

Tadeusz WIECZOREK, Paweł ŚWITAŁA
Politechnika Śląska, Katedra Zarządzania i Informatyki

SYSTEM PREDYKCJI DODATKÓW STOPOWYCH W PROCESIE STALOWNICZYM

Streszczenie. Najważniejszym etapem produkcji stali w procesie elektrostalowniczym jest uzyskanie odpowiedniego składu chemicznego. Przez wprowadzanie odpowiednich dodatków stopowych. Zarówno dobór poszczególnych dodatków, jak i ich masa w praktyce obliczana jest na podstawie teorii równowagowych procesów chemicznych oraz doświadczenia operatora prowadzącego dany proces produkcyjny. Dokładność takich obliczeń nie jest wysoka, natomiast koszt wielu dodatków stopowych jest duży. Dlatego w świecie pracuje się nad systemami ekspertowymi pozwalającymi na precyzyjniejszą predykcję ilości potrzebnych dodatków. W pracy przedstawiono opracowany przez autorów system predykcyjny bazujący na sztucznych sieciach neuronowych, algorytmach wektorów wspierających (SVM) oraz regresji liniowej wielu zmiennych. System ten, składający się z czterech modułów, wdrożono w jednej z hut krajowych. Zaimplementowany został jako aplikacja sieciowa w technologii .NET. Do wyznaczenia optymalnych parametrów modułu SVM oraz regresji liniowej wykorzystano system Statistica, natomiast architekturę sieci neuronowych dobrano wykorzystując własne oprogramowanie. Przedstawiono wyniki eksperymentów przeprowadzonych w rzeczywistych warunkach przemysłowych.

Słowa kluczowe: obróbka pozapiecowa stali, sieci neuronowe, inteligencja obliczeniowa, SVM, prognozowanie

ALLOY ADDITIVES PREDICTION SYSTEM FOR STEELMAKING PROCESS

Summary. For adjustments of steel composition alloy additions are added to the ladle furnace for obtaining the grade of steel being manufactured. The prediction of steel composition is a crucial factor of secondary metallurgy. Calculations usually are made basing on the equilibrate chemical processes in molten steel. In the paper the problem of prediction of alloy additions has been solved using Artificial Neural Nets and the SVM algorithm. Review of applications of computational intelligence in secondary steelmaking has been made. The prediction system used by authors has been

introduced. Details of the neural network prediction and other approaches to the prediction problem, i.e. Support Vector Regression Module and Multivariate Linear Regression have been introduced. Experimental results and the final conclusions and recommendations have been presented.

Keywords: secondary steelmaking, neural networks, computational intelligence, SVM, prediction

1. Wstęp

Badany proces elektrostalowniczy składa się z 4 głównych etapów. Rozpoczyna się na hali wsadowej, na której przygotowywany jest wsad do pieca łukowego. W kolejnym etapie wsad topi się w elektrycznym piecu łukowym, po czym następuje spust stali do kadzi głównej. Następnie stal podlega rafinacji i uzyskuje odpowiednią temperaturę odlewania w piecu kadziowym. Za pomocą suwnicy zostaje przetransportowana na stanowisko do ciągłego odlewania, gdzie odlewane są gotowe wlewki.

