ニューラルネットワークによる高炉炉頂部の 装入物プロフィールの認識*

大塚喜久**・小西正躬**・門口維人***

Recognition of Burden Profile at the Top of Blast Furnace Using Neural Network Model*

Yoshihisa OTSUKA**, Masami KONISHI** and Korehito KADOGUCHI***

Recently, neural network models have been applied to solve various problems and multi layer neural network with back propagation algorithm is shown to be useful for pattern recognition. In this paper, a recognition system for burden profile at the top of blast furnace using the neural network is described. Here, two problems of the neural network are studied. One is how to escape from local minima in learning process. For this purpose, a new method which updates the teaching data from simple to complicated one is proposed, and the effectiveness of the method is shown. Another problem is the selection of teaching data in recognition of scaler value, such as length. For this problem, two teaching data, which we call digital and analog type teaching data, are compared, and the digital type teaching data is shown to be better for the recognition of blast furnace data.

1. はじめに

高炉は大規模な分布系のプロセスである。したがって多数のセンサから得られる高さ方向や半径方向などの各種計測量の特徴的な分布パターンを適正に認識し、炉況の診断や制御に反映することが操業上重要である。従来これらのパターンは、熟練者が多数のデータを観察して、そのデータにどのような特徴があるかを把握し、その特徴が明確に表われている典型的なパターンを設定する。操業時には、時々刻々に得られるデータがどの典型パターンに属するかを目視判断し、そのパターンに対応する操業を行ってきた。このような目視によるパターン認識では客観性に欠けるため、計算機によりパターンを指数化することも試みられてきた。しかし、熟練者はデータにノイズや欠損が含まれていても、全体の傾向から直感的にパターンを認識しているが、そのロジックを抽出し

てアルゴリズムを構築することは困難な場合が多い。したがって、現状では単純なパターンの指数化が実用化されるにとどまっている。

近年、研究がさかに行われているニューラルネットは、神経回路網を参考にしたモデルであり、分布データの学習と認識を特徴としている。とくに、バックプロパゲーションアルゴリズムを用いた階層型ネットワーク¹⁾が多くのパターン認識問題に適用され^{2,3)}、その有効性が示されているが、下記の問題が依然として残されている。

第一に、バックプロパゲーションアルゴリズムでは学習の段階で局所最適解に陥り、学習が進まなくなる場合がある。第二に、階層型ネットワークは分布データを複数のカテゴリーに識別するのに適しているが、プロセスデータの認識では大きさや長さなどの連続値を認識するニーズも多い。この場合、出力値を量子化して複数のカテゴリーに識別するか、ネットワークからの出力を0から1の連続値として扱うかを選択する必要がある。

本研究では、高炉（溶鉱炉）の炉頂における装入物堆積プロフィールを、ニューラルネットにより認識する技術を開発した。この具体例に関し、第一の問題点である学習における局所最適解からの回避については、教師データを順次変更しつつ学習を進める方法を提案し、その

* 原稿受付 1992. 3. 23

** ㈱ 神戸製鋼所 電子技術研究所 KOBE STEEL, LTD., Electronics Research Laboratory; 1-5-5, Takatsukadai Nishi-ku, Kobe, Hyogo 651-22, JAPAN

*** ㈱ 神戸製鋼所 鉄鋼事業本部 KOBE STEEL, LTD., Iron & Steel Division, 1-3-18 Wakinocho-cho, Chuo-ku, Kobe, Hyogo 651, JAPAN

Key Words: neural network, back propagation, recognition, learning, blast furnace.

