

MODELOWANIE ZA POMOCĄ SZTUCZNYCH SIECI NEURONOWYCH ZMIAN WŁAŚCIWOŚCI WARSTWY WIERZCHNIEJ BIOMATERIAŁÓW

MICHAŁ SZOTA, JÓZEF JASIŃSKI, LEOPOLD JEZIORSKI,
MAŁGORZATA LUBAS

POLITECHNIKA CZĘSTOCHOWSKA,
WYDZIAŁ INŻYNIERII PROCESOWEJ, MATERIAŁOWEJ I FIZYKI
STOSOWANEJ, INSTYTUT INŻYNIERII MATERIAŁOWEJ,
ZAKŁAD BIOMATERIAŁÓW I INŻYNIERII POWIERZCHNI,
42-200 CZĘSTOCHOWA, AL. ARMII KRAJOWEJ 19, POLAND
E-MAIL: MSZOTA@MIM.PCZ.CZEST.PL

Streszczenie

W publikacji przedstawiono sposób projektowania struktury sieci neuronowej stosowanej do modelowania procesów obróbki cieplno-chemicznej biomateriałów w złożu fluidalnym. Artykuł ten prezentuje model neuronowy stosowany do właściwości warstwy wierzchniej biomateriałów. Proces ten jest dość skomplikowany, ponieważ jest wieloparametryczny i posiada nieliniowe charakterystyki [1-2]. Fakt ten oraz brak algorytmów matematycznych opisujących ten proces czynią modelowanie, właściwości warstwy wierzchniej biomateriałów, za pomocą tradycyjnych metod numerycznych trudne, a czasami niemożliwe. W tym przypadku celowa jest próba zastosowania sztucznych sieci neuronowych.

Struktura sieci neuronowej jest projektowana oraz budowana poprzez dobór parametrów wejściowych oraz wielkości modelowanych – parametrów wyjściowych. Przedstawione zostaną metody uczenia, oraz testowania sieci neuronowej, sposoby ograniczenia liczebności struktury sieci oraz błędu uczenia i testowania. Tak przygotowany model neuronowy, po zadaniu oczekiwanych wartości parametrów warstwy wierzchniej na wyjście, dostarczy wiele informacji na temat przebiegu procesu nawęglania w złożu fluidalnym. Model neuronowy może być zastosowany do budowy systemu sterującego, kontrolującego w czasie rzeczywistym przebiegu procesu, który będzie również wspierał decyzję inżynierską.

Praca przedstawia odmienną koncepcję uzyskiwania oczekiwanych właściwości warstwy wierzchniej biomateriałów po obróbce cieplno-chemicznej w złożu fluidalnym. Odpowiednio przygotowany model sieci neuronowej może być stosowany do projektowania procesów cieplno-chemicznych w złożu fluidalnym oraz kontroli przebiegu tych procesów.

[Inżynieria Biomateriałów, 67-68, (2007), 45-47]

Wprowadzenie

Proces fluidalnej obróbki cieplno-chemicznej jest wieloparametryczny i skomplikowany, ponieważ zmiany parametrów procesu mają charakter nieliniowy. Kolejnym problemem jest brak algorytmów matematycznych, opisujących te procesy. Zastosowanie sieci neuronowych do modelowania procesów fluidalnej obróbki cieplno-chemicznej jest wynikiem szczególnych właściwości cech sieci neuronowej:

MODELING CHANGES OF PROPERTIES OF SURFACE LAYER OF BIOMATERIALS BY MEANS ARTIFICIAL NEURAL NETWORKS

MICHAŁ SZOTA, JÓZEF JASIŃSKI, LEOPOLD JEZIORSKI,
MAŁGORZATA LUBAS

CZESTOCHOWA UNIVERSITY OF TECHNOLOGY,
FACULTY OF MATERIALS PROCESSING TECHNOLOGY AND APPLIED
PHYSICS, INSTITUTE OF MATERIALS ENGINEERING, BIOMATERIALS
AND SURFACE ENGINEERING RESEARCH INSTITUTE,
19 ARMII KRAJOWEJ AV., 42-200 CZESTOCHOWA, POLAND,
E-MAIL: MSZOTA@MIM.PCZ.CZEST.PL

Abstract

In this publication is presented manner of designed structure of neural networks and using it for modeling of oxidations process in fluidized bed. This paper presents neural network model used for designing the properties of surface layer after thermo-chemical processes in fluidized bed. This process is very complicated and difficult as multi-parameters changes are non linear. This fact and lack of mathematical algorithms describing this process makes modelling properties of biomaterials by traditional numerical methods difficult or even impossible. In this case it is possible to try using artificial neural network.