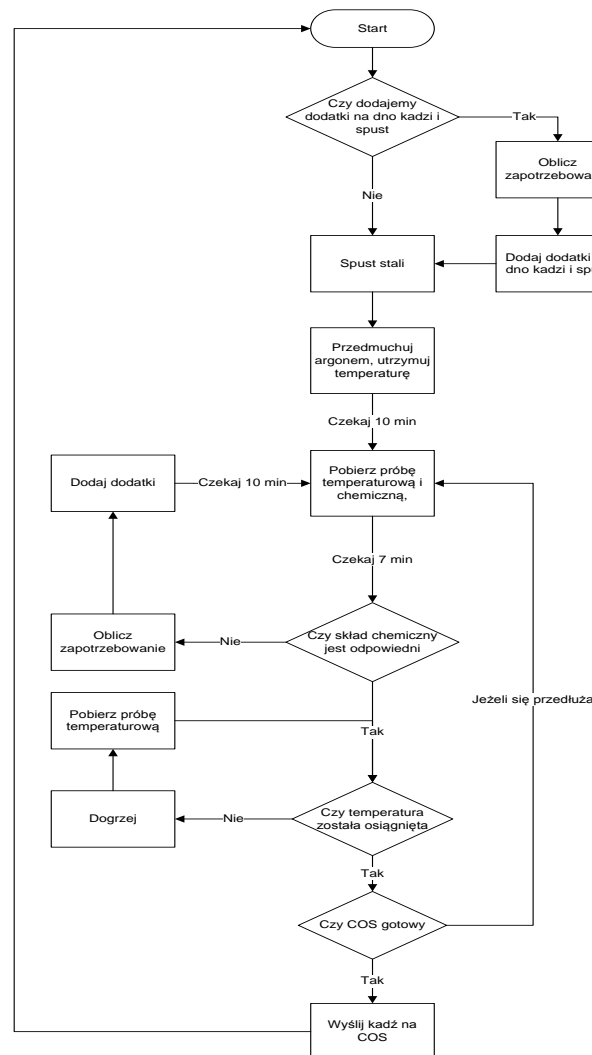
Przedstawiona praca dotyczy tej części procesu, która związana jest z rafinacją stali w piecu kadziowym. W badanej hucie produkowanych jest ponad 800 gatunków stali, w tym stale narzędziowe i wysokostopowe, o różnej konfiguracji zawartości pierwiastków w stali. Zadaniem elektrostalowni jest uzyskanie stali o określonym składzie chemicznym oraz zadanych własnościach, spełniających wymagania stawiane przez zamawiającego. Rafinacja stali wymaga przestrzegania wielu procedur technologicznych, z których do najważniejszych należy dodawanie dodatków stopowych zapewniających żądany skład chemiczny stali. Uzyskanie odpowiedniego składu chemicznego jest jednym z nadrzędnych celów, które muszą być zrealizowane na stanowisku rafinacji stali.

W pracy przedstawiono modele zbudowane w oparciu o metody takie, jak: regresja liniowa, maszyna wektorów podpierających i sieci neuronowe, a następnie wyniki zweryfikowane w warunkach przemysłowych. Modele zostały zaimplementowane w Inteligentnym Systemie Ekspertowym wdrożonym w jednej z krajowych hut.

2. Wprowadzanie dodatków stopowych do stali

Każda ze stalowni ma własne empiryczne zależności, wynikające z praktyki, które zawierają informacje na temat uzysku i zawartości pierwiastków w żelazostopach i dodatkach żużlotwórczych. Na przykład w hucie, w której prowadzono badania, są to procedury tzw. wyrobienia stali, w których obliczanie koniecznej do wprowadzenia masy dodatku stopowego oparte jest na prostych, równowagowych równaniach chemicznych, modyfikowanych wielo-

ma współczynnikami empirycznymi. Uproszczenia takie powodują, że wynik obarczony jest dużym błędem, co w konsekwencji prowadzi do dzielenia procesu dodawania dodatków stopowych na etapy, w których uzupełniany jest jedynie częściowo skład chemiczny. Najpierw pobiera się więc próbę chemiczną, po czym uzupełniany jest częściowo skład chemiczny, znowu bierze się kolejną próbę sprawdzając skład i dodaje kolejną część masy dodatku (rys.1). Taki algorytm postępowania wynika z faktu, że operator pieca kadziowego nie może przekroczyć górnej granicy zawartości danego pierwiastka dla danego gatunku stali, gdyż spowodowałoby to „nietrafienie” wytopu i straty finansowe stalowni.



Rys. 1. Schemat blokowy wprowadzania dodatków stopowych w piecu kadziowym w warunkach przemysłowych

Fig. 1. The block schema of alloy additions inserting into industrial ladle furnace

Podejście takie jest powszechnie stosowane w przemyśle, gdyż brak jest odpowiednio dokładnych metod obliczania mas dodatków stopowych koniecznych do uzyskaniażądanego składu końcowego stali. Większość autorów, np. [2,3,5], najczęściej wykorzystuje modele fizykochemiczne oparte na termodynamicznych bazach danych oraz kryterium zachowania

energii swobodnej układu, uwzględniające wiele czynników teoretycznych oraz wyniki badań laboratoryjnych. Obliczenia ograniczone są jedynie do niewielkiej liczby parametrów procesu, o których wiemy, że mają wpływ na wynik końcowy rafinacji. Charakteryzują się one dobrą, jakościową analizą zjawisk, mają dużą wartość poznawczą, niestety, są zbyt mało dokładne do zastosowania w praktyce. Ostatnio pojawiają się prace wykorzystujące metody inteligencji obliczeniowej do rozwiązania tego problemu, np. [7,9,15], w tym także prace autorów [12,13,14]. Metody te nie wymagają przyjmowania takich uproszczeń i ograniczeń, jak modelowania fizykochemiczne. Pozwalają na uwzględnienie wszystkich istotnych parametrów rzeczywistego procesu przemysłowego, co daje możliwość uzyskania o wiele większych dokładności. W oparciu o te metody opracowano przedstawiony w pracy model do predykcji mas dodatków stopowych wymaganych do otrzymaniażądanego gatunku stali w procesie rafinacji stali w piecu kadziowym.

