

高炉内分布データのパターン認識における ニューラルネットの応用

© 1991 ISIJ

技術報告

大塚 喜久*・田村 直樹*・松田 浩一*
小西 正躬*²・門口 維人*³

Application of Neural Network to the Distribution Pattern Recognition of Blast Furnace Data

*Yoshihisa OTSUKA, Naoki TAMURA, Kouichi MATSUDA,
Masami KONISHI and Korehito KADOGUCHI*

Synopsis :

As for operation of the blast furnace, it is important to recognize the distribution pattern of measured furnace data. Usually, these data are identified visually by human experts. Recently, the neural network technology is expected to be a new technology realizing the artificial pattern recognition of the data in good agreement with human judgement.

In this paper, the application of back propagation type neural network to the pattern recognition of blast furnace data is studied. This type of network can distinguish some specific pattern from others after learning typical teaching data. Such teaching data can be arranged in two ways. One way is to choose typical pattern out of the actual operation data. The other way is to create artificial teaching data, when it is difficult to find out that data from actual data. As for the recognition of the top gas temperature distribution in furnace the actual data are prepared for learning and for that of burden profile recognition, the artificial data are adopted. In both cases, the neural network succeeded in recognition regardless of noises existing in the data.

Key words : blast furnace; top gas temperature; burden profile; neural network; data recognition; back propagation.

1. 緒 言

高炉は大規模な分布系を特徴とするプロセスである。従って、高炉内部状態の高さ方向や半径方向等の分布を認識することが操業上重要である。このために多数のセンサーが高炉に取り付けられ、膨大な量のデータが採取されている。従来分布形状は、これらのデータから熟練者が判断したり、計算機を用いてその特徴点を指數化してきた。しかし、熟練者による判断では、結果が客観性に欠けるし、データを指數化するにはアルゴリズムの構築に試行錯誤を伴い多くの労力を要する。

近年、研究がさかんに行われているニューラルネット¹⁾は神経回路網を参考にしたモデルであり、数学モ

ルで記述されたニューロン（神經細胞）を多数ネットワーク結合し、複数種類の典型的な分布パターン（学習用データ）を学習することにより構成される。学習後のニューラルネットは測定データがいずれの学習用データに近いかを認識することができる。このように本技術は分布データの学習と認識を特徴としており、上記の問題点を克服する技術^{2)~4)}として注目されている。

本研究では、神戸3高炉の炉頂部温度分布と炉頂装入物プロフィールをニューラルネットにより認識した。前者は学習用データを測定値から選択できた例であり、後者は人工的に作成した例である。いずれの場合も学習によりニューラルネットが構成でき、測定データに対して人間による判断と近い認識結果を得ることができた。

平成元年9月本会講演大会にて発表 平成2年4月5日受付 (Received Apr. 5, 1990)

* (株)神戸製鋼所電子技術研究所 (Electronics Research Laboratory, Kobe Steel, Ltd., 1-5-5 Takatsukadai Nishi-ku
Kobe 651-22)

*2 (株)神戸製鋼所電子技術研究所 工博 (Electronics Research Laboratory, Kobe Steel, Ltd.)

*3 (株)神戸製鋼所生産技術部 (Technology Administration Department, Kobe Steel, Ltd.)

2. ニューラルネットの概要

人間の脳は多数のニューロン(神経細胞)がシナプス結合によりネットワークを構成し、各ニューロンが密に相互作用することにより知的な処理を行っている。ニューラルネットは、人間の脳に習い、数学的に記述したニューロンを多数相互結合して構成したネットワークにより、分布データの学習と認識を行う。

ニューロンの数学モデル⁵⁾は、Fig. 1 に示すように入力の荷重和と非線形処理で記述される。ニューラルネットはこのニューロンモデルを Fig. 2 に示すように階層的にネットワーク結合したものであり、情報は入力層から出力層へと流れる。ニューラルネットは典型的な分布

パターンを学習用データとして学習するだけで構成することができる。学習では学習用データをニューラルネットに入力したとき、出力値が教師データと呼ばれる好みの値に近づくようにニューロンの結合荷重を変更する操作を繰り返す。この変更にはバックプロパゲーションアルゴリズムが用いられる(数学的な詳細は Appendix を参照)。学習後のニューラルネットは測定データがどの学習用データに近いかを認識することができる。