The neural network structure is designed and prepared by choosing input and output parameters of process. The method of learning and testing neural network, the way of limiting nets structure and minimizing learning and testing error are discussed. Such prepared neural network model, after putting expected values of parameters of surface layer in output layer, can give answers to a lot of questions about running heat treatment in fluidized bed. The neural network model can be used to build control system capable of on-line controlling running process and supporting engineering decision in real time.

This paper presents different conception to obtain assumed material's properties of surface layer of biomaterials after heat treatment in fluidized bed. The specially prepared neural networks model could be a help for engineering decisions and may be used in designing thermo-chemical process in fluidized bed as well as in controlling changes of this process.

[Engineering of Biomaterials, 67-68, (2007), 45-47]

Introduction

The thermo-chemical processes in fluidized bed is multi-parameters and complicated [1,2], because changes of parameters during this process have non linear characteristic. The next problem is the lack of mathematical algorithms that could describe it. Using neural networks for modelling oxidizing in fluidized bed is caused by several nets' features:

- non linear character,
- ability to generalize the results of calculations for data out of training set and no need for mathematical algorithms describing influence changes input parameters on hardness,
- no need for mathematical algorithms describing influence changes input parameters on modelling materials properties [3-7].

- nieliniowego charakteru,
- możliwości uogólniania wyników obliczeń dla danych nie zawartych w zbiorze uczącym,
- brak potrzeby stosowania algorytmów matematycznych opisujących wpływ zmian parametrów wejściowych na modelowane właściwości materiałów [3-7].

Badania są podzielone na osiem części:

- wybór modelowanych właściwości materiałów,
- wybór parametrów obróbki cieplnej,
- planowanie i zbudowanie struktury sieci neuronowej,
- minimalizacja struktury modelu,
- minimalizacja błędów,
- zastosowanie modelu sztucznych sieci neuronowych dla prognozowania warstw wierzchnich biomateriałów po obróbce fluidalnej cieplno-chemicznej,
- praktyczna weryfikacja wyników modelu.

W prezentowanej technice modyfikacji warstwy wierzchniej materiałów zastosowano fluidalną obróbkę cieplno-chemiczną – wytwarzanie warstw powierzchniowych biomateriałów. Charakteryzują się ona wysokim współczynnikiem przepływu masy i ciepła. Techniki te są często stosowane w instytutach badawczych i małych przedsiębiorstwach [1,8-11].

Metodyka pracy


Modelowanie procesów obróbki cieplnej z zastosowaniem sieci neuronowych rozpoczynamy od zamodelowania struktury sieci. Charakterystyczne cechy sieci neuronowych to: numer warstw, ilość neuronów w warstwie i rodzaj połączeń. Liczba neuronów w wejściowej warstwie i liczba neuronów wyjściowych parametrów użytych w równaniu. Dla procesu wytwarzania warstw powierzchniowych biomateriałów wynosi ona 7 ($n=7$).

Liczba wyjściowej warstwy jest równa z liczbą modelowanych parametrów. W tym przypadku wyjściowe neurony warstwy są podzielone na cztery sekcje, co pokazano na RYS.1. Ilość sekcji jest uzależniona od przyjętych właściwości warstwy wierzchniej materiału.

Po ustaleniu wejściowej i wyjściowej struktury sieci, następnym krokiem jest modelowanie wewnętrznych warstw modelu. Matematyczne algorytmy opisujące zależność pomiędzy wektorami x_n i y_k , które nie są znane, nie są konieczne podczas stosowania niekonwencjonalnych sposobów budowy sieci neuronowych. To jest informacja oparta na danych wejściowych i wyjściowych.

Problem teoretycznego wyboru struktury sieci ogranicza się do znalezienia wielo-czynnikowej funkcji aktywacji dla zadanego wektora wejściowego x_n [3]. Prezentowany w tej pracy przypadek charakteryzuje się wielowymiarowym wektorem wejściowym i ciągłą funkcją aktywacji.

Ten model sieci neuronowej został zbudowany przez Kołmogorowa [12]. Udowodnił on, że otrzymane inne k -wymiarowe wektory wyjściowe y_k dla n -wymiarowych wektorów wejściowych x_k oraz ciągła funkcja aktywacji używa jednej ukrytej warstwy sieci wykorzystując wystarczającą neuronów $2n+1$.