有効性を示す。また第二の問題点である連続値の認識については、高炉のデータ認識問題について、デジタル方式とアナログ方式の2種類の教師データを検討し、ニューラルネットによる認識結果と人間の目視認識結果とを比較することにより適切な教師データを検討した。

2. 問題の設定

2.1 高炉装入物堆積プロフィール

高炉は大規模な分布系であり、1基の高炉に数百のセンサが設置されており、操業者はこれら多数のセンサから得られる分布データを適切に認識しながら操作を行っている。これらの分布データの一つに、炉頂部における装入物の堆積プロフィールがあり、これは高炉の安定操作を維持する上で非常に重要な分布データである。Fig. 1に重垂式のプロフィールメータによる装入物堆積プロフィールの測定方法を示す。この測定は炉頂部から原料の鉄鋼石やコークスを装入した直後に行われ、測定装置であるランスが炉壁より中心部に向かって伸びてゆき、あらかじめ設定された半径位置において重垂を降下して装入物の表面までの距離を測定する。神戸第3高炉では半径方向15点の測定地点で装入物の堆積高さ位置を測定し、その分布プロフィールを把握している。ここで、最も壁側の測定地点を1ポイント、最も中心寄りの測定地点を15ポイントと呼ぶことにする。Fig. 2では測定例として三つの堆積プロフィールを高さ位置をずらして表示している。Fig. 2に示すように、高炉原料の装入時には、炉況安定化を目的として壁近傍に堆積形状が水平になる領域（フラット部）を形成させている。このフラット部長さの認識と調節が重要であるが、測定データはノイズによるばらつきが多く、従来は認識の自動化が困難であり、操業者が目視でフラット部長さを判断せざるをえなかった。そこで、ニューラルネットによるフラット

Fig. 1 Measurement of burden profile at the top of blast furnace

Fig. 2 Example of measured burden profile

部長さの認識技術を開発した。ここで、ニューラルネットは測定データの1ポイントを0、15ポイントを1と正規化したデータを入力して、壁側からどの測定ポイントまでがフラットであるかを認識するものとした。

2.2 認識用学習データ

本節ではネットワークの学習に用いたデータについて説明する。なお、学習に用いるデータのうち、ネットワークへの入力に用いるデータを学習用入力データ、ネットワークの出力と比較するデータを教師データ、学習用入力データと教師データをあわせて学習用データと呼ぶことにする。

個々のプロフィール測定データは、操業者の主観により認識結果が異なるので、学習のための基本パターンを測定データから設定することが困難であった。そこで、学習用入力データとしてFig. 3(a)に示す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ポイントまでフラットであることを表わしている。教師データはFig. 3(b)に示すAとBの2種類を検討し

Fig. 3 Input pattern data sets and corresponding teaching data for recognition of burden profile

た。ここで、データ A は出力層のニューロン数を 7 とし、フラット部に対応するニューロンが On 状態、その他のニューロンが Off 状態となると定義するもので、デジタル出力方式と呼ぶことにする。一方、データ B は出力層のニューロン数を 1 とし、フラット長さに対応する値を出力すると定義するもので、アナログ出力方式と呼ぶことにする。

次にデジタル出力方式の教師データにおける On および Off の値について、まず On = 1.0 および Off = 0.0 の場合を考察する。出力ユニット i において、入力を x_j 、結合荷重を w_{ij} 、閾値を θ_i 、出力を y_i とすると、 y_i は

$$z_i = \sum_j w_{ij} x_j - \theta_i \quad (1)$$

$$y_i = \frac{1}{1 + e^{-z_i}} \quad (2)$$

で計算される。ある学習データに対して出力ユニット i の教師データが 1.0 であった場合、 $0 < y_i < 1$ であるから y_i は 1.0 とはなりえず、収束判定基準を満たす範囲で、教師データである 1.0 に近い値で学習は終了する。学習終了時の y_i を y_i^* 、対応する z_i を z_i^* としよう。データを認識する際に、 z_i の値が z_i^* よりも大きな値となるほど、出力 y_i は y_i^* よりも教師データ 1.0 に近い値となる。すなわち z_i の値が z_i^* の値よりも大きくなる方向に、認識対象のデータが学習したデータから遠ざかれば遠ざかるほど、出力値 y_i は教師データである 1.0 に近づいてしまう。しかし、ニューラルネットを用いてデータの認識を行う場合、学習に用いたデータと類似したデータからは教師データに近い値が、学習に用いたデータと大きく異なるデータからは教師データと大きく異なる値が出力されることが好ましい。特にプロセスデータの認識ではプロセスの経時変化やノイズなどにより、学習に用いたデータと大きく異なる異常データが測定されることがあり、これらのデータに対しては教師データと大きく異なる値が出力されねばならない。そこで本研究では、 z_i の値が学習したデータの値と異なれば、出力値も教師データとは異なるように、On = 0.8, Off = 0.2 と設定した。

