego samego rzędu, natomiast błędy dmuchu w 3 przypadkach trochę gorsze (około 1,5 razy większa objętość tlenu). Rysunek 6 przedstawia porównanie kilku rzeczywistych losowo wybranych po-

Tabela 2. Błąd nauczania i testowania sieci.

Wejście	Sieć liniowa	Sieć nieliniowa
kampania 1		
Temperatura po dmuchu	25,39 [°C]	25,32 [°C]
Ilość tlenu w dmuchu	898,79 [m ³]	1025,49 [m ³]
kampania 2		
Temperatura po dmuchu	26,78 [°C]	28,00 [°C]
Ilość tlenu w dmuchu	1389,02 [m ³]	1116,42 [m ³]


miarów temperatury z wartościami jakie uzyskano na wyjściu sieci wielowarstwowej liniowej.

Wyniki symulacji zamieszczone na rysunkach 6 i 7 otrzymano dla danych wejściowych z kampanii 1. Na rysunkach 6 i 7 zamieszczono tylko kilka losowo wybranych wyników. Spowodowane było to dużą liczbą danych wejściowych (936), których zamieszczenie na jednym wykresie spowodowałoby, że stałyby się one nieczytelne.


Rysunek 7 przedstawia porównanie kilku rzeczywistych losowo wybranych pomiarów zawartości tlenu z wartościami jakie uzyskano na wyjściu sieci wielowarstwowej liniowej.

5. WRAŻLIWOŚĆ MODELU NEURONOWEGO

Mając zaprojektowane oraz nauczone sieci neuronowe zbadano ich wrażliwość na zmianę poszczególnych parametrów wejściowych. Doświadczenie pole-



Rysunek 6. Wynik symulacji (kolor jaśniejszy) oraz pomiary rzeczywiste (kolor ciemniejszy).



Rysunek 7. Wynik symulacji (kolor jaśniejszy) oraz pomiary rzeczywiste (kolor ciemniejszy).

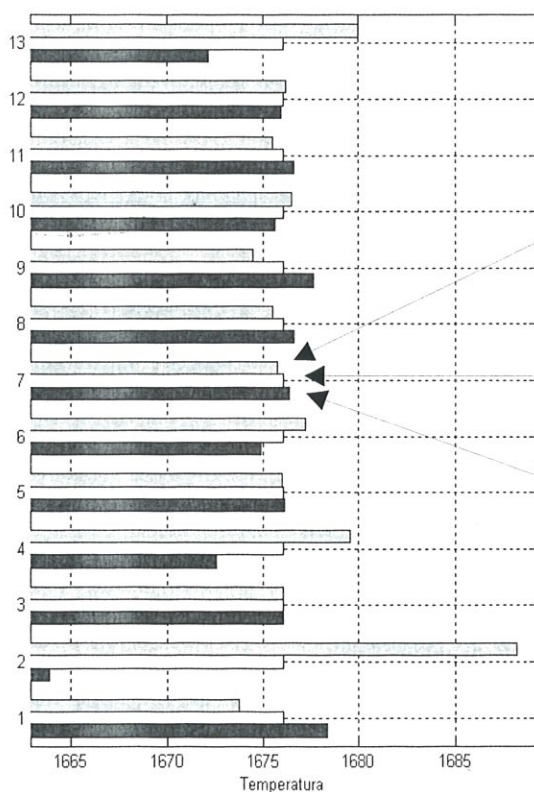
gało na zmianie (zwiększenie i zmniejszenie) wartości poszczególnych składników wejściowych o +5% i -5% wartości podstawowej danego składnika. Kolejno modyfikowano poszczególne składniki wejściowe (np. węgiel, mangan, masę surówki, i tak dalej). Tak przygotowane trzy zestawy danych:

- zestaw 1 – obniżenie zawartości składnika o 5%
 - zestaw 2 – zawartość oryginalna (zmierzona)
 - zestaw 3 – zwiększenie zawartości składnika o 5%,
- zostały kolejno podane na wejścia wcześniej nauczonej sieci neuronowej. Badanie wrażliwości sieci neuronowej odbywała się na danych z kampanii 1. Rysunek 8 przedstawia wykres zmiany temperatury przy zaburzonych danych. Analizując wyniki pokazane na rysunku 8 można zauważyć, że wyjście układu na pewne parametry wejściowe jest stosunkowo mało wrażliwe.

Oś rzędnych wykresu przedstawionego na rysunku 8 reprezentuje poszczególne składowe wektora wejściowego opisane w tabeli 1. Dla przykładu 1 – masa surówki, 2 – temperatura surówki, itd.. Ostatni parametr o numerze 13 reprezentuje ilość tlenu.