3. Modele predykcji masy dodatków stopowych

Celem znalezienia najlepszego modelu do predykcji mas dodatków stopowych zastosowano trzy metody: regresji wielorakiej, maszyny wektorów podpierających (SVM) oraz sztucznych sieci neuronowych. Model regresyjny zastosowano jedynie, by wykazać, że proste metody liniowe predykcji dodatków stopowych obarczone są dużymi błędami. Metody te zostały ze sobą porównane w celu znalezienia tej, która będzie miała największą dokładność.

3.1. Predykcja w oparciu o metodę regresji wielokrotnej

Regresja wielokrotna to poszukiwanie zależności pomiędzy zmienną prognozowaną (y) a zbiorem zmiennych objaśniających (x_i). W porównaniu do prostej regresji liniowej, modele regresji wielokrotnej zapewniają często większą dokładność. W regresji liniowej wielokrotnej używa się hiperpłaszczyzny, w celu przybliżenia zależności pomiędzy ciągłą zmienną celu a zbiorem zmiennych objaśniających. Dla regresji wielokrotnej z zmiennymi równanie regresji przybiera postać:

$$\hat{y} = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n \quad (1)$$

Przy regresji wielokrotnej błędy predykcji są mierzone za pomocą reszt $y - \hat{y}$. Reszty te reprezentują odległość pomiędzy właściwym punktem danych a hiperpłaszczyzną regresji.

Wnioskowanie w modelu regresji wielokrotnej można oprzeć między innymi na następujących metodach [6]:

- test t dla zależności pomiędzy zmienną y a daną zmienną objaśniającą x_i , z uwzględnieniem innych zmiennych objaśniających $x_{(i)}$, gdzie $x_{(i)} = x_1, \dots, x_n$
- test F istotności regresji,
- przedział ufności dla współczynnika nachylenia i -tej zmiennej objaśniającej β_i ,
- przedział ufności wartości średniej zmiennej celu dla danego zbioru wartości zmiennych objaśniających x_1, \dots, x_n ,
- przedział predykcji zmiennej celu y dla danego zbioru wartości zmiennych objaśniających x_1, \dots, x_n .

Zmienne objaśniające najczęściej są ciągłe, mogą jednak również być zmiennymi jakościowymi. Jednak zmienna jakościowa w modelu regresji wielokrotnej musi zostać zamieniona na $(k - 1)$ zmiennych wskaźnikowych (zmienna wskaźnikowa jest zmienną binarną i przyjmuje wartość 1, jeżeli obserwowana wartość należy do danej kategorii, oraz wartość 0 w przypadku gdy tak nie jest).

Regresja wielokrotna to rozszerzenie regresji liniowej i ma analogiczne założenia dotyczące błędu losowego. Powinno się wystrzegać współliniowości, co oznacza korelację kilku zmiennych objaśniających, gdyż może prowadzić do niestabilności w przestrzeni poszukiwań. Do przeprowadzenia obliczeń w oparciu o model regresji wielokrotnej wykorzystano system Statistica.

3.2. Predykcja w oparciu o algorytm SVM

Maszyna wektorów podpierających (SVM – Support Vector Machine) to stosunkowo nowa metoda wprowadzona w 1992 roku, oparta na tzw. statystycznej teorii uczenia Vapnika i Chervonenkisa [1], stosowana do estymacji wielowymiarowych funkcji lub do klasyfikacji.

W przypadku klasyfikacji poszukiwany jest maksymalny margines zarówno dla rozwiązań liniowych, jak i nieliniowych. Najczęściej wykorzystuje się funkcje jądrowe (ang. *kernel functions*) [8], które prowadzą do transformacji danych wejściowych do przestrzeni o większym wymiarze i poszukiwania funkcji liniowych modelujących te dane. Wektorami podpierającymi nazywamy te wektory danych wejściowych, które określają optymalną separującą hiperpłaszczyznę lub optymalną powierzchnię aproksymującą. Później SVM znalazły również zastosowanie w problemach regresji [4], w tym między innymi do detekcji nowości, analizy skupień, ekstrakcji i selekcji cech i innych.