学習の収束判定には、ネットワークの出力値と教師データの差の最大値を用いた。すなわち、 y_{pq} および t_{pq} を学習データ p における出力ユニット q の出力値および教師データとし、(3) 式に示す収束判定のための誤差ノルム En が閾値以下となった場合に収束したと判断した。

$$En = \max_p \max_q |y_{pq} - t_{pq}| \quad (3)$$

この収束判定により、学習データに対する出力値の取得範囲が明確となり、データ認識時に出力値がこの範

囲から逸脱するほど、学習したデータとは異なったデータであると判断できる。また、収束判定の閾値は、データ A は出力をデジタル量として取り扱うので、ある程度の誤差は許容されると判断して 0.01 に、またデータ B では出力をアナログ量として取り扱うので、データ A よりも高精度な 0.001 を閾値とした。なお、収束を判定するための誤差ノルム En は (3) 式で定義したが、結合荷重の変化量を計算するための出力誤差 E は通常用いられている (4) 式で定義した。

$$E = \sum_p \sum_q (y_{pq} - t_{pq})^2 \quad (4)$$

3. 学習方法の検討

3.1 バックプロパゲーションアルゴリズムによる学習

ネットワークにおけるニューロン数は入力層で 15、中間層で 10 とした。また、出力層のニューロン数は教師データ A に対しては 7、教師データ B に対しては 1 とした。

バックプロパゲーションアルゴリズムの最も基本的なアルゴリズムに従うと、出力誤差 E に対し、 k 層のニューロン i と $k-1$ 層のニューロン j の間のシナプス結合荷重 $w_{ij}(k)$ の修正量は

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

で与えられる。ここで η は結合荷重の修正量のゲインを表わす正の常数である。

まず、対象とする Fig. 3 の教師データ A と B に対して (5) 式を用いて学習を行ったところ、教師データ B は容易に収束したが、教師データ A は収束しなかった。学習係数 η を 4.0 とした場合の学習の繰り返し回数に対する誤差ノルムの推移を Fig. 4 に示す。(5) 式のバックプロパゲーションアルゴリズムは、非線形最適化に最急降下法を用いているので、教師データ A の学習のように局所最適解におちいり学習が進まなくなる場合があることが知られている。このような非線形最適化問題において、局所最適解を回避する方法として確率的なゆらぎを導入する方法が知られている。この方法の一つであるシミュレーティッドアニーリング法⁹⁾は、冶金分野における焼き鈍しを模擬した手法で、十分に長い時間をかければ確率 1 で最小値が求まることが知られている。ニューラルネットワークの学習でも種々の確率的なゆらぎを用いる方法^{5)~7)}が提案されている。松葉⁵⁾は (6) 式に示すように (5) 式に確率的なゆらぎ $\xi_{ij}(k)$ を加えることにより、シミュレーティッドアニーリング法と等価になり、学習性能が向上することを示している。

Fig. 4 Error behavior in learning of blast furnace data by conventional learning algorithm

Fig. 5 Error behavior for data A by conventional algorithm with stochastic perturbation

$$\Delta w_{ij}(k) = -\eta \frac{\partial E}{\partial w_{ij}(k)} + \xi_{ij}(k) \quad (6)$$

ここに $\xi_{ij}(k)$ は、 s を繰り返し回数として平均値 0、分散 $T(s)$ の白色ガウス分布ノイズを表わす。繰り返し計算を進めるにしたがって (7) 式で示すように分散 $T(s)$ の値を徐々に小さくすることにより、焼き鈍しにおける温度を徐々に下げる過程を模擬する。

$$T(s) = \frac{\beta^2}{\ln(1+s)} \quad (7)$$

この確率的なゆらぎを導入する方法を用い、(5) 式の基本アルゴリズムでは収束しなかった教師データ A の学習を行った。種々の学習パラメータによるケーススタディの中で、最も誤差ノルムが減少した $\eta = 4.0$, $\beta = 0.001$ とした際の繰り返し回数に対する誤差ノルムの推移を Fig. 5 に示す。確率的なゆらぎを導入することにより、10 万回の繰り返しで誤差を約 0.2 から 0.03 まで減少させる効果はあったが、収束判定の閾値として設定した 0.01 まで減少するには至らなかった。