Temperatury zamieszczone na rysunku 8 są temperaturami średnimi i wyznaczano je z następującego wzoru:

$$y_{sre} = \frac{1}{Q} \sum_{k=1}^Q y(k) \quad (3)$$



gdzie y jest wartością wyjścia z sieci neuronowej, Q jest liczbą próbek.

Po uzyskaniu odpowiedzi modelu na wszystkie zaburzone próbki wyznaczano średnią temperaturę wyjścia. Tego rodzaju postępowanie wynika z dużej ilości próbek (z pierwszej kampanii 936 próbek, z drugiej: 679). Porównanie wszystkich odpowiedzi modelu, gdy na jego wejście podano zaburzone dane z rzeczywistymi pomiarami jest dość złożone. Dla przykładu na rysunku 9 pokazano wpływ 5% zmian węgla na temperaturę dla próbek z pierwszej kampanii. Na osi pionowej na rysunku 9 umieszczono $y_s - y_{s_{min}}$ oraz $y_{s_{max}} - y_s$, gdzie y_s oznacza wyjście z sieci (temperatura) dla danych nie zaburzonych, $y_{s_{min}}$ wyjście z sieci dla danych zaburzonych pomniejszonych (zmniejszenie wybranego składnika o 5%), $y_{s_{max}}$ wyjście z sieci dla danych zaburzonych powiększonych (zwiększenie wybranego składnika o 5%). Analizując rysunek 9 postanowiono w rozważaniach o wrażliwości wykorzystywać odpowiednie wartości średnie.

Dokładniej, badanie wrażliwości sieci przebiegało według następującego schematu:

1. Wyznaczamy odpowiedzi (temperatury, ilość tlenu) sieci gdy na wejście są podane dane nie zaburzone. W wyniku tego dostajemy wektor z temperaturą (ilością tlenu). Wyliczamy średnią temperaturę (ilość tlenu) na podstawie wzoru (3).
2. Zmniejszamy zawartość wybranego składnika w próbce o 5%. Modyfikujemy tak wszystkie próbki

Średnia temperatura uzyskana z sieci dla danych w których zawartość jednego ze składników zwiększono o 5% w stosunku do wartości oryginalnej (pomiaru)

Średnia temperatura uzyskana z sieci dla nie zaburzonych danych wejściowych.

Średnia temperatura uzyskana z sieci dla danych w których zawartość jednego ze składników zmniejszono o 5% w stosunku do wartości oryginalnej (pomiaru)


Rysunek 8. Wrażliwość modelu neuronowego.

w wyniku czego dostajemy zestaw danych zaburzonych (pomniejszonych). Następnie takie dane zaburzone są podawane na wejście sieci i wyznaczamy z odpowiedzi sieci temperaturę albo dmuch. Mając wyznaczone wszystkie odpowiedzi sieci dla tak zaburzonych (pomniejszonych) danych liczymy średnią temperaturę według wzoru (3).


3. Krok 2 jest powtarzany dla wszystkich składowych wektora wejściowego.
4. Kroki 2 i 3 są wykonywane jeszcze raz tylko teraz zamiast zmniejszać zawartość wybranego składnika, zwiększamy go o 5%. Reszta działań pozostaje bez zmian.

Jeśli temperatura faktycznie silnie zależy od zawartości danego składnika, to średnia temperatura będzie

a)



b)



Rysunek 9. Wpływ zmian zawartości węgla na temperaturę, a) zmniejszenie zawartości węgla o 5%, b) zwiększenie zawartości węgla o 5%.

się różniła od temperatury rzeczywistej. Wyznaczanie temperatury średniej ma też tę zaletę, że eliminuje przypadkowe błędy odpowiedzi modelu. Tabela 3 przedstawia różnicę pomiędzy wartościami średniej temperatury dla próbek, których składniki były zwiększane o 5%, a średnią temperaturą dla próbek, których składniki były zmniejszane o 5%.

Analizując dane zawarte w tabeli 3 widać, że obydwa modele sieci (wielowarstwowy liniowy i nieliniowy) są wrażliwe na zmianę zawartości tych samych składników. Istnieje grupa składników na zmianę, których sieć reaguje słabiej, są to np.: węgiel, krzem, siarka, wapno, koks (szare pola w tabeli 3). Również jest grupa składników na zmianę, których sieć reaguje mocniej, np.: mangan, fosfor, złom ciężki, złom lekki, dolomit. To spostrzeżenie wymaga weryfikacji i interpretacji praktycznej.