The researchers are divided into eight stages:

- choosing modelling properties of materials
- choosing heat treatment parameters to prepare data input vector
- using special computer system to obtain training data set,
- designing and building neural network structure,
- minimizing model structure and learning error,
- minimizing testing error,
- using neural network model for prediction oxygen layer thickness of material after heat treatment in fluidized bed,
- practical verification of modelling results.

At present techniques of modification of surface layer of biomaterials are used in the thermo chemical treatment. One of this is oxidizing in fluidized bed. This is characterized by high coefficient heat and mass transfer. These techniques are very often used in researching institutes and small industrial plant [1,8-11].

Work methodology

Modelling the process using neural networks can be started with designing the structure of the network. The characteristic features of neural nets are: the number of layers, the number of neurons in each layer and kinds of neural connections. The number of neurons in input layer and the number of input parameters are usually equal. For oxidizing steel process in fluidized bed $n=7$. Particular neural networks inputs are described particular variables data inputs, such as:

The size of output layer is equal with number of searched parameters. In this case neurons in output layer are divided into four sections shown in FIG.1. The quantity of section is depend on assumed properties of surface layer.

After fixing the input and the output layer structure the next step is designing the inside layers of the model. As mathematic algorithms describing correlations between vectors x_n and y_k are not known it is necessary to use an unconventional way of building the neural nets. It is based on information about output and input.

Theoretically the problem of choosing neural structure is restricted to approximation of multi-variable function for given vector x_n [3]. The case discussed in this paper concerns multi-dimensional input vector and continuous activation function. Building that kind of neural network model is defined by Kołmogorow statement [12]. He proved that in order to obtain k -dimensional output vector y_k for n -dimensional input vector x_n and continuous activation function, using one hidden layer neural network built of $2n+1$ neurons is sufficient. Kołmogorow didn't define activation function algorithm, because it is chosen for a particular process likewise the number of hidden layers which changes in range from n to $3n$.

RYS.1. Struktura sieci neuronowej zgodnie z twierdzeniem Kołmogorowa, gdzie:

$X=[x_1, x_2, \dots, x_n]$ – n – wymiarowy wektor wejściowy;
 $Y=[y_1, y_2, \dots, y_k]$ – k – wymiarowy wektor wyjściowy;
 $Z_1, Z_2, \dots, Z_{2n+1}$ – neurony warstwy ukrytej.

FIG.1. Structure of neural network for modelling properties of surface of biomaterials in accordance with Kołmogorow statement, where:

$X=[x_1, x_2, \dots, x_n]$ – n – dimensional input vector;
 $Y=[y_1, y_2, \dots, y_k]$ – k – dimensional output vector;
 $Z_1, Z_2, \dots, Z_{2n+1}$ – hidden layer neurons.

Kołmogorow nie zdefiniował algorytmu funkcji aktywacji, ponieważ nie wybrał dla poszczególnych procesów liczby ukrytych warstw, które są zmienne w zakresie $n - 3n$.

Rezultaty modelowania za pomocą sztucznych sieci neuronowych

Sieć neuronowa może przewidywać właściwości warstwy wierzchniej biomateriałów z błędem od 4,5% – 6,8%. Taki wynik umożliwia zastosowanie sieci neuronowych, projektowanych tą metodą, do projektowania oczekiwanych właściwości warstw wierzchnich biomateriałów po obróbce cieplno-chemicznej w złożu fluidalnym.

Wnioski

Sieć neuronowa zbudowana i stosowana podczas tych badań pozwoliła na modelowanie właściwości warstwy po procesach obróbki cieplnej i cieplno-chemicznej w złożu fluidalnym. Wyniki otrzymane tą drogą porównano z wynikami otrzymanymi po przeprowadzonych obróbkach cieplnych lub cieplno-chemicznych w złożu fluidalnym.

Powyższe badania będą kontynuowane dla kompleksowego rozwiązania problemu. Wynikiem końcowym będzie opracowany specjalny system komputerowy, połączony w czasie rzeczywistym z oprzyrządowaniem stanowiska obróbki cieplnej. Połączenie to umożliwi ciągłe wzbogacanie bazy danych uczących i testujących. Bezpośrednie połączenie sieci neuronowej, w czasie rzeczywistym, z systemem sterującym pozwoli na ciągłą kontrolę zmian parametrów procesu [14-15] oraz będzie wsparciem podczas podejmowania decyzji inżynierskich.