なお、前回の修正量の定数倍を加速度項として (5) 式に付加する方法¹⁾ も知られているが、教師データ A に対しては効果がなかった。

このように、教師データ B の学習は容易に終了するのに対し、教師データ A の学習が進まない理由は次のように考えられる。学習用入力データの内、隣りあうデータの差は数値としてみれば微小である。この微小な差に対し、データ B における教師データの差は 0.1 と少ないが、データ A では教師データは On から Off へと 0.6 もの大きな差が設定される。従って微小な入力の差に対し、出力値を多く変換させる必要のある教師データ A の学習が難しくなっている。

上記のアルゴリズムでは学習を完了できなかった教師データ A の学習方法として、筆者らは以下の学習方法を検討した。

3.2 局所解を回避する学習方法の検討

人間が学習をする場合には、基本的な問題を学習してから応用問題や例外処理に取り組んだりするなど、学習を効率的に行うために学習問題の設定に工夫を凝らしている。バックプロパゲーションアルゴリズムによる階層型ネットワークは、必ずしも人間の脳を正確にモデル化しているとはいえないが、教師データの与え方が学習結果に影響することは考えられる。本節では教師データを順次更新しながら学習を進めることにより局所最適解を回避する方法を提案する。この方法の説明には 1 入力 1 出力関数の同定問題を例として用いる。

階層型ネットワークでは、学習用入力データと対応する教師データをまず設定する。これらの入出力の関係である学習データが単純であれば学習が進みやすい場合が多く、また複雑であれば学習が進みにくい場合が多い。さらに学習用入力データが同一でも、教師データによって学習データは単純にも複雑にもなりえる。 x を入力、

Fig. 6 Input and teaching data for 1 dimensional data

Table 1 Transient teaching data for 1 dimensional data

Data number	Input data	Teaching data						
		D_1	D_2	D_3	D_4	D_5	D_6	D_7
1	0.1	0.8	0.7	0.6	0.5	0.4	0.3	0.2
2	0.2	0.8	0.8	0.8	0.8	0.8	0.8	0.8
3	0.3	0.8	0.7	0.6	0.5	0.4	0.3	0.2
4	0.4	0.8	0.8	0.8	0.8	0.8	0.8	0.8
5	0.5	0.2	0.2	0.2	0.2	0.2	0.2	0.2
6	0.6	0.2	0.2	0.2	0.2	0.2	0.2	0.2
7	0.7	0.2	0.2	0.2	0.2	0.2	0.2	0.2
8	0.8	0.2	0.2	0.2	0.2	0.2	0.2	0.2
9	0.9	0.2	0.3	0.4	0.5	0.6	0.7	0.8

y を出力とする 1 入力 1 出力の関係を学習する場合を例にとると、Fig. 6 (a) は (b) に比べて入出力関係が単純であり、また学習も進みやすい。すなわち、パラメータである結合荷重に対する誤差の曲面を考えると、単純な学習データでは単峰性に近く、複雑な学習データでは多峰性の複雑な形状になっていると考えられる。

次に同一の学習用入力データに対して単純および複雑な二つの教師データと、それらを生挿する複数の教師データを考える。例えば Table 1 の D_1 と D_7 は、Fig. 6 の (a) と (b) を表わしており、 D_i ($i = 2 \sim 6$) はこれらを 6 等分に生挿した教師データになっている。ここで隣りあう教師データ D_i と D_{i+1} とに着目すると、教師データの差は少ないので、各々が形成する誤差曲面は互いに似ていると考えられる。したがって、 D_{i+1} に対する大域的最適解は D_i の大域的最適解の近傍にあり、 D_i に対する最適解を初期値とすると D_{i+1} に対する最適解が容易に学習できることが期待できる。