Taką samą metodą badania wrażliwości sieci neuronowych zastosowano dla modelowania zapotrzebowania na tlen. W tym przypadku nie wyznaczano średniej temperatury tylko średnie zapotrzebowanie na tlen. Tabela 4 przedstawia otrzymane wyniki

Analizując dane zebrane w tabeli 4 widać, że dla dwóch różnych sieci (sieć wielowarstwowa liniowa i sieć nieliniowa) nie można znaleźć wspólnych składników, na które obydwie sieci reagują podobnymi zmianami wyjścia. Być może, w tym przypadku trzeba próbować innej struktury sieci, np. takiej jak w pracy Falkus i inni (2002).

Porównując rysunek 10 z rysunkiem 11, na pierwszy rzut oka można wyciągnąć wniosek, że sieć liniowa charakteryzuje się mniejszymi zmianami wyjścia (zapotrzebowanie na tlen) przy zaburzonych wejściach. Dokładne porównanie wymaga wprowadzenie dodat-

Tabela 3. Wrażliwość sieci neuronowych użytych do modelowania tlenowego procesu konwertorowego na zmianę parametrów wejściowych (wyjście temperatura).

Lp.	składniki	kampania 1		kampania 2	
		sieć liniowa	sieć nieli.	sieć liniowa	sieć nieli.
		[°C]	[°C]	[°C]	[°C]
1.	Masa surówki	4.65	2.88	4.73	1.73
2.	Temperatura surówki	24.40	-23.82	-24.31	-15.18
3.	Węgiel (C)	0.04	-0.36	0.03	-0.21
4.	Manganu (Mn)	-6.94	-6.48	-4.95	-2.82
5.	Krzemu (Si)	0.13	0.16	0.12	0.10
6.	Fosforu (P)	-2.28	-2.91	-2.75	-2.10
7.	Siarki (S)	0.62	0.74	0.65	0.44
8.	Złom ciężki	1.15	1.04	1.26	0.70
9.	Złom lekki	3.22	3.11	2.78	1.52
10.	Wapno (Ca)	-0.89	-0.88	-0.91	-0.56
11.	Dolomit	1.08	1.16	1.19	0.70
12.	Koks	0.30	-0.31	-0.20	-0.15

kowych kryteriów oceny, co może być przedmiotem dalszych badań. Trudno określić, która z sieci jest lepsza do modelowania zapotrzebowania na tlen (zobacz również tabela 2, gdzie podano błąd uczenia sieci). Z jednej strony mniejsze zmiany wyjścia przy zaburzonych wejściach sieci wielowarstwowej liniowej może sugerować, że sieć ta gorzej modeluje zapotrzebowanie na tlen, bo słabiej reaguje na zmiany parametrów wejściowych. Z drugiej strony, jeśli zapotrzebowanie na tlen faktycznie nie zależy do tych składników (nie wiemy dokładnie, od jakich składników zależy) to wtedy sieć nieliniowa wydaje się być gorszą. Możliwe jest też takie rozwiązanie, że obydwie sieci nie są dobre do

Tabela 4. Wrażliwość sieci neuronowych użytych do modelowania tlenowego procesu konwertorowego na zmianę parametrów wejściowych (wyjście ilość tlenu).

Lp.	składniki	kampania 1		kampania 2	
		sieć liniowa [m ³]	sieć nieli. [m ³]	sieć liniowa [m ³]	sieć nieli. [m ³]
1.	Masa surówki	-782.8	-686.9	-796.2	-487.5
2.	Temperatura surówki	373.5	-202.8	372.1	-28.8
3.	Węgiel (C)	204.0	47.3	197.7	-0.5
4.	Manganu (Mn)	301.5	-16.6	215.0	18.3
5.	Krzemu (Si)	2.5	18.9	2.4	-6.1
6.	Fosforu (P)	74.2	192.3	89.4	46.1
7.	Siarki (S)	-15.7	-12.9	-16.5	25.1
8.	Złom ciężki	20.1	43.4	22.0	32.5
9.	Złom lekki	2.2	82.7	1.9	72.9
10.	Wapno (Ca)	-22.7	31.3	-23.3	-26.2
11.	Dolomit	21.5	-50.5	23.6	-98.6
12.	Koks	-61.8	-104.3	-40.0	-23.8

modelowania zapotrzebowania na tlen. Nie ma żadnych reguł, które by podpowiadały, jak należy dobierać struktury sieci. Może się też okazać, że model statyczny nie jest dobry do modelowania zapotrzebowania na tlen.

6. IDENTYFIKACJA

Nauczone wcześniej sieci neuronowe można traktować jako modele statyczne zależności określonych równościami (1). W ten sposób funkcje wewnętrzne sieci neuronowych można uznać za funkcje otrzymane w wyniku procesu identyfikacji zależności (1) na podstawie pomiarów wejściowych u i wyjściowych y .

