

ニューラルネットワークモデルとその鉄鋼 プロセスへの応用

解説

大塚 喜久*・小西 正躬**

Neural Network Models and Its Applications to Iron and Steel Making Processes

Yoshihisa OTSUKA and Masami KONISHI

1. はじめに

ニューラルネットワークは神経回路網を参考にした数学モデルであり、人間の直感的な認識処理など従来手法では困難な情報処理を計算機上で実現するための有力な手法として期待がかけられている。このモデルは数学的に記述されたニューロン（神経細胞）が多数個つなぎ合わされたネットワーク結合により構成されている。このニューロンの結合方法により種々のネットワークモデルが提案され、それぞれの特徴を生かして組み合わせ最適化問題やパターン認識などの分野に応用されつつある。

本稿では、種々のニューラルネットワークモデルの中からホップフィールドモデル¹⁾、バックプロパゲーションモデル²⁾、自己組織特徴マップモデル³⁾を取り上げ、その概要と鉄鋼業への応用について解説する。

2. ニューラルネットワークモデルとその応用

本節では、まず単一ニューロンの数学モデルについて説明する。続いてニューロン結合のモデルとして代表的な上記3モデルの説明とその応用例について述べる。

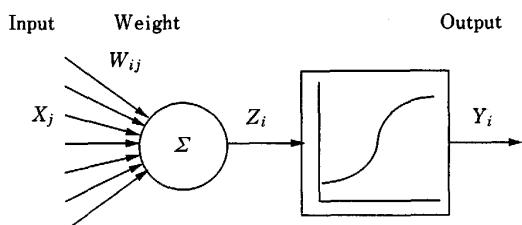


Fig. 1. Configuration of neuron model.

2.1 ニューロンのモデル

現在、多くのニューラルネットワークモデルで用いられている単一のニューロンは Fig. 1 で示すような多入力 1 出力の素子として扱われている。ニューロン j からニューロン i への入力を X_j 、これらのニューロン間の結合荷重を W_{ij} とすると、まず(1)式で示す入力の荷重和を計算し、次に閾値関数と呼ばれる非線形関数の処理を行って出力値 Y_i を求める。閾値関数は通常(2)式で示されるような飽和特性を持つ S 字型の関数が用いられる。

ここで、 θ は閾値である。

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

$$Y_i = \frac{1}{1 + e^{-(Z_i - \theta)}} \dots (2)$$

2.2 ホップフィールドモデル

ホップフィールドモデル¹⁾におけるネットワーク結合は、対称な相互結合となっている。すなわち、ニューロン i と j の結合荷重を W_{ij} とすると、

$$W_{ij} = W_{ji} \dots (3)$$

であるような構造となっている。また、本モデルは Fig. 2 のようにフィードバック結合を含み、各ニューロンの出力は時間とともに変化する。すなわちネットワークへの入力を X_i 、出力を Y_i とすると、各ニューロンの出力は

$$E = -\frac{1}{2} \sum_{i \neq j} \sum_j W_{ij} Y_i Y_j + \sum_i X_i Y_i \dots (4)$$

で定義されたエネルギー関数の値が時間とともに減少するようになる。ネットワークの出力値は飽和特性を持たせてるので、(4)式の値は有界であり、十分に時間が経過すれば(4)式の値が最小値となるような出力値

平成3年3月25日受付 (Received Mar. 25, 1991) (依頼解説)

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

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

Key words : neural network; Hopfield model; back propagation model; self organization model; combinatorial optimization; pattern recognition; coil train; blast furnace; continuous casting.

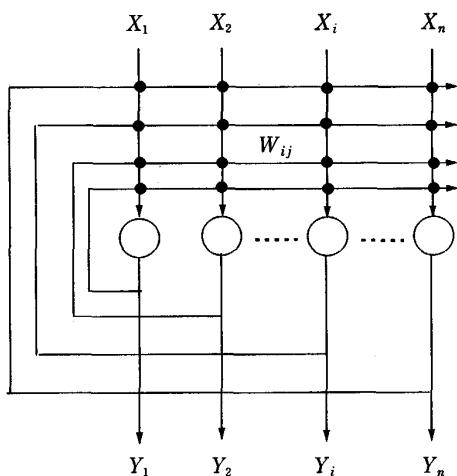


Fig. 2. Configuration of Hopfield model.