W zagadnieniach regresyjnych estymujemy zmienną celu y na podstawie n -wymiarowego wektora x . Podobnie jak w przypadku klasyfikacji, na początku uczymy model SVM na zbiorze treningowym. Różnica polega na rozmiarze macierzy Heszjanu oraz wektorów, które w tym przypadku są podwójnych rozmiarów. Wynaleziono, pierwotnie dla problemów klasy-

fikacji, techniki mogą być skutecznie użyte również w przypadku problemów regresyjnych. Wtedy celem jest znalezienie zależności między wejściami a wyjściami (mapowania), co prowadzi do równania liniowego hiperpłaszczyzny aproksymującej $f(x, w)$:

$$f(x, w) = w^T x + b \quad (1)$$

W przypadku problemu regresyjnego rozwiązywanego za pomocą algorytmu SVM poszukujemy środka (zamiast marginesu, jak w przypadku klasyfikacji). Najbardziej znaczącą różnicą w stosunku do klasycznej regresji jest to, że używamy funkcji błędu z marginesem w postaci równania:

$$E(x, y, f) = |y - f(x, w)|_\varepsilon = \begin{cases} 0 & \text{jeżeli } |y - f(x, w)| \leq \varepsilon \\ |y - f(x, w)| - \varepsilon & \text{w przeciwnym razie} \end{cases} \quad (3)$$

Do przeprowadzenia obliczeń w oparciu o model SVM wykorzystano system Statistica.

3.3. Predykcja w oparciu o sztuczne sieci neuronowe


Problem znalezienia (nauczenia się przez sieć) nieznaną zależność (zwykle funkcji wielu zmiennych), która transformuje wielkości wejściowe procesu w jego wyjścia, może być rozważany jako problem regresyjny. Podstawą teoretyczną jest tu więc teoria aproksymacji. Budowanie modelu neuronowego procesu (poprzez uczenie sieci neuronowej) może być rozważane jako szczególna metoda aproksymacji funkcji. Dla badanego procesu (który najczęściej jest skomplikowaną funkcją zależną od wielu zmiennych) poszukujemy zestawu prostych funkcji, zwykle zależnych od mniejszej ilości zmiennych. Przykładowo, jeśli by dowolną funkcję wielu zmiennych dało się przedstawić jako sumę lub iloczyn pewnych funkcji jednej zmiennej, to obrazem graficznym takiej aproksymacji byłaby sieć składająca się z neuronów o jednym wejściu i jednym wyjściu. Tak więc budowa neuronowego modelu procesu technologicznego może być traktowane jako problem aproksymacji.

Ze względu na przedmiot analizy, podstawowe znaczenie mają własności aproksymacyjne jednokierunkowych sieci neuronowych, gdyż one najczęściej wykorzystywane są w modelowaniu procesów technologicznych. Zagadnieniu temu poświęcono ogromną ilość prac, gdyż ma ono znaczenie fundamentalne (zajmowali się tym także autorzy – [10]). Szerokie zastosowanie jednokierunkowych sieci neuronowych typu MLP wynika z ich własności jako tzw. uniwersalnych aproksymatorów. Wykorzystanie własności aproksymacyjnych SSN występuje w wielu zagadnieniach związanych z analizą danych, gdzie celem jest aproksymacja pewnej nieznaną funkcji (modelu procesu), z którego zostały wzięte pomiary. Z praktycznego punktu widzenia, w tego typu zagadnieniach trzeba wziąć pod uwagę wiele aspektów: jaki jest stopień zaszumienia danych, czy dane pokrywają całą dziedzinę funkcji, której szukamy, jaki rodzaj funkcji aproksymującej jest najodpowiedniejszy dla badanego procesu. Oczywiście,

zakłada się zawsze, że dane, które posiadamy są (zakłóconymi) przykładami tej poszukiwanej, nieznannej funkcji. W pewnych przypadkach to wcale nie musi być prawdą. Najczęściej posiadamy dane z procesu technologicznego (tak właśnie jest w przypadku przytaczanych w pracy przykładów pochodzących z procesu elektrostalowniczego) sterowanego przez operatorów – ludzi. Operatorzy ci mogą stosować różne strategie, aby osiągnąć wyznaczone parametry procesu (cele). Nawet zresztą pojedynczy operator nie zawsze musi stosować te same metody. Tak więc zbiór danych zawierający mieszankę przykładów z tego samego procesu, ale realizowanego różnymi metodami, nie reprezentuje tej samej poszukiwanej funkcji. Dlatego występuje wieloznaczność (ang. *ambiguity*) sposobu selekcji danych ze zbioru, tak aby reprezentowały pojedynczy model procesu. Aby dokonać poprawnego wyboru zbioru uczącego, trzeba zidentyfikować te wieloznaczności, a następnie odpowiednio rozdzielić dane tak, aby odpowiadały oddzielnym modelom [11].