3. ニューラルネットによる高炉データの認識

高炉操業では、炉頂部や炉壁部等の温度分布、装入物分布、圧力分布など、分布データを認識することが重要である。本節ではこれらの分布データの中から炉頂温度分布と装入物プロフィールを取り上げ、これら分布データの認識にニューラルネットの応用を検討した。

ニューラルネットでは、その特徴をよく表している典型的な分布パターンを学習用データとして学習する。したがって学習用データをいかに設定するかが重要な要因となる。この設定には認識対象に応じて次の二つの方法がある。

- (1)測定データから選択する
- (2)人工的に作成する

以下では前者を炉頂温度分布の認識に、また後者を炉頂装入物プロフィールの認識に適用した結果について述べる。

3・1 炉頂温度分布の認識

神戸3高炉において炉頂温度分布はクロスゾンデにより東西南北の4方向22点で測定されている。測定結果を目視により観察すると、周辺部が中間部よりもやや高温である分布と、周辺部と中間部がほぼ同じ温度である分布に大別できた。前者をW型分布、後者をL型分布と呼ぶことにする。それぞれの学習用データは測定データから容易に選択することができた。これらをFig. 3に示す。

ニューラルネットは、測定された炉頂温度分布がW型であるかまたはL型であるかを認識する。学習には

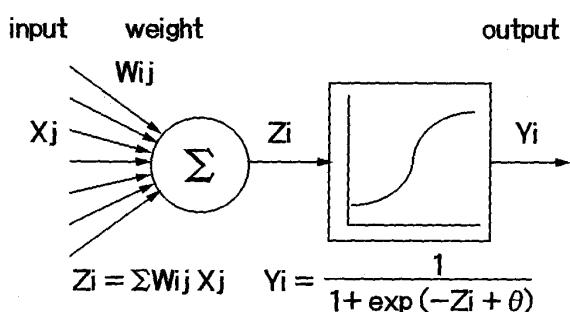


Fig. 1. Mathematical neuron model.

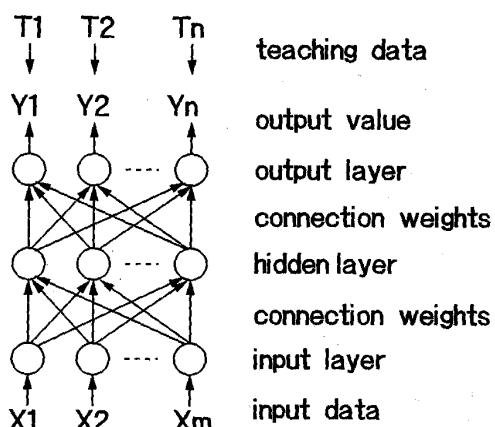


Fig. 2. Back propagation type neural network.

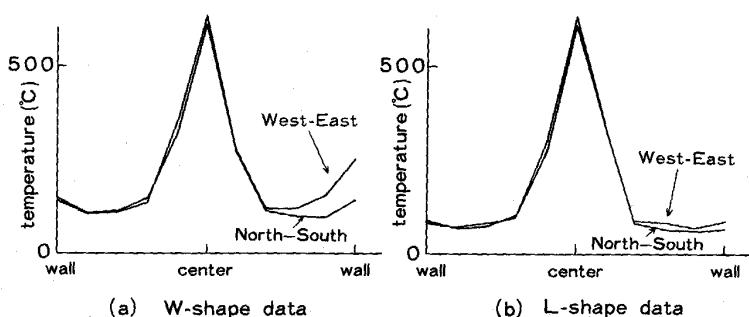


Fig. 3. Typical pattern data of top gas temperature distribution for teaching.