Fig. 7 Flow chart of teaching data updating

以上の考えから、学習が困難な教師データ D_p の学習方法として、Fig. 7 のフローチャートに示す学習方法を提案する。すなわち、まず D_p に類似して単純な教師データ D_1 を設定する。 $D_p = D_{n+1}$ として、 D_1 と D_{n+1} を内挿する $n-1$ 個の過渡的な教師データ D_i ($i = 2 \sim n$) を作る。 D_1 に対する学習結果の結合荷重を w とする。 D_{i-1} の学習結果の結合荷重を初期値として D_i を学習して、その結果を w に置き換える操作を $i = 2 \sim n+1$ ままで繰り返す。

Fig. 7 の学習方法の効果を確認するために、本方法を Table 1 の学習データに適用した。ここでは、 D_7 を最終的に学習する教師データを D_p とし、 D_1 から順次学習を行った。ネットワークのニューロン数は、入力層と出力層が 1、中間層は 12 とした。また、学習アルゴリズムは (5) 式を用い、学習係数 η は 4.0 とした。Fig. 7 の学習方法を適用した場合と Table 1 の D_7 を直接学習した場合の学習回数に対する誤差ノルムを Fig. 8 に示す。ここで収束判定の閾値は 0.01 とした。Fig. 8 における D_1 のグラフは教師データを D_1 とした学習における誤差ノルムの推移を示しており、この学習は 48,077 回で誤差ノルムが収束判定の閾値である 0.01 以下となった。続いて教師データを D_2 に切り換えて学習を行った際の誤差ノルムの推移を D_2 のグラフは表わしている。

Fig. 8 Comparison between proposed and conventional method in error convergence behavior

教師データを切り換えることにより誤差ノルムは一時的に増えるが、 D_2 のデータは29,433回で収束した。すなわち D_1 の学習からの累計77,510回で学習が終了した。以後、教師データを D_3 から D_7 へと更新し、 D_1 の学習からの累計93,785回で目標とする教師データ D_7 の学習が完了した。一方、目標とする D_7 のみを学習した場合にはFig. 8に示すように学習が進まず、今回提案した教師データを順次更新してゆく方法の有効性が確認できた。

本手法を学習が困難な教師データ D_p の学習に適用する場合には、単純な教師データ D_1 と過渡的な教師データ D_i を設定する必要がある。これらを設定する汎用的な方法は確立できていないが、経験的には以下の方法が有効であった。

まず、 D_1 を教師データ D_p から設定する方法として、以下の2種類の方法が有効であった。その一つの方法は、十分な学習回数後に出力値が変化しなくなり学習が進まなくなった場合に有効である。この場合は、この変化しなくなった出力値を教師データ D_1 と設定する。もう一つの方法は、学習データを m 種類($m \geq 3$)のカテゴリーに分類する問題で学習が進まなくても、複数のカテゴリーを統合して分類するカテゴリーの種類を少なくすると学習が進む場合に有効である。この場合は、データを n 種類($n < m$)のカテゴリーに分類する教師データ

として単純な教師データ D_1 を設定する。

次に過渡的な教師データ D_i は、 D_1 と D_p を内挿して設定すればよい。ただし、 D_1 と D_p を単純に等間隔に内挿するとFig. 8に示すように初期教師データ更新時に多くの学習回数を要するので、経験的には初期の教師データの更新量は少なく、後半では更新量を多くとると効率的な学習が行えた。しかしこの更新量の設定方法については、より多くの事例での検討が必要あり、今後の課題である。

また、今回は最適化アルゴリズムとして最急降下法であるバックプロパゲーションアルゴリズムを用いたが、本方法は教師データの設定に関するものであるので最適化アルゴリズムとは独立である。すなわち初期値を用いる任意の探索型の最適化アルゴリズムを組み合わせることが可能である。