4. Wyniki badań w rzeczywistych warunkach przemysłowych


Jedną z ważnych decyzji, jakie musi podejmować mistrz w trakcie procesu rafinacji stali, jest masa dodatków stopowych, koniecznych do uzyskaniażądanego, końcowego składu chemicznego stali. Ponieważ znany jest wyjściowy (przed rafinacją) skład stali, więc wydawałoby się, że stosując klasyczne modele termodynamiczne, bilanse masowe i energetyczne oraz równowagowe reakcje chemiczne można ten problem rozwiązać. W literaturze zresztą sporo jest prac wykorzystujących te metody do modelowania procesów elektrostalowniczych, ale ich przydatność praktyczna jest znikoma. Spójrzmy zresztą na rys. 2. Dla wybranych 160 procesów rafinacji określonego, tego samego gatunku stali wykreślono trzy krzywe, dla jednego pierwiastka - manganu: krzywa górna mówi o zawartości końcowej manganu (po rafinacji). Ponieważ jest to ten sam gatunek stali, więc zawartość manganu musi być jednakowa (dokładnie mieścić się w dopuszczalnym zakresie, zgodnie z normą). Krzywa środkowa to zawartość manganu wyjściowa (przed rafinacją), krzywa dolna to ilości manganu dodane w trakcie procesu rafinacji. Czy można w tym zauważyć jakąkolwiek prostą zależność? Przecież wartości na krzywej środkowej odchylają się od średniej (ok. 0,08) minimalnie, natomiast ilości dodatków różnią się zasadniczo. To tylko jeden przykład, ale tego typu zależności występują prawie dla wszystkich pierwiastków, oprócz kilku, które prawie nie wchodzą w żadne reakcje i ich zawartość zmienia się minimalnie. Po prostu przy tak wysokich temperaturach i tak dużej dynamice zachodzących reakcji, prawidłowymi metodami opisu są termodynamika i chemia nierównowagowa, a to już bardzo skomplikowane równania różniczkowe i praktycznie niemożliwe do wyznaczenia stałe reakcji. Dlatego właśnie w tych zagadnieniach inteligencja obliczeniowa może przynieść oczekiwane rezultaty.



Rys. 2. Ilość manganu w wybranym gatunku stali: krzywa górna – końcowa zawartość, krzywa dolna – ilość dodana podczas rafinacji, krzywa środkowa – początkowa zawartość (są to przeskalowane wielkości, nie muszą się sumować) (źródło [15])

Fig. 2. Mass of Mn for chosen steel grade: upper curve final capacity, bottom curve – mass added during refining, middle curve – starting capacity (values have been scaled therefore sum of two not equals the third)

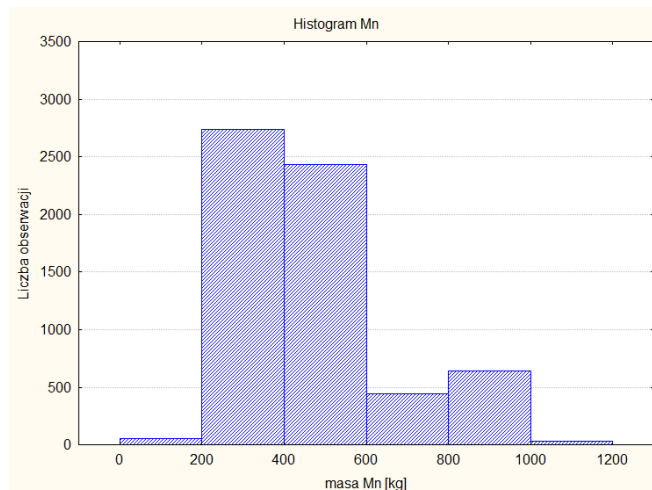
Badania modelowania inteligentnego procesu rafinacji stali prowadzono na danych pochodzących z jednej z hut krajowych. Ogółem dostępnych było ponad 10 000 przykładów uczących (wytopów). W artykule ograniczono się do przedstawienia wyników uzyskanych dla trzech pierwiastków: węgla (C), manganu (Mn) i krzemu (Si). Na rys.3-5 przedstawiono przykładowe histogramy zbiorów danych uczących (po usunięciu wartości odstających). Odciągają one znacznie od rozkładów normalnych, stąd niewielka szansa na uzyskanie poprawnych wyników w oparciu o modele statystyczne. Dlatego zastosowano algorytmy inteligencji obliczeniowej.