Rozważmy zależność (1) określającą temperaturę wyjściową y w zależności od u . Dla uproszczenia zapisu poniżej będziemy opuszczać wskaźniki przy wielkościach wejściowych i wyjściowych.

W przypadku sieci liniowej (zob. rysunek 2) funkcja przejścia ma następującą postać:


$$F(\mathbf{u}) = f_3(f_2(f_1(\mathbf{u}))), \quad \mathbf{u} = [u_1 \ u_2 \ \dots \ u_{13}]^T \in R^{13} \quad (4)$$

przy czym funkcje f_i , $i = 1, 2, 3$ są określone w następujący sposób:


$$f_i(\mathbf{u}) = \mathbf{W}_i \mathbf{u} + \mathbf{b}_i \quad \text{dla } i = 1, 2, 3 \quad (5)$$

Po wstawieniu (5) do (4) otrzymujemy

$$F(\mathbf{u}) = \mathbf{W}_3 \mathbf{W}_2 \mathbf{W}_1 \mathbf{u} + \mathbf{W}_3 \mathbf{W}_2 \mathbf{b}_1 + \mathbf{W}_3 \mathbf{b}_2 + \mathbf{b}_3 \quad (6)$$



Rysunek 10. Wrażliwość sieci wielowarstwowej liniowej – wyjście z sieci to zapotrzebowanie na tlen.



Rysunek 11. Wrażliwość sieci nieliniowej – wyjście z sieci to zapotrzebowanie na tlen.

gdzie $\mathbf{u} = [u_1 \quad u_2 \quad \dots \quad u_{13}]^T \in R^{13}$,

$\mathbf{W}_1, \mathbf{W}_2$ i \mathbf{W}_3 są macierzami wagowymi odpowiednich sieci neuronowych. W naszym przypadku dla modelu (6) wymienione macierze wagowe mają następującą postać:

$$\mathbf{W}_1 = [-0,0226314364083296; 23,4468043811514; \\ -9,65285754412926; 32857,530968617; \\ -366,247620779864; 33133,4908281204; \\ -44287,972130745; -0,0498805643096054; \\ -0,0845271425613222; 0,120795934815334; \\ -0,460694068267954; 0,320102392912532; \\ 0,589072294106866]$$

$$\mathbf{b}_1 = [-18,76883907947659], \\ \mathbf{W}_2 = [-0,141871385156692], \\ \mathbf{b}_2 = [-95,4886706142727], \\ \mathbf{W}_3 = [-0,0533322821357122], \\ \mathbf{b}_3 = [1352,85938778094]$$

W przypadku sieci nieliniowej (zob. rysunek 4) funkcja przejścia dana jest następującą równością:

$$F(\mathbf{u}) = f_2(f_1(\mathbf{u})), \quad \mathbf{u} = [u_1 \quad u_2 \quad \dots \quad u_{13}]^T \in R^{13} \quad (7)$$

przy czym f_2 dana jest równością (5) oraz $f_1(\mathbf{u}) = \tanh(\mathbf{W}_1\mathbf{u} + \mathbf{b}_1)$,

$$\tanh(z) = \frac{2}{1 + \exp(-2z)} - 1 \quad (8)$$

Wstawiając (8) do (7) i wykorzystując (5) ostatecznie mamy

$$F(\mathbf{u}) = \mathbf{W}_2 \left(\frac{2}{1 + \exp(-2(\mathbf{W}_1\mathbf{u} + \mathbf{b}_1))} - 1 \right) + \mathbf{b}_2 \quad (9)$$

gdzie

$$\mathbf{W}_1 = [-0,00000568081488; 0,00988493055778; \\ 0,04099989890734; 12,35691538166040; \\ -0,18377516461613; 17,04689621409924; \\ -21,53081135580617; -0,00001790851155; \\ -0,00003357688328; 0,00004795409939; \\ -0,00020085912460; 0,00012552515177; \\ 0,00022132085075]$$

$$\mathbf{b}_1 = [-18,7688390794766], \\ \mathbf{W}_2 = [25,6825410814296], \\ \mathbf{b}_2 = [1682,76534324061].$$

Elementy macierzy wagowych $\mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3$ i elementy \mathbf{b} , otrzymano w wyniku procedury nauczania sieci (standardowy algorytm propagacji wstecznej używany w pakiecie MATLAB). Otrzymane modele statyczne (6) i (9) zostały uzyskane z wyników pomiarów kampanii 1. Niestety cechą charakterystyczną uczenia sieci jest brak powtarzalności, tzn. przy ponownym nauczaniu sieci otrzymamy inne współczynniki modeli (6) i (9). W celu uzyskania uniwersalnych modeli statycznych konieczne są badania dla innych zestawów parametrów wejściowych uzyskane z innych kampanii.