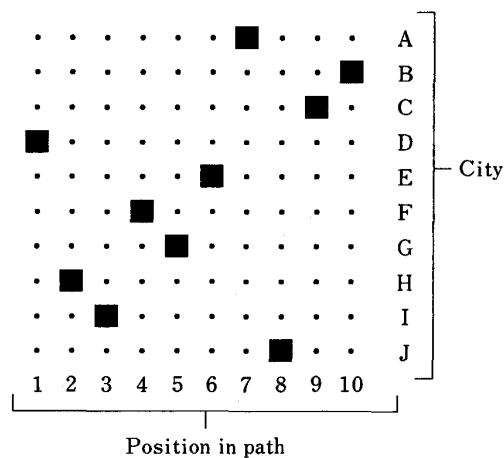


Fig. 3. Neuron outputs which represent the path.

に収束する。すなわちこのネットワークモデルを用いると、(4)式を評価関数とする Y_i に関する最適化問題を解くことができる。

最適化に関する本ネットワークの代表的な適用例¹⁾として巡回セールスマントラム問題がある。これは N 都市を一度ずつ巡って元の都市に戻る最短の経路を求める問題である。この問題を解くためには $N \times N$ 個のニューロンを用意し、このニューロンの 0 または 1 の出力値の組合せにより一つの巡回経路を表現する。Fig. 3 は A~J の 10 都市の巡回路の表現例であり、“.”は 0 を、“■”は 1 を出力しているニューロンを表している。この配列において各行は各都市を、各列は訪れる順番を表している。この問題に対し、各ニューロンの出力値が最適解となるようなエネルギー関数として(5)式が用いられる。

$$\begin{aligned} E = & A \cdot \sum_{x} \sum_{i} \sum_{j} Y_{xi} \cdot Y_{xj} + B \cdot \sum_{x} \sum_{y} \sum_{i} Y_{xi} \cdot Y_{yi} \\ & + C \cdot (\sum_{x} \sum_{i} Y_{xi} - N)^2 \\ & + D \cdot \sum_{x} \sum_{y} \sum_{i} d_{xy} \cdot Y_{xi} \cdot (Y_{yi+1} + Y_{yi-1}) \quad \dots \dots \dots (5) \end{aligned}$$

ここで、 Y_{xi} はニューロンの出力値で、この値が 1 の場合に都市 x を i 番目に訪れるこことを表す。また、 d_{xy} は都市 x と y との距離を表し、 $A \sim D$ は正の定数である。(5)式において右辺の第 1~3 項は各都市を 1 回ずつ訪れるという制約条件を表し、第 4 項は巡回路長を表している。

この定式化方法を応用して、大堀らは亜鉛めっき工場におけるコイル搬送台車の運行計画を作成した⁴⁾。この計画ではスキッド間で台車を用いてコイルを搬送する際に全コイルを搬送するのに要する時間が最短となるようなコイルの搬送順を決定する。本システムを用いることによりコイル搬送効率は従来法に比べ 10% 程度を改善した。

2・3 バックプロパゲーションモデル

バックプロパゲーションモデル²⁾では Fig. 4 に示すようにニューロンを入力層、中間層、出力層の多層構造に結合する。ネットワークへの入力は入力層に入力され、入力層の出力値は中間層に、中間層の出力値は出力層へと送られる。