Podziękowania

Praca finansowana ze środków Ministra Nauki, w ramach realizacji Programu Wieloletniego pt. „Doskonalenie systemów rozwoju innowacyjności w produkcji i eksploatacji w latach 2004 – 2008” –PW004/ITE/02/2005

Results of neural network modeling

Neural network can predicts values of properties with average error in range 4,5%–6,8%. This result makes possibility that prepared in that way neural network can be used to design assumed surface layer of biomaterials after process in fluidized bed.

Conclusions

Neural network developed and used in this research is able to modelling properties of surface layer after thermo and thermo-chemical processes in fluidized bed. In accordance with empirical obtained properties of biomaterials, surface layer of research biomaterials is computed. After compared this results with results obtained by neural network modelling, error of prediction is computed.

This research will be continued to complex solve this subject and applied it in Industrial plant. The final solution will be special computer system, which will be connected in real time [13] with heat medium and gas distribution station. This connection and special work application make to possible to add new date in training and testing data. Connection of this system whit heat treatment control system makes to possible on-line control running process [14-15] and support engineering decision in real time.

Acknowledgements

The studies were financially supported by project No PW-004/ITE/02/2005

Piśmiennictwo

- [1] J. Jasinski, Oddziaływanie złoza fluidalnego na procesy nasycania dyfuzyjnego warstwy wierzchniej stali, Wydawnictwo WIPMiFS, Częstochowa 2003
- [2] J. Jasinski, L. Jeziorski, M. Kubara, Carbonitriding of steel In fluidized beds, Heat Treatment of Metals, Vol. 12, nr 2, 1988
- [3] S. Osowski, Sieci neuronowe do przetwarzania informacji, Oficyna Wydaw. Politechniki Warszawskiej, Warszawa 2003
- [4] L. Rutkowski Sieci neuronowe i neurokomputery, Wydawnictwo Politechniki Częstochowskiej, Częstochowa, 1996
- [5] J. Trzaska, L.A. dobrzanski, Application of neural networks for designing the chemical composition of steel with the assumed hardness after cooling from the austenitising temperature, Journal of Materials Processing Technology 164-165, 2005
- [6] W. Sitek, L.A. Dobrzanski, Application of genetic method in materials' design, Journal of Materials Processing Technology 164-165, 2005
- [7] L.A. Dobrzanski, M. Kowalski, J. Madejski, Methodology of the mechanical properties prediction for the metallurgical products from the engineering steels Rusing the Artificial Intelligence methods, Journal of Materials Processing Technology 164-165, 2005
- [8] Z. Rogalski, Obróbka cieplna fluidalna – stan techniki, czesc 1, Inzynieria Powierzchni nr 2, Warszawa 2000

References

- [9] T. Babul, A. Nakonieczny, Z. Obuchowicz, D. Orzechowski, J. Jasinski, L. Jeziorski, T. Fraczek, R. Torbus, Przemyslowe zastosowanie wizualizacji i sterowania komputerowego piecami do obróbki cieplnej i cieplno-chemicznej, Inzynieria Materialowa, nr 5, 2002
- [10] J. Jasinski, L. Jeziorski, T. Fraczek, R. Torbus, P. Chrzastek, T. Babul, A. Nakonieczny, Z. Obuchowicz, Komputerowy system sterowania i wizualizacji procesami F-A/O-D w wersji laboratoryjnej, Inzynieria Materialowa, nr 5, 2002,
- [11] J. Jasinski, System wizualizacji i sterowania procesow obróbki cieplno-chemicznej w wersji laboratoryjnej, Biuletyn Automatyki ASTOR, Automatyka, Sterowanie i Organizacja Produkcji, Krakow 2004
- [12] S. Haykin, Neural networks, a comprehensive foundation, Macmillan College Publishing Company, New York, 1994,
- [13] Joon-Sik Son, Duk-Man Lee, Ill-Soo Kim, Seung-Gap Choi, A study on on-line learning neural networks for prediction for rolling force in hot-rolling mill, Journal of Materials Processing Technology 164-165, 2005,
- [14] Sviaticznyj D., Pietrzyk M., On-line Model of Thermal Roll Profile during Hot Rolling, Metall. Foundry Eng., 1, 27 2001,
- [15] J. Kusiak, Pietrzyk M., Sviaticznyj D., Application of artificial neural network in on-line control pf hot flat folling processes, Int. Journal Engineering Simulation, 1, 3, 2000.