3.3 提案方法の高炉データへの適用

バックプロパゲーションアルゴリズムによる学習では収束しなかった教師データAに対し、Fig. 7の教師データの更新アルゴリズムを用いた。実際の教師データの更新方法はTable 2に示すように設定した。ここでは、まず基本パターンを表わす単純な教師データはフラット部が短い長いかの識別問題として設定した。すなわち、フラット部が短い①～④の学習入力データに対してはすべての教師データを0.2とし、⑤～⑧に対しては0.8とした。つぎに、この教師データをFig. 3の教師データAに近づけて過渡的な教師データを設定する。学習を効率的に行うために、Table 2では初期の教師データの更新量は0.02と少なく、後半では0.2と多く設定した。学習アルゴリズムは(5)式で、学習係数 η は4.0とした。Fig. 9に示すように、Fig. 7のアルゴリズムを適用することにより、教師データAを学習することができた。

Table 2 Transient teaching data for recognition of blast furnace data

Data number	Teaching data A							
①	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2
②	Δ	0.2	0.2	0.2	0.2	0.2	0.2	0.2
③	Δ	Δ	0.2	0.2	0.2	0.2	0.2	0.2
④	Δ	Δ	Δ	0.2	0.2	0.2	0.2	0.2
⑤	0.8	0.8	0.8	0.8	∇	∇	∇	∇
⑥	0.8	0.8	0.8	0.8	0.8	∇	∇	∇
⑦	0.8	0.8	0.8	0.8	0.8	0.8	∇	∇
⑧	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.8

Δ : 0.2 $\rightarrow$ 0.22 $\rightarrow$ 0.24 $\rightarrow$ 0.27 $\rightarrow$ 0.3 $\rightarrow$ 0.4 $\rightarrow$ 0.6 $\rightarrow$ 0.8

∇ : 0.8 $\rightarrow$ 0.78 $\rightarrow$ 0.76 $\rightarrow$ 0.73 $\rightarrow$ 0.7 $\rightarrow$ 0.6 $\rightarrow$ 0.4 $\rightarrow$ 0.2

Fig. 9 Error behavior in learning of blast furnace data A by proposed method

3.4 教師データの評価とその考察

教師データ A および B を学習したニューラルネットは、測定した堆積形状において炉壁からどの測定ポイントまでがフラットであるかを認識することができる。Fig. 10 に教師データを A を学習に用いたニューラルネットによる認識結果と熟練者の目視による認識結果の例を示す。ここで、図中の矢印は認識したフラット部の先端位置を示している。すなわちこれら三つの測定データに対し、ニューラルネットは上から 7 ポイント、4 ポイント、7 ポイントまでフラットであると認識し、熟練者

Fig. 10 Comparison of recognition results between neural network and human expert

は 7 ポイント、5 ポイント、7 ポイントまでフラットであると認識した。また、これらのデータに対して教師データ B で学習したニューラルネットは上から 7 ポイント、3 ポイント、6 ポイントまでがフラットであると認識した。

多数の測定データの認識結果を用いて教師データ A および B の評価を行った。すなわち熟練者の目視による認識結果を真として、各教師データを用いて学習したニューラルネットと目視との認識結果の差の分散で教師データ A および B を評価した。ここで、測定データ i に対し、教師データ A により認識したフラット長さを r_{ai} (測定ポイント)、教師データ B による認識結果を r_{bi} 、熟練者の目視による認識結果を h_i とするとき、教師データ A および B による差の分散を (8) 式および (9) 式で定義した。

$$\sigma_a = \sqrt{\frac{\sum_i (r_{ai} - h_i)^2}{n}} \quad (8)$$

$$\sigma_b = \sqrt{\frac{\sum_i (r_{bi} - h_i)^2}{n}} \quad (9)$$

(8) 式および (9) 式の分散を 39 件の測定データを用いて計算したところ、 σ_a は約 1.3 ポイント、 σ_b は約 1.6 ポイントであった。なお各教師データに対して、収束判定の閾値を一桁精度を上げてても認識結果は同じであった。