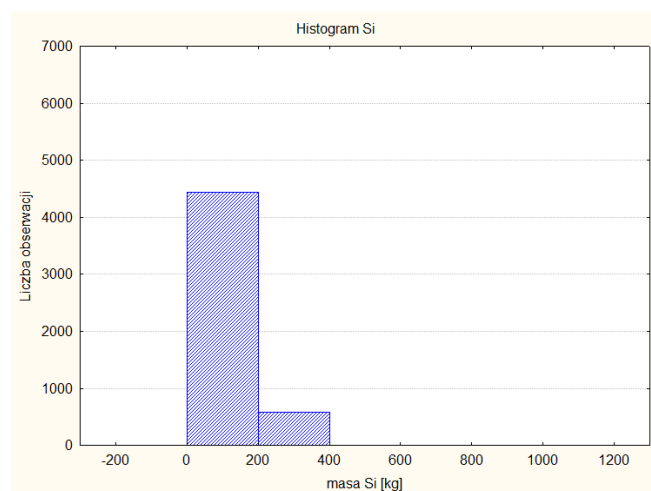
Rys. 3. Masy dodawanego węgla w poszczególnych wytopach
Fig. 3. Histogram of added coal for particular heats

W modelu SVM zastosowano funkcje jądrowe typu radialnych funkcji bazowych (RBF) i model regresji typu 1 (dla którego otrzymywano najlepsze parametry). Optymalne parametry funkcji i modelu regresji były wyznaczane w procesie uczenia, z osobna dla każdego progno-

zwanego pierwiastka. Badania modelu SVM oraz liniowego modelu regresyjnego prowadzone były w środowisku Statistica. Podsumowujące wyniki dla regresji liniowej i SVM zebrano w tab.1 i tab.2.



Rys. 4. Masy dodawanego manganu w poszczególnych wytopach
Fig. 4. Histogram of added Mn for particular heats



Rys. 5. Masy dodawanego krzemu w poszczególnych wytopach
Fig. 5. Histogram of added Si for particular heats

Tabela 1

Uśrednione wskaźniki prognozowania masy wybranych dodatków stopowych dla modelu regresji liniowej wielorakiej

Dodatek	Si	Mn	C
Wartość			
Współ. korelacji	0.974491	0.983812	0.947754
R^2	0.959217	0.977661	0.907281

W modelu neuronowym zastosowano sieć typu MLP z 27 neuronami wejściowymi (odpowiadającymi takim wielkościom fizycznym, jak: masa, temperatura, składy chemiczne na wejściu i wyjściu procesu rafinacji i in.). Testowano różną liczbę neuronów w warstwie ukry-

tej. Najlepsze rezultaty osiągnięto dla 17 neuronów. W warstwie ukrytej zastosowano sigmoidalne funkcje aktywacji neuronów (tanh), natomiast w warstwie wyjściowej – liniowe funkcje aktywacji. Do uczenia zastosowano algorytm BFGS. Dostępny zbiór przykładów został podzielony następująco: 60% zbiór uczący, 20% zbiór walidacyjny, 20% zbiór testowy. Uczenie prowadzone było w 10-krotnej kros walidacji i w tabelach przedstawione są średnie wartości błędów. Badania modelu neuronowego prowadzone były w środowisku Statistica. Uzyskane wyniki zebrano w tab.3.

Tabela 2

Uśrednione wskaźniki prognozowania masy wybranych dodatków stopowych dla modelu SVM

Dodatek	Si	Mn	C
Wartość			
Liczba predyktorów	27	27	27
Typ SVM	Regresja typu 1	Regresja typu 1	Regresja typu 1
Typ jądra	RBF	RBF	RBF
Liczba wektorów podpierających	43	57	217
Współ. korelacji	0.9575	0.9857	0.9705

Tabela 3

Uśrednione wskaźniki prognozowania masy wybranych dodatków stopowych dla modelu regresji liniowej wielorakiej

Dodatek	Si	Mn	C
Wartość			
Typ sieci	MLP 27-17-1	MLP 27-17-1	MLP 27-17-1
Algorytm uczenia	BFGS 73	BFGS 79	BFGS 112
Aktywacja neurony ukryte	Tanh	Tanh	Tanh
Aktywacja neurony wyjściowe	Liniowa	Liniowa	Liniowa
Jakość (uczenie)	0.988044	0.998405	0.978211
Jakość (testowanie)	0.990657	0.998230	0.978074