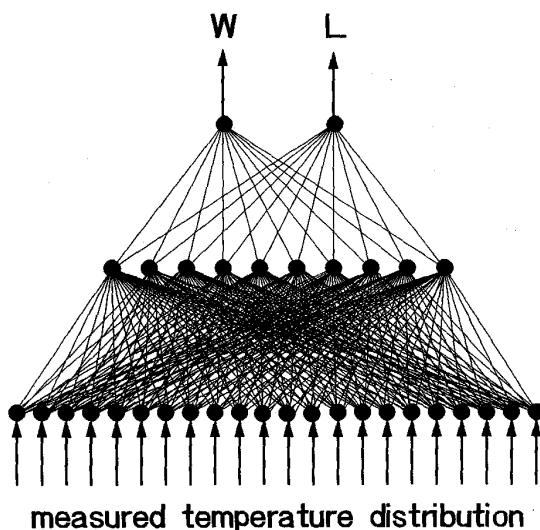


Fig. 4. Network configuration for the recognition of top gas temperature distribution.

Fig. 3 のデータを用いた。ニューラルネットへは 22 点の測定値を入力する。すなわち入力層のニューロン数は 22 とした。出力層には W 型のデータに反応するニューロンと L 型のデータに反応するニューロンを配置した。中間層のニューロン数の設定方法は確立していないが、試行錯誤により 10 と設定した。このネットワーク構成を Fig. 4 に示す。

ニューラルネットへの入力値は 1 近傍の値に正規化することが好ましい。炉頂温度は 100°C~600°C 程度の温度域であるので、ニューラルネットへの入力は炉頂温度を 1 000 で割り、正規化した。また、出力値は 0 と 1 の間の値をとるので、教師信号はニューロンが反応している場合には 0.8、反応していない場合には 0.2 と定義した。

収束判定条件は教師データと出力の差の最大値で定義した誤差ノルムが 0.001 以下とした。

Fig. 5 に各繰返し回数における誤差ノルムを示す。学習により誤差ノルムは単調に減少し、繰返し回数 228 回で収束は完了した。

Fig. 6 に学習後のニューラルネットによる日平均データの認識結果例を示す。各データは目視による判断と良好な対応のつく結果を出力している。Fig. 7 に出力層のニューロンの値を時系列的に表示した。この期間の中では、10 月下旬に L 型を指向するよう装入方法を変更したが、ニューラルネットによりその効果を確認することができる。また Fig. 7 より L 型と W 型の各認識度合いは相反しており、競合していない。すなわち W 型の認識度合いを炉頂温度分布の指標として用いることができ、他の操業データや炉況との関係を解析することができます。

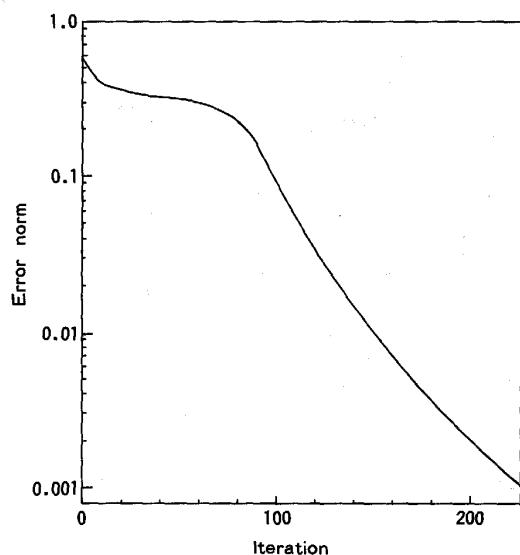


Fig. 5. Relationship between iteration time and error norm in teaching process.