7. DYNAMIKA PROCESU I CELE STEROWANIE

Podstawową zaletą procesu konwertorowego jest jego szybki przebieg (dmuch 15–20 min., całkowity czas z procesami towarzyszącymi 30–50 min.). Krótki czas trwania całego procesu jest równocześnie czynnikiem utrudniającym sterowanie wytopem (Mamro i Mazanek 1968, s. 159; Kruciński 1986, s. 179). Podczas trwania procesu konwertorowego praktycznie nie ma możliwości zmierzenia temperatury kąpieli i jej składu bez przzerwania dmuchu i chwilowego przzerwania procesu. Szybkość utleniania węgla jest bardzo duża, co utrudnia określenie właściwego momentu przzerwania dmuchu w celu uzyskania stali o zadanym składzie.

7.1. Cele sterowania

Najważniejszym celem sterowania wytopem konwertorowym jest otrzymanie produktu, czyli stali o zadanym z góry składzie, temperaturze i ciężarze. Drugi produkt wytopu to żużel, który powinien mieć odpowiedni stopień zasadowości. Cele te można osiągnąć stosując odpowiednie układy automatycznej regulacji.

7.2. Zadania układu regulacji automatycznej

Podstawowym zadaniem układu regulacji jest zatrzymanie dmuchu w odpowiednim momencie (tak, by nie były potrzebne dodatkowe dmuchy bądź inne środki korygowania składu i temperatury kąpieli). Przerwanie dmuchu w czasie wytopu jest dokonywane w następujący sposób:

1. zatrzymanie dmuchu przy zadanych wartościach składu i temperatury określane na podstawie wielkości wejściowych (zob. np. model statyczny (1));
2. zatrzymanie dmuchu po osiągnięciu odpowiedniej zawartości węgla na podstawie obserwacji płomienia nad gardzielą konwertora;
3. zatrzymanie dmuchu po osiągnięciu odpowiedniej

zawartości węgla na podstawie pomiaru składu i ilości gazów konwertorowych;

4. zatrzymanie dmuchu po osiągnięciu odpowiedniej zawartości węgla na podstawie efektów akustycznych.

Dodatkowo należy minimalizować czas trwania wytopu i minimalizować straty żelaza w czasie trwania wytopu. Szybkość reakcji w konwertorze tlenowym zależy (Mamro i Mazanek 1968, s. 49) od sposobu wdmuchiwania tlenu (odległość dyszy od powierzchni kąpeli i szybkość wypływu tlenu z dyszy, 300–500 m/sek.). Większa liczba dysz w konsekwencji zmniejsza straty żelaza i zmniejsza zużycie wyłożenia ogniotrwałego (Kruczyński i Falkus 1988, s. 24).

7.3. Elementy dynamiki procesu konwertorowego

Istnieją pewne możliwości uwzględnienia dynamiki procesu w algorytmach sterowania wytopem. Możliwości te przedstawimy poniżej.

W celu uwzględnienia np. wpływu zużycia wyłożenia konwertora przy wyliczaniu danych w wytopie o numerze k (w danej kampanii, czyli w zbiorze wytopów konwertora z tym samym wyłożeniem ogniotrwałym) wykorzystuje się pewne dane z wytopu poprzedniego, czyli z wytopu o numerze $k - 1$. W ten sposób otrzymujemy dyskretny układ dynamiczny o następującej postaci (Mamro i Mazanek 1968, s. 174):

$$y(k) = f(y(k-1), u(k), u(k-1)), \quad (10)$$

gdzie $k = 0, 1, 2, \dots$, $y(k)$ jest odpowiednim wyjściem (zob. (1)). W tym miejscu warto wspomnieć, że istnieje zależność między zużyciem wyłożenia a stopniem utleniania żużla (Mamro i Mazanek 1968, s. 173). Zawartość żelaza w żużlu w zależności od liczby wytopów jest krzywą z wyraźnym minimum w końcowej fazie kampanii.