各ニューロンの結合荷重 W_{ij} は以下に示す学習により決定する。学習のためには訓練データとして入力データとそれに対する正解出力データ（教師データ）を複数組用意する。この入力データに対するネットワークの出力値が教師データに近づくように各ニューロンの結合荷重を修正する。すなわち、ネットワークからの出力値を Y_i 、教師データを T_i とし、

$$E = \sum_i (Y_i - T_i)^2 / 2 \quad \dots \dots \dots (6)$$

で定義される誤差 E が減少するように(7)式で示す最急勾配法で荷重を修正する。

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E}{\partial W_{ij}} \quad (\eta > 0) \quad \dots \dots \dots (7)$$

学習用の入力データのあるカテゴリーに属する典型的な分布データとし、教師データをそのカテゴリーを示すコードとすると、学習後のネットワークを用いることにより分布データがどのカテゴリーに属するかを認識することができる。

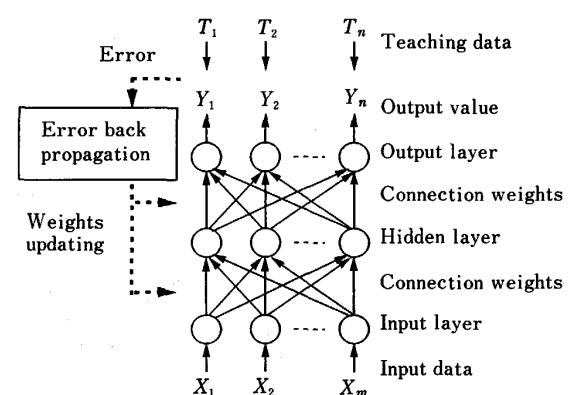


Fig. 4. Configuration of back propagation model.

本ネットワークモデルを筆者らは高炉炉頂部の温度分布および装入物プロファイルの認識に適用している⁵⁾。学習用のデータを、前者では計測データから選択し、後者では人工的に作成している。

炉頂装入物の堆積プロファイルは Fig. 5 に示すように半径方向 15 点で計測されている。このプロファイルの典型的な分布データを計測データから選択することは困難であるので、Fig. 6 に示す 8 種類のデータを人工的に作成し、ニューラルネットの学習を行った。学習後のニューラルネットにより従来システム化ができなかった炉壁近傍の水平な堆積領域の自動認識を実現でき、Fig. 5 に示すように人間の認識と良好な対応が得られた。

また、平田らは本モデルを高炉のシャフト上部ゾンデのガス利用率分布、シャフト中部ゾンデのガス利用率分布、ステープ温度の高さ方向分布、の認識に適用し、この認識結果を高炉操業管理エキスパートシステムの入力

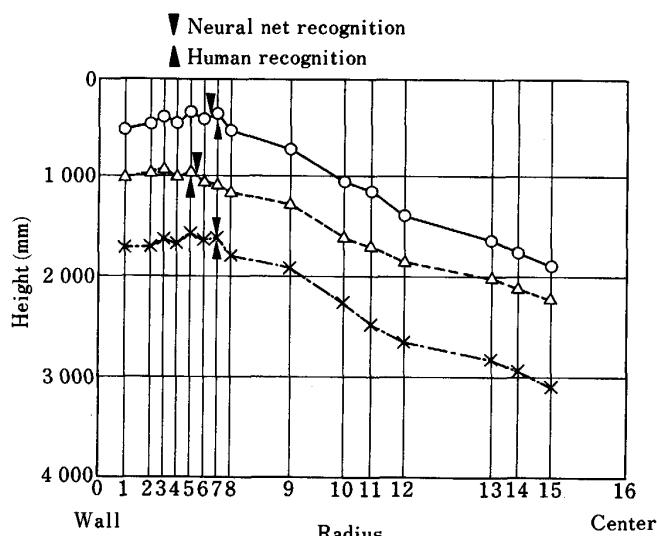


Fig. 5. Example of measured burden profile.