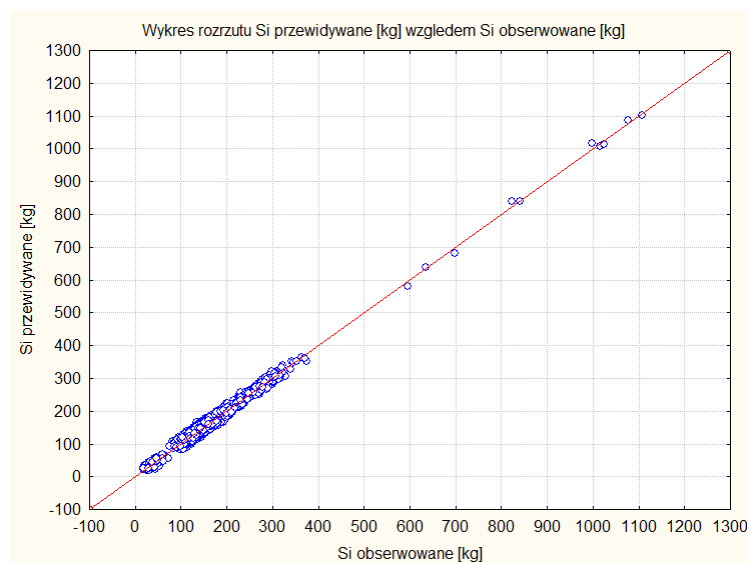
W trakcie badań przetestowano trzy omówione wyżej modele. Wszystkie zamieszczone tu wyniki zostały otrzymane przy optymalnych parametrach modelu. Dobór optymalnego modelu polegał na systematycznych badaniach z wykorzystaniem selekcji cech oraz optymalizacji parametrów modeli, wykonywanych przez przetestowanie, w sposób zautomatyzowany, najlepszych z możliwych kombinacji, przy czym badane modele nie wykazywały zbytniej czułości na zmianę parametrów. Prosty model typu regresji liniowej daje na tych danych błędy maksymalne rzędu kilkudziesięciu procent. W większości przypadków wyniki uzyskane z wykorzystaniem modelu SVM z radialnymi funkcjami bazowymi wahały się w granicach kilku do kilkunastu procent błędu predykcji. Najlepsze wyniki zapewniały modele neuronowe (nawet 99% dokładności, rys.6). Zbudowane modele neuronowe charakteryzują się wysoką

dokładności i dobrą generalizacją. Poniżej przedstawiono porównanie błędów trzech badanych modeli dla przewidywania ilości dodatków, w przypadku wybranych pierwiastków.

Tabela 4

Porównanie dokładności badanych modeli (błędy w kilogramach pierwiastka)

	Regresja wieloraka			SVM			Sieci neuronowe		
	C	Mn	Si	c	mn	si	c	mn	si
Błąd średni	-0.0047	-0.0043	-0.0002	0.8772	-5.8481	-5.1114	-0.0245	0.0639	0.0308
Błąd średni bezwzględny	10.6274	16.1837	10.4918	9.4206	14.8098	17.1541	7.7953	8.7343	8.8818
Błąd średnio kwadratowy	13.1436	20.3742	12.5764	11.0415	18.4095	21.5939	9.5844	10.3714	10.5631



Rys. 6. Przewidywana przez model masa dodawanego krzemu w funkcji mas rzeczywiście dodawanych w procesie

Fig. 6. Predicted vs. observed masses of Si for the LHF process

5. Podsumowanie

Wzrost konkurencyjności na rynku zmusza przedsiębiorstwa do produkowania, szybko i dużo, produktów o wysokiej jakości w najbardziej ekonomiczny sposób. Aby sprostać tym wyzwaniom, konieczne jest optymalizowanie procesu technologicznego, jego bieżące monitorowanie i ciągła kontrola jakości produkcji. Najlepiej nadają się do tego metody inteligencji obliczeniowej, narzędzia operujące na danych bezpośrednio pobieranych z procesu technologicznego, najczęściej sygnałach mierzonych przez zestawy sensorów, sterowniki mikroprocesorowe czy analogowe systemy pomiarowe, będące częścią współczesnego w pełni opomiarowanego i zautomatyzowanego procesu technologicznego. Predykcje podawane przez wybrany model inteligentny (wcześniej nauczony) mogą być używane do detekcji pojawiających się anomalii w sterowaniu, gdy określone parametry procesu w jego trakcie ulegają zmianie.