W procesie konwertorowym stosunkowo łatwo dostępny do analizy jest płomień nad gardzielą konwertora. Dmuch można zatrzymać po osiągnięciu zadanej zawartości węgla w kąpeli końcowej. Intensywność promieniowania płomienia w czasie jest zależna od szybkości utleniania się węgla w czasie wytopu. Krzywa intensywności promieniowania płomienia nad gardzielą konwertora jest krzywą osiągającą maksimum w czasie 1–1.5 min. przed końcem procesu dmuchania (Mamro i Mazanek 1968, s. 197). Fakt ten próbowano wykorzystać do zatrzymywania dmuchu w procesie konwertorowym. Metoda ta nie jest dokładna i raczej ciągle ma charakter poznawczy. W tym miejscu warto wspomnieć, że w większości przypadków praktycznych moment zakończenia procesu dmuchania jest określony przez pulpitowego na podstawie wyglądu płomienia (Mamro i Mazanek 1968, s. 175)

lub na podstawie efektów akustycznych. W różnych eksperymentach intensywność promieniowania mierzono za pomocą fotokomórki z różnymi filtrami barwnymi lub za pomocą pomiaru stopnia zaczerwienienia z wykorzystaniem odpowiedniego elektrycznego mostka pomiarowego (Mamro i Mazanek 1968, s. 196 i 198).

Bieżącą zawartość węgla w metalu i szybkość jego usuwania z kąpeli metalowej można określić na podstawie znajomości składu i ilości gazów uchodzących z konwertora (Mamro i Mazanek 1968, s. 200). Na podstawie krzywej określającej zawartość CO_2 i CO w gazach konwertorowych w zależności od czasu można określić moment przzerwania dmuchu (Mamro i Mazanek 1968, s. 205–210).

8. ALGORYTM ZATRZYMANIA DMUCHU

Jedną z metod określenia zawartości węgla w kąpeli metalowej jest zbadanie właściwości uchodzących z konwertora gazów (Mamro i Mazanek 1968, s. 200–205). Znając ilość węgla wniesioną do układu, ilość gazów uchodzących z kąpeli oraz zawartość tlenu i dwutlenku węgla w uchodzących gazach można znaleźć masę węgla pozostałego w kąpeli i określić jego zawartość procentową. Metoda ta pozwala zatrzymać dmuch w momencie, gdy uzyskamy odpowiednio niską zawartość węgla w kąpeli.

Wprowadźmy następujące oznaczenia:

$n_g(t)$ – natężenie przepływu gazów konwertorowych w chwili t ,

$m_g(t)$ – ilość spalin konwertorowych po czasie t ,

$CO(t)$ – procentowa zawartość CO w próbie gazu pobranej po czasie t

$CO_2(t)$ – procentowa zawartość CO_2 w próbie gazu pobranej po czasie t

Ilość gazów konwertorowych procesu dmuchania po czasie t możemy otrzymać z następującej równości:

$$m_g(t) = (CO(t) + CO_2(t))n_g(t) \quad (11)$$

Przy spalaniu się jednego grama atomu węgla (masa atomowa węgla wynosi 12) tworzy się 22,4 litrów CO , CO_2 lub mieszaniny obu tych gazów. Szybkość utleniania się węgla możemy wyrazić za pomocą następującego równania różniczkowego:

$$\frac{dC}{dt} = \frac{12}{22,4} m_g(t) \quad (12)$$

Zgodność jednostek w równaniu otrzymamy, jeżeli szybkość utleniania węgla będziemy mierzyć w kg/h , natomiast ilość gazów konwertorowych w m^3/h Niech

$$\text{stała } k_1 = \frac{12}{22,4} \approx 0,536 .$$

Wykorzystując powyższe równości (11) i (12) możemy napisać:

$$\frac{dC}{dt} = k_1(CO(t) + CO_2(t))n_g(t) \quad (13)$$

i dalej po scałkowaniu (13) po czasie t mamy

$$\Delta C = \int_0^t \frac{dC}{dt} dt = \int_0^t k_1(CO(t) + CO_2(t))n_g(t) dt \quad (14)$$

Wprowadźmy kolejne oznaczenia:

g_0 – masa metalu na początku procesu dmuchania
 g_t – masa metalu po czasie t od początku procesu
 C_0 – zawartość węgla w metalu na początku procesu
 C_t – zawartość węgla w metalu po czasie t od początku procesu.

Prawdziwa jest następująca równość:

$$\Delta C = \frac{g_0 C_0 - g_t C_t}{100} \quad (15)$$

Zatem

$$C_t = \frac{1}{g_t} (g_0 C_0 - 100 \cdot \Delta C) \quad (16)$$

$$C_t = \frac{1}{g_t} \left[g_0 C_0 - k_2 \int_0^t (CO(t) + CO_2(t))n_g(t) dt \right]$$

gdzie $k_2 = 100k_1$

W najprostszym przypadku, gdy nie weźmiemy pod uwagę zmiany masy metalu podczas wytopu wzór (16) przyjmie następującą postać:

$$C_t = C_0 - \frac{k_2}{g_0} \int_0^t (CO(t) + CO_2(t)) \cdot n_g(t) dt \quad (17)$$

W tym przypadku, w celu określenia bieżącej zawartości węgla w kąpieli, wystarczy znać następujące parametry procesu:

- zawartość węgla w surówce C_0
- ilość surówki wlanej do konwertora g_0
- zawartość $CO(t)$ i $CO_2(t)$ w próbce gazów konwertorowych pobranej w chwili t
- natężenie przepływu gazów konwertorowych $n_g(t)$

Rozważmy teraz następujący problem. Chcemy skonstruować algorytm, który pozwoli nam wyznaczyć czas po którym należy wyłączyć dmuch w celu uzyskania odpowiedniej procentowej zawartości węgla w stali. Problem polega na tym, że pomiary zawartości CO oraz CO_2 w gazach konwertorowych nie są dokonywane w sposób ciągły. Dlatego wyliczony przez nas wzór całkowity (17) nie może zostać bezpośrednio wykorzystany.

PRZYKŁAD 1.

Na podstawie badanych próbek gazów konwertorowych możemy wyznaczyć funkcję regresji liniowej:

$CO(t) + CO_2(t) = at + b$. Po wstawieniu ostatniego wyrażenia do (17) po scałkowaniu i wykonaniu elementarnych obliczeń otrzymujemy chwilę czasu t , w której należy zatrzymać dmuch

$$t = 2 \left(\sqrt{b^2 + \frac{2a(C_0 - C_T)g_0}{k_2 n_g}} - b \right) \quad (18)$$

PRZYKŁAD 2.

Założmy, że pomiary $CO(t)$ i $CO_2(t)$ są wykonywane w dyskretnych chwilach czasu $t = t_i$, $i = 0, 1, \dots, m$. Wykonując całkowanie numeryczne, np. metodą trapezów, z równości (17) otrzymamy

$$\sum_{i=0}^{m-1} (n_g(t_i) \cdot (CO(t_i) + CO_2(t_i)) + n_g(t_{i+1}) \cdot (CO(t_{i+1}) + CO_2(t_{i+1}))) = 2 \frac{(C_0 - C_m)g_0}{Tk_2}, \quad (19)$$

$$T = t_{i+1} - t_i, \quad i = 0, 1, \dots, m-1$$

Przy zadanej zawartości węgla C_m w końcowej chwili procesu konwertorowego oraz przy zadanym kroku próbkowania T (odstęp czasowy pomiędzy pomiarami składu gazów konwertorowych) dmuch należy przerwać w chwili czasu $t = mT$. Parametr m uzyskujemy z równości (19) przy jej spełnieniu (suma z lewej strony będzie równa wyrażeniu z prawej strony). Zwiększenie dokładności można uzyskać dokonując całkowania ze zmiennym krokiem czasowym

$$T_i = t_{i+1} - t_i.$$

PRZYKŁAD 3.

Założmy, że mamy do czynienia z pewnym procesem konwertorowym (wykorzystano dane z pewnej huty polskiej). Naszym celem jest osiągnięcie bardzo niskiej zawartości węgla w stali, wynoszącej 0,1% ($C_m = 0,1$). Znamy dane dotyczące procentowej zawartości CO oraz CO_2 . Znamy również natężenia przepływu gazów konwertorowych. Wszystkie próbki pobierane były z procesu w odstępach dwusekundowych ($T = 2$ sek.). Znamy też następujące parametry proce-

su: $C_0 = 4,9$ oraz $g_0 = 280000$ kg. Na podstawie otrzymanych danych wyliczone zostało, że oczekiwana zawartość węgla zostanie osiągnięta po 966 sekundach czyli po 16 minutach i 6 sekundach. Przyjmując $m = 483$ otrzymamy:

$$S = \sum_{i=0}^{483} (n_g(t_i) \cdot (CO(t_i) + CO_2(t_i)) + n_g(t_{i+1}) \cdot (CO(t_{i+1}) + CO_2(t_{i+1}))) = 25082,42 \quad (20)$$

oraz następnie

$$C_{483} = C_0 - \frac{T \cdot k_2 \cdot S}{2g_0} = 4,9 - \frac{2 \cdot 53,6 \cdot 25082,42}{2 \cdot 280000} \approx 4,9 - 4,8 = 0,1 \quad (21)$$

W takiej sytuacji należałoby więc zatrzymać dmuch po 16 minutach i 6 sekundach trwania procesu.