教師データ A と B による認識結果の差は次のように解釈することができる。すなわち、各ニューロンは (10) 式で示す閾値関数を用いて入力 x_j から出力 y_i を求めている。

$$y_i = \frac{1}{1 + e^{-(\sum_j w_{ij} \cdot x_j)}} \quad (10)$$

この関数は $0 < y_i < 1$ で S 字型をしているので、 $y_i = 0.5$ の時が x_j に関する微分値が最も大きく、0 または 1 に近づくにしたがって微分値は減少する。したがって、0.5 近辺の出力値も利用しているアナログ出力方式の教師データ B は、閾値関数の微係数の大きな部分を利用して入力 x_j の変動の影響を受けやすく認識精度も落ちる。一方デジタル出力方式の教師データ A では、微係数の小さな領域を利用しているので入力の変動の影響を受けにくく、良好な認識精度が得られたと考えられる。

次に二人の熟練者による堆積プロフィールの認識結果の差を調べた。すなわち、測定データ i に対し、二人の熟練者が目視で認識したフラット長さを h_{pi} (測定ポイント) および h_{qi} とするとき、これらの差の分散を (11)

式で定義した.

$$\sigma_h = \sqrt{\frac{\sum_i^n (h_{pi} - h_{qi})^2}{n}} \quad (11)$$

教師データの評価に用いたデータと同じ39件の測定データを用いて(11)式を計算したところ、 σ_h は約1.1ポイントであった. 教師データAを用いて学習したニューラルネットと熟練者の目視との認識の差の分散 σ_a は、上述したように1.3ポイントであったので、ニューラルネットの認識結果は熟練者の目視による認識結果とほぼ同等であると考えられる.

4. むすび

本研究では高炉装入物の堆積プロフィールをニューラルネットを用いて認識する技術を開発した.

まず、本認識問題は従来法では学習時に局所最適解に陥り学習が進まなくなるので、これを解決する方法として新しく教師データを順次変更しつつ学習を進める方法を提案した. 本方法は学習のための最適化アルゴリズムとは独立であり、種々のアルゴリズムとの組み合わせも可能である. 初期値として用いる単純な教師データと、過渡的な教師データのより汎用的な設定方法が今後の課題として残されている.

つぎに、教師データをディジタル出力として設定する場合とアナログ出力として設定する場合を比較検討し、高炉のデータに対しては前者の方が入力データのばらつきの影響を受けにくい認識ができ、操業者の認識結果と同等の認識結果がえられることを確認した.

なお、エキスパートシステムなどの知能化システムを構築する際に、熟練者の行っているパターン認識などの感応情報をいかにシステム化するかが課題の一つであった. 本研究で得られた知見はニューラルネットの分布データのパターン認識への適用範囲を広げるものであり、高炉のみならず種々のシステムの知能化と省力化に寄与することが期待できる.

参 考 文 献

- 1) D. E. Rumelhart, G. E. Hinton and R. J. Williams : Learning Internal Representations by Error Propagation, Parallel Distributed Processing, Vol. 1, Cambridge, MA, MIT Press, pp. 318~362 (1986)
- 2) 大塚, 田村, 松田, 小西, 門口 : 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 ; 鉄と鋼, Vol. 77, No. 1, pp. 79~84 (1991)
- 3) 小南, 内藤, 鎌田, 浜口, 田中, 遠藤 : ニューラルネット技術による連続鋳造ブレイクアウト予知システム ; 製鉄研究, No. 339, pp. 31~34 (1990)
- 4) S. Kirkpatrick, C. D. Gelatt, Jr. and M. P. Vecchi : Optimization by Simulated Annealing ; Science, Vol. 220, No. 4598, pp. 671~680 (1983)
- 5) 松葉 : バックプロパゲーションによる特徴抽出 ; 数理科学, No. 338, pp. 31~37 (1991)
- 6) 飯国, 酒井, 得丸 : アニールを用いた多層神経回路の学習アルゴリズム ; 第33回システム制御情報学会発表講演会論文集, 3012, pp. 249~250 (1989)
- 7) N. Baba : A New Approach for Finding the Global Minimum of Error Function of Neural Networks ; Neural Networks, Vol. 2, No. 5, pp. 367~373 (1989)