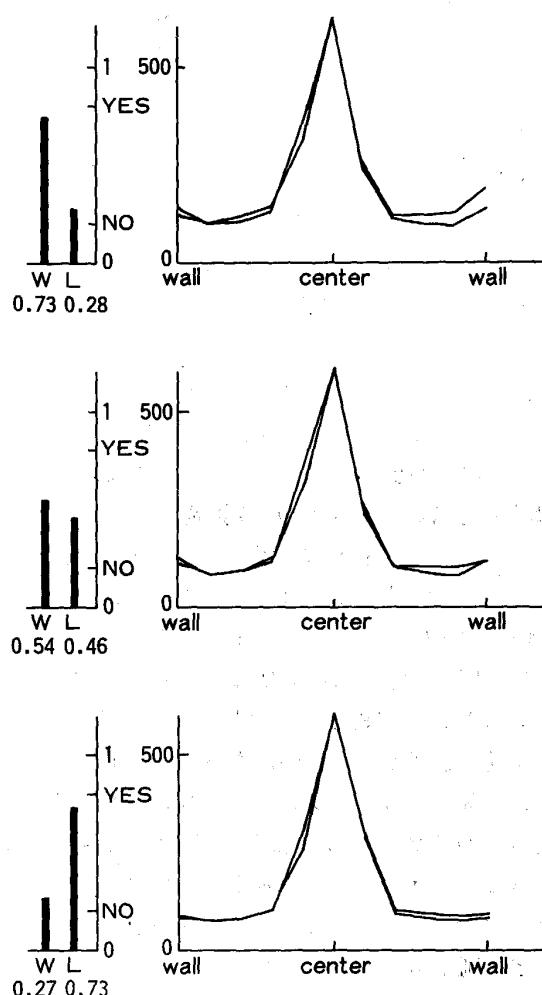


Fig. 6. Example of recognition results of top gas temperature distribution using neural network.

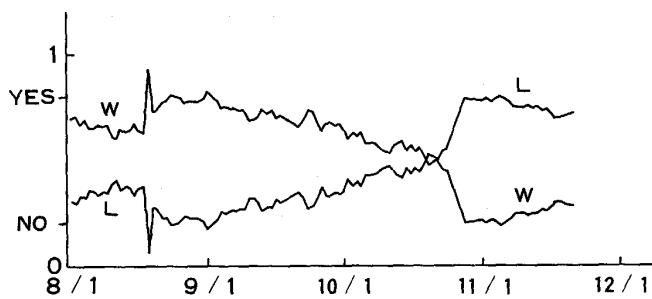


Fig. 7. Transition of top gas temperature distribution recognized by neural network.

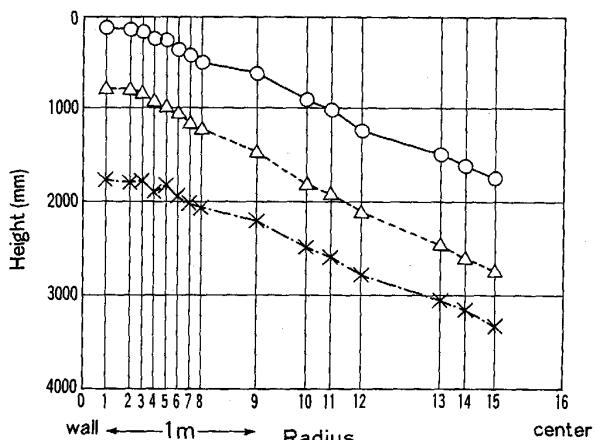


Fig. 9. Example of measured burden profile.

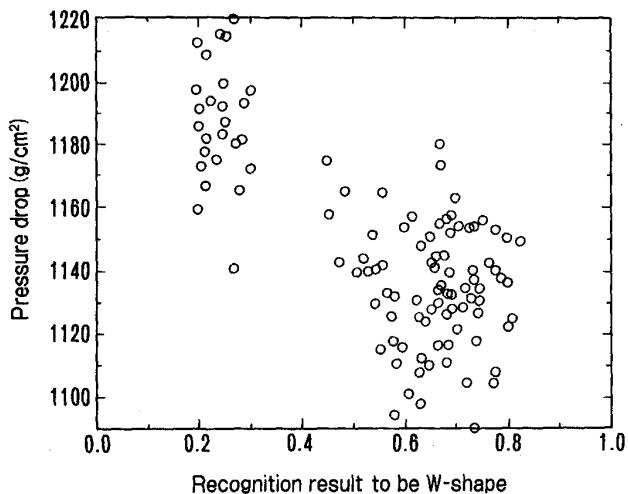


Fig. 8. Relationship between pressure drop and recognized temperature distribution.