情報として活用している⁶⁾。

以上は分布データのパターン認識への適用例であるが、小幡らは種々の計測データに基づく高炉炉熱レベル推移の予測に本ネットワークモデルを適用している⁷⁾。このネットワークは高炉炉熱制御システムの一部として活用されている。

また、鎌田らは連続铸造におけるブレークアウトの予知に本ネットワークモデルを適用している⁸⁾。構築した予知システムにより従来法に比べてより早期かつ高精度な予測結果が得られた。

2・4 自己組織特徴マップモデル

KOHONEN によって提唱された自己組織特徴マップモデル³⁾は、Fig. 7 に示すようにニューロンが 2 次元配列状に結合しており、入力データはすべてのニューロンに入力される。従ってすべてのニューロンは入力データ数に等しい次数の結合荷重を有する。この結合荷重 W を決定するための学習では、多数の入力データを用いる。学習用の入力データ X に対し、最も大きな値を出力したニューロンが核となり、核となったニューロンおよびその近傍のニューロンの荷重が(8)式により入力データに近づくように修正される。

$$W_{n+1} = W_n + \alpha \cdot (X_n - W_n) \quad (0 < \alpha < 1) \quad \dots \dots \dots (8)$$

ただし、 n はくりかえし回数を示す。この学習により、学習後のニューロンは同様の入力に対し、さらに大きな値を出力するようになる。この学習を種々の入力データに対して繰り返し行うことにより、各ニューロンの結合荷重は対応する代表的な入力パターンを示すように分類される。このモデルでは学習前にどのようにデータを分類するかを設定する必要はなく、学習によって分布データの特徴抽出と分類が自動的に行える。前述のバックプロパゲーションモデルと比較すると、この自己組織特徴マップの特徴として以下の項目が挙げられる。

1) ネットワークは学習により自動的にデータの特徴を抽出し、いくつかのパターンに分類するので、基本的

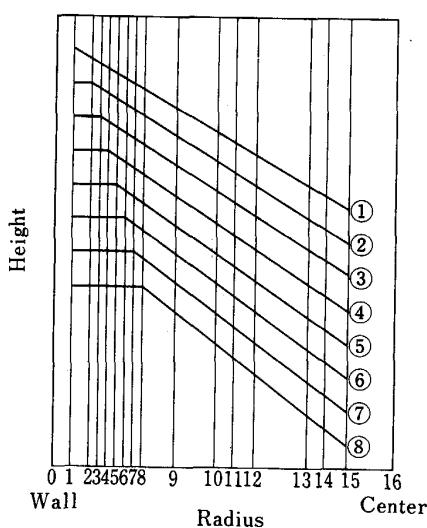


Fig. 6. Learning data for burden profile recognition.

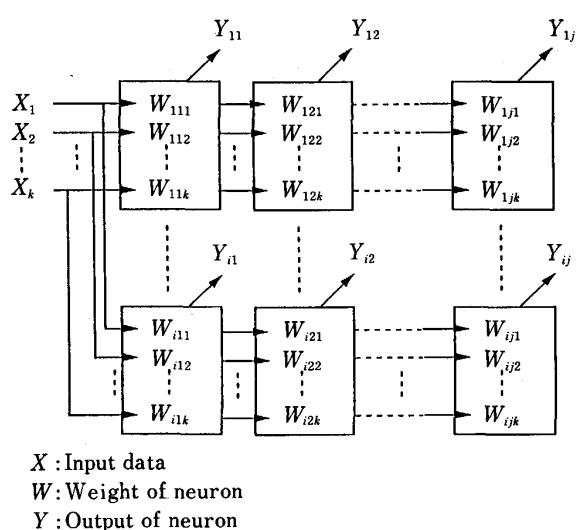


Fig. 7. Configuration of self organization feature maps model.