9. UWAGI KOŃCOWE

W pracy podjęto próbę zamodelowania procesu konwertorowego wytopu stali za pomocą dwóch sieci neuronowych o różnych architekturach. W wyniku eksperymentów numerycznych uzyskano dwie sieci, które w miarę dobrze modelują dane wyjściowe. Tak uzyskane modele neuronowe przebadano pod kątem ich wrażliwości na zaburzenie parametrów wejściowych. Analizując Rysunek 8 można dojść do wniosku, że są składniki wektora wejściowego, na których zmianę sieć reaguje większymi zmianami temperatury na wyjściu. Są także składniki, których zmiana nie powoduje większych zmian wyjścia sieci, np.: węgiel, krzem, siarka, wapno, koks. Podane w pracy architektury dwóch sieci są tylko propozycjami, ponieważ nie ma żadnych reguł, które mówią, w jaki sposób należy konstruować takie sieci. Architektury sieci przedstawione w artykule zostały wybrane na podstawie przeprowadzonych doświadczeń numerycznych, w których jako kryterium jakości przyjęto wskaźnik oceny błędu uczenia sieci (2).

W rozdziale 8 zaproponowano pewien algorytm sterowania, w którym na podstawie pomiarów składu gazów konwertorowych określa się moment przzerwania dmuchu. W przykładzie 3 dokonano obliczeń numerycznych na podstawie danych praktycznych, uzyskując moment przzerwania dmuchu porównywalny ze stosowanym w procesie realnym.

Na zakończenie jeszcze jedna uwaga. Kąpiel metalowa jest mieszana strugą tlenu wypływającą z dyszy. Można rozważyć mieszanie mieszadłem magnetycznym (Kamiński 1994, s. 145). Pole magnetyczne wnika tylko w niewielką warstwę ciekłego metalu. Jeżeli war-

stwa ta jest zbyt cienka, to nie można wywołać efektywnej turbulencji w całej objętości ciekłego metalu. Głębokość wnikania pola elektromagnetycznego przy $f = 50$ Hz dla stali wynosi ok. 0,08 m. Dla polepszenia wnikania należy stosować pole wolnozmiennne zgodnie z zależnością (Kamiński 1994, s. 146)

$$\delta = \sqrt{\frac{2}{\omega \mu \gamma}} \quad (22)$$

przy czym:

δ – głębokość wnikania, ω – pulsacja, μ – przenikalność magnetyczna, γ – przewodność ciekłego metalu. W zastosowaniach przemysłowych do mieszania ciekłego metalu stosuje się zasilanie z częstotliwością $f = 0,4-5$ Hz.

Z punktu widzenia poznawczego, związanego z procesem konwertorowym, interesująca jest również dynamika płomienia (spalania), zob. np. (Friedly 1975, s. 178, 324, 489).

Obliczenia numeryczne wykonano wykorzystując pakiet programowy Matlab (zob. np. Zalewski i Cegiela 1997, Kasprzyk i inni 2002, s. 23-38).

Uwaga końcowa: Praca finansowana przez KBN, częściowo w ramach projektu nr 7T08B06220 oraz częściowo w ramach projektu AGH 1111120230.

LITERATURA

- Demuth, H., Beale, M., 2002, *Neural Network Toolbox*.
 Falkus, J., Pietrzkiwicz, P., Pietrzyk, W., Kusiak, J., 2002, Statyczny model konwertora tlenowego oparty o sztuczną sieć neuronową, *Infomatyka w technologii materiałów*, t. 2, nr 2-3, 55-64.
 Friedly, J.C., 1975, *Analiza dynamiki procesów*, WNT, Warszawa.
 Kamiński, G., 1994, *Silniki elektryczne o ruchu złożonym*, Oficyna Wydawnicza Pol. Warszawskiej, Warszawa.
 Kasprzyk, J. (red.), 2002, *Identyfikacja procesów*, Wyd. Pol. Śląskiej, Gliwice.
 Korbicz, J., Obuchowicz, A., Uciński, D., 1994, *Sztuczne sieci neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa.
 Kruciński, M., 1986, *Metalurgia stali, Tom I, cz. II, Tlenowy proces konwertorowy*, Wyd. 2 uzupeł., skrypt nr 1083 AGH, Kraków.
 Kruciński, M., Falkus, J., 1988, *Materiały do ćwiczeń audytoryjnych i projektowych z metalurgii stali*, Skrypt nr 1140 AGH, Kraków.
 Mamro, K., Mazanek, T., 1968, *Tlenowy proces konwertorowy*, PWN, Warszawa.
 Mitkowski, W., Długosz, M., 2003, Uwagi o modelowaniu tlenowego procesu konwertorowego, *Mat. Konf. KomPlasTech 2003*, ed. Grosman, F., Piela, A., Kusiak, J., Pietrzyk, M., Wisła-Jawornik, 41-46.
 Tadeusiewicz, R., 1993, *Sieci Neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa.
 Zalewski, A., Cegiela, R., 1997, *Matlab, obliczenia numeryczne i ich zastosowania*, Wyd. Nakom, Poznań.

Artykuł otrzymano 30 kwietnia 2003 r.