きる。Fig. 8 に W 型の認識度合いと圧力損失（送風圧と炉頂圧の差）との関係を示す。炉頂温度分布が W 型の方が圧力損失が少ないという関係が確認できた。

3・2 炉頂装入物プロフィールの認識

神戸 3 高炉では Fig. 9 に示すように半径方向 15 点の各測定ポイントで装入物プロフィールを測定している。ここで炉壁周辺にはプロフィールが水平となるフラット部がある。炉況安定化には適切なフラット部領域の形成が有効であることが知られており⁶⁾、このためにまずフラット部長さを認識する必要がある。しかし測定値をプロットしてもなめらかなプロフィールとはならず、従来は操業者が目視でフラット部長さを判断せざるを得なかつた。ここでは、ニューラルネットによるフラット部長さの認識を検討した。ここで、ニューラルネットは壁側からどの測定ポイントまでフラットであるかを出力するものとした。

認識対象はフラット部長さであり、プロフィールの各部がフラットであるか否かの認識ができればよい。そこ

で、測定データは 1 測定ポイント（壁側）を 0、15 測定ポイント（中心部）を 1 と正規化した。学習のためのデータは、前述したように測定データから選択することは困難であるので、Fig. 10 に示すように 8 種類のデータを人工的に作成した。①のデータはフラット部がないことを表し、②～⑧の各データは、それぞれ 2～8 測定ポイントまでフラットであることを表している。このようになめらかなプロフィールデータを人工的に作成することにより、各フラット部長さに対応する学習用データを明確に定義することができる。対応する教師データは Fig. 10 の中に記したようにフラット部に対応するニューロンが反応する（0.8 を出力する）と定義した。

ネットワーク構成は 3 層とし、ニューロン数は入力層 15、中間層 10 とした。収束判定のための誤差は前回と同様、教師データと出力値の差の最大値で判断した。収束判定の閾値は 0.01 とした。

学習において、本データにバックプロパゲーションアルゴリズムを適用するだけでは局所最適値に陥り学習が進まなくなるので、教師データを順次変更しつつ学習を進める方法³⁾を採用した。

学習したニューラルネットによる認識結果と専門家の目視結果を比較した結果、フラット部長さが短い場合と長い場合は各認識結果はよく一致しているが、中間的な長さの場合はニューラルネットによる認識は目視よりも短い値となる。目視による認識結果との対応を検討するために、ニューラルネットの認識結果に(1)式で示す m 次多項式の補正項を加えた。ここで、 r と s はニューラルネットの認識結果とその補正值を表す。

$$s = r + (a_0 + a_1 \cdot r + a_2 \cdot r^2 + \dots + a_m \cdot r^m) \dots (1)$$

補正項の係数は種々のデータに対する目視による認識結果 h と補正值 s との誤差分散 σ ((2)式) が最小となる

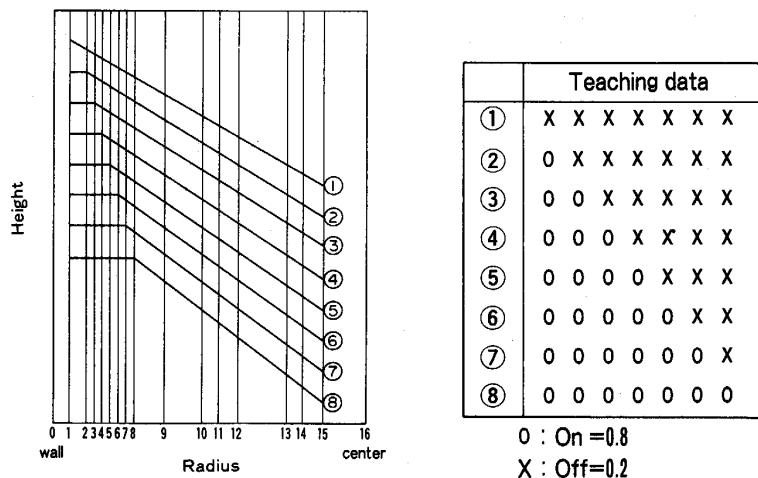


Fig. 10. Input pattern data sets and corresponding teaching data for recognition of burden profile.

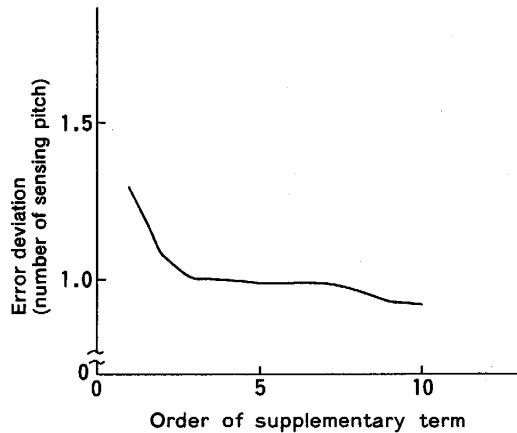


Fig. 11. Estimation error deviation against the order of supplementary term.