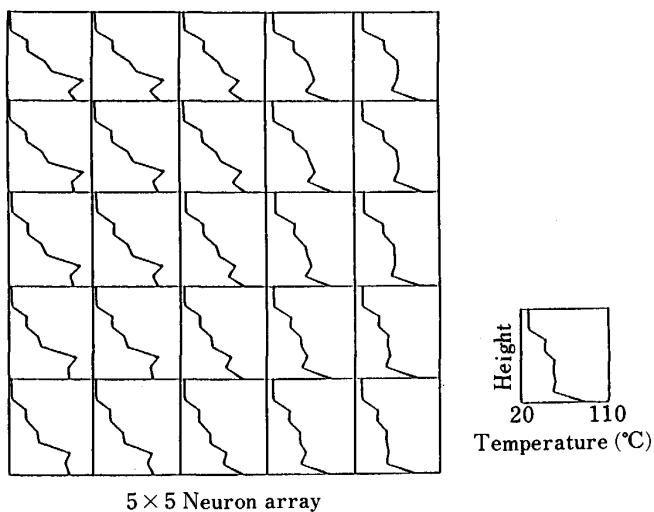


Fig. 8. Stave temperature patterns classified by self organization neural net.

なパターン（教師データ）を設定する必要はない。

2) 分類されたパターンはニューロンの結合荷重として記憶されるので、結合荷重を観察することによりデータの特徴を把握することができる。

本ネットワークモデルを松田らは高炉炉壁温度分布の特徴抽出と分類に適用している⁹⁾。炉壁温度データは高炉の高さ方向と円周方向の合計65点で計測されており、これらの多点データを視覚的に認識することは困難であるので、本ネットワークを用いてデータの特徴抽出と分類を行った。ネットワークの規模を5×5とし、200件のデータを用いて学習した結果をFig. 8に示す。ただし、Fig. 8では、分類結果を円周方向で平均化して表示している。また、Fig. 8を観察することにより、高炉の下部が高温（左上のニューロン）、下部がやや高温（左下）等の特徴を抽出しながら炉壁温度が25種類

のパターンに分類されていることが分かる。この分類結果は高炉熱損失の推定に活用されている。

また、本ネットワークを用いた時系列データの認識例としては、高炉内の化学反応の一つであるソルーションロス反応量の時間推移の認識がある¹⁰⁾。

3. 鉄鋼業におけるニューラルネットワーク応用の展望

鉄鋼業における人工知能技術の応用として、診断問題、制御問題、計画問題などへのエキスパートシステムの応用が盛んである。

プロセス診断や制御では計測データやプロコンのデータを読み込んでオンラインで処理する必要がある。しかし、エキスパートシステムの知識ベースに蓄えられているルールはIf-then形式で記述できる専門家の論理的な知識に限られるため、計測データのパターン認識など専門家の主観的な情報処理のルール化が困難で、オンラインエキスパートシステム構築時の課題となっている。バックプロパゲーションおよび自己組織特徴マップモデルは分布データの認識、特徴抽出、分類に優れており、この課題に対する有力な解決法である。すなわち、専門家の主観的な認識をニューラルネットが代行し、認識結果を用いた論理的な推論をエキスパートシステムが受け持つことにより、より柔軟で人間の処理に近いシステムが構築できる。さらにニューラルネットによる分布データの処理結果を解析することにより、新しい知識を獲得できる可能性がある。この意味で、ニューラルネットは知識獲得支援システムとしても活用できるだろう。

また、計画問題では組合せ爆発への対処方法が課題となっており、これを防止するためエキスパートシステムを用いて専門家の知見を生かした実行可能解の探索や組合せの絞り込みを行っている。これらの問題に対し、ホップフィールドモデルが有効に適用できたならば、高速に高精度な解が求められる可能性がある。ただし、ホップフィールドモデルでは、制約条件と評価関数を2次形式のエネルギー関数で記述する必要があるので、大規模かつ複雑な鉄鋼プロセスの計画問題に対しては、エネルギー関数で定式化できるような部分問題に分割するなどの工夫が必要になろう。

このように、ニューラルネットワーク技術は従来のシステム最適化などの数理的な手法やエキスパートシステムとは異なったアプローチをとっているため、これまでシステム化が困難であった問題に対するブレークスルーリー策として