W tego typu aplikacjach najważniejsza jest dokładność predykcji i stopień zautomatyzowania, natomiast mniej ważne jest, jaki inteligentny model został wybrany. Jednakże jeśli struktura modelu jest łatwo interpretowalna, jak to występuje w systemach neuronowo-symbolicznych, neuronowo-rozmytych i in., jest lepiej, gdyż taka struktura pozwala zrozumieć przebieg procesu i dokonać uogólnień dotyczących jego istoty. W konsekwencji powstaje pogłębiona wiedza o procesie technologicznym, która może być użyta do jego modyfikacji, unowocześnienia, poprawy efektywności.

BIBLIOGRAFIA

1. Cortes C., Vapnik V.: Support-Vector Networks. Machine Learning, 20, 1995.
2. Engh T.A.: Principles of metal refining. Oxford Univ. Press, Oxford 1992.
3. Ghosh A.: Secondary steelmaking. CRC Press Boca Raton, New York 2001.
4. Drucker H., Burges C.J.C., Kaufman L., Smola A., Vapnik V.: Support Vector Regression Machines. Advances in Neural Information Processing Systems 9, NIPS 1996, MIT Press 1997, s. 155÷161.
5. Karbowiczek M.: Elektrometalurgia stali. AGH, Kraków 1993.
6. Larose D.: Metody i modele eksploracji danych. PWN, Warszawa 2008.
7. Meireles M., Almeida P., Simões M.: A Comprehensive Review for Industrial Applicability of Artificial Neural Networks. IEEE Transactions on Industrial Electronics 2003, 3, s. 585÷601.
8. Schölkopf B., Smola A.J.: Learning with kernels. MIT Press Cambridge MA 2002.
9. Siemens A.G.: SIMELT NEC – neural network based energy control efficiency. Industrial solution and services. Siemens Press, 2005, s. 1÷8.
10. Wieczorek T.: Optymalizacja struktury sztucznych sieci neuronowych typu perceptron wielowarstwowy. W: Węgrzyn S., Znamierowski L., Czachórski T., Kozielski S. (red.) Nowe technologie sieci komputerowych. WKŁ, Warszawa 2006, s. 153÷164
11. Wieczorek T.: Neuronowe modelowanie procesów technologicznych. Politechnika Śląska, Gliwice 2008.
12. Wieczorek T., Mączka K., Świłała P.: Automatyczne tworzenie baz wiedzy z wykorzystaniem drzew decyzyjnych. Bazy danych – nowe technologie. Architektura, metody formalne i zaawansowana analiza danych. Kozielski S., Małyśiak B., Kasprowski P., Mrozek D. (red.) WKŁ, Warszawa 2007, s. 385÷392.
13. Wieczorek T., Pilarczyk M.: Classification of steel scrap in the EAF process using image analysis methods. Archives of Metallurgy and Materials, 2008, Vol.53, No. 2, s. 613÷618.

14. Wieczorek T., Świtała P.: Wykorzystanie algorytmu CART do automatycznego tworzenia bazy wiedzy systemu ekspertowego. Bazy danych – nowe technologie, WKŁ, Warszawa 2008.
15. Yanguang S., Daixian W., Yan T., Shi T., Fang Y., Wang S.: An Intelligent Ladle Furnace Control System, Proceedings of the 3th World Congress on Intelligent Control and Automation, Hefei P.R. China, 1, 2000, s. 330÷334.

Recenzenci: Prof. dr hab. inż. Tadeusz Czachórski
Prof. dr hab. inż. Jerzy Klamka

Wpłynęło do Redakcji 31 stycznia 2010 r.

Abstract

For adjustments of steel composition alloy additions are added to the ladle furnace for obtaining the grade of steel being manufactured. The prediction of steel composition is a crucial factor of secondary metallurgy. Calculations usually are made basing on the equilibrate chemical processes in molten steel. In the paper the problem of prediction of alloy additions has been solved using Artificial Neural Nets and the SVM algorithm. Review of applications of computational intelligence in secondary steelmaking has been made. The prediction system used by authors has been introduced. Details of the neural network prediction and other approaches to the prediction problem, i.e. Support Vector Regression Module and Multivariate Linear Regression have been introduced. Experimental results and the final conclusions and recommendations have been presented.

Adresy

Tadeusz WIECZOREK: Politechnika Śląska, Katedra Zarządzania i Informatyki, ul. Krasińskiego 8, 40-019 Katowice, Polska, tadeusz.wieczorek@polsl.pl.

Paweł ŚWITAŁA: Politechnika Śląska, Katedra Zarządzania i Informatyki, ul. Krasińskiego 8, 40-019 Katowice, Polska, tadeusz.wieczorek@polsl.pl.