よう最小自乗法を用いて計算した。

$$\sigma = \sqrt{\sum_i^n (s_i - h_i)^2 / n} \dots \dots \dots \dots \quad (2)$$

補正項の次数と誤差分散 σ との関係を Fig. 11 に示す。Fig. 11 より、補正項の次数は 3 で十分である。また、誤差分散は 1 測定ポイント未満 (≈ 90 mm) であり、ニューラルネットによる認識結果が目視結果をよく再現している。Fig. 12 に認識例を示す。

なお、本検討では、ニューロンが反応しているか否かのデジタル的な表現をした。別途、出力層を 1 ニューロンとし、教師データをフラット部長さに対応するアナログ値とする方法も検討したが、本方法の方が人間による認識との対応が良好であった³⁾。これはニューロンの S 字型の非線形特性のためにほとんどの場合 0 または 1 の近傍の値を取り、デジタル的な振舞いをしやすいためと考えられる。

3・3 今後の課題と展望

ニューラルネットを高炉データの認識に適用し、従来

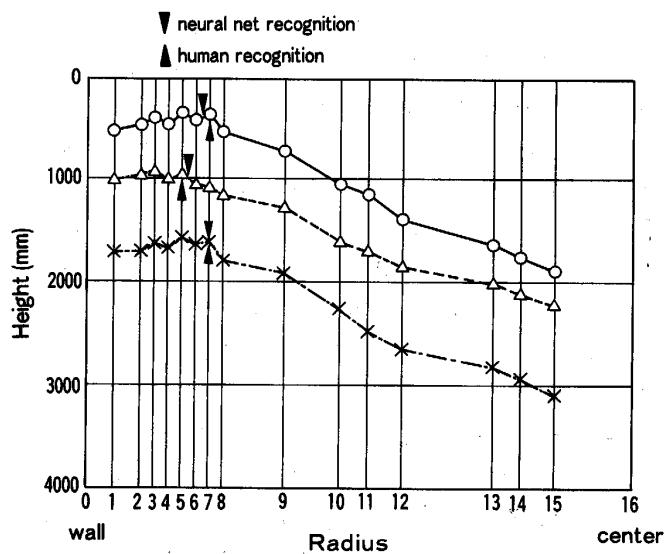


Fig. 12. Comparison of recognition results between neural network and human expert.

人間により認識していた分布データを客観的かつ定量的に認識できることを確認した。

ニューラルネットに関する今後の課題としては、まず学習方法の改善がある。バックプロパゲーションアルゴリズムは学習に多くの計算を要したり、また局所最適値に陥り学習に失敗する場合もある。この問題に対しては学習データの設定方法⁴⁾⁷⁾、学習アルゴリズムの改善^{8)~11)}、結合荷重の初期値の設定方法¹²⁾など研究は進められている。次に、大規模な問題に対しては学習用データの設定が困難になる。蓄積されたデータから学習用データを自動的に選択する技術も必要になると思われる。また、学習後のニューラルネットが入力した信号のどの特徴をとらえているかが解析できれば、新たな知識獲得の手段になるだろう。

現在、高炉の診断や操業のエキスパートシステムが活

発に開発されている。ニューラルネットによる認識結果はエキスパートシステムに対する入力情報になりうるし、認識結果と他の計測値との解析により新たな知識獲得が可能になるだろう。従来のエキスパートシステムは論理的な判断を行い、ニューラルネットは直感的判断を行う。これらの技術を融合することによりより知的なシステムの構築が可能になると思われる。

4. 結 言

本研究では、ニューラルネットの高炉データのパターン認識問題への適用について検討した。本検討には認識問題に有効であるとされているバックプロパゲーションタイプのニューラルネットを用いた。

ニューラルネットの学習用データは、実データから選択する方法と人工的に作成する方法とを用いた。前者は実データから学習用データを抽出できる場合に有効であり、炉頂温度分布の認識に用いた。また後者は認識する基準は明確であるが実データから学習用データの抽出が困難な場合に有効であり、炉頂装入物プロフィールにおけるフラット部長さの認識に用いた。いずれの場合も学習によりニューラルネットが構成でき、測定データに対して人間による判断と良好に対応する認識結果を得ることができた。

ニューラルネットを用いると、従来操業者が主観的に判断していた分布データの認識を客観的、定量的に行うことができる。また従来試行錯誤的にデータの特徴を指數化したのと異なり、学習アルゴリズムにより容易に認識システムを構築することができる。このように分布データの定量的な認識が可能になることにより、これら分布データ間の関係や炉況との関係の解析が容易になり、高炉操業に関する知識獲得に活用できる。また、エキスパートシステムへの入力情報の自動作成に活用することもできる。

今後、ニューラルネットに関しては、学習データの設定方法の確立と学習アルゴリズムの高速化が課題である。

Appendix

ニューロン i における入力、出力を X_j, Y_i とするとき、これらの関係は膜電位と呼ばれる内部状態量 Z_i とシナプスの結合荷重 W_{ij} を用いて(1), (2)式で記述

する。

$$Z_i = \sum_j W_{ij} \cdot X_j \quad (1)$$

$$Y_i = f_i(Z_i) \quad (2)$$

また(2)式における非線形な閾値関数 f は通常(3)式で記述する。

$$f(X) = 1 / \{1 + \exp(-\beta X + \theta)\} \quad (3)$$

ニューラルネットにおけるニューロン間の結合荷重 W_{ij} は以下に示す学習により決定する。まず乱数により荷重の初期値を仮設定する。このニューラルネットに学習用データを入力する。この入力に対する出力層の出力値 Y_i と、対応する好ましい出力値 T_i (教師データ) との誤差 E を(4)式で定義する。

$$E = 1/2 \cdot \sum_i (Y_i - T_i)^2 \quad (4)$$

この誤差が少なくなるように、最急勾配法で荷重を修正する。すなわち荷重の修正量を(5)式とする。

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E}{\partial W_{ij}} \quad (5)$$

(5)式の偏微分を整理することにより、(6)式が得られる。ここで m は層の番号を表す。なお、(6)式における一般化誤差 δ_{mi} は、出力層に対しては(7)式により計算でき、また出力層以外の層に関しては(8)式により計算できる。

$$\Delta W_{ij} = \eta \cdot \delta_{mi} \cdot X_j \quad (6)$$

$$\delta_{mi} = f'_i(Z_i) \cdot (T_i - Y_i) \quad (7)$$

$$\delta_{mi} = f'_i(Z_i) \cdot \sum_k \delta_{m+1,k} W_{ki} \quad (8)$$

文 献

- 1) D. E. RUMELHART, J. L. McCLELLAND and the PDP Research Group: *Parallel Distributed Processing*, Volume 1, 2 (1986) [MIT Press]
- 2) 大塚喜久, 田村直樹, 松田浩一, 小西正躬: 材料とプロセス, 2 (1989), p. 993
- 3) 平田達朗, 山村耕造, 橋口宗之, 森本忍, 高田寛: 材料とプロセス, 2 (1989), p. 992
- 4) 大塚喜久, 布木明, 小西正躬, 門口維人: 自動制御連合講演会, 32 (1989), p. 3019
- 5) W. PITTS and W. S. MACCULLOCH: *Bull. Math. Biophysics*, 5 (1943), p. 115
- 6) 稲葉晋一, 沖本憲市, 西田功, 矢場田武, 高田稔: 神戸製鋼技報 R & D, 34 (1984) 4, p. 42
- 7) 益岡竜介: 信学技報, 88 (1989) 466, p. 121
- 8) 飯国洋二, 酒井英昭, 得丸英勝: システム制御情報学会研究発表講演会, 33 (1989), p. 3012
- 9) 馬場則夫, 鳥取武司: システム制御情報学会研究発表講演会, 33 (1989), p. 3009
- 10) T. P. VOGL, J. K. MANGIS, A. K. RIGLER, W. T. ZINK and D. L. ALKON: *Biol. Cybern.*, 59 (1988), p. 257
- 11) R. A. JACOBS: *Neural Networks*, 1 (1988), p. 295
- 12) 二木徹: 信学技報, 53 (1988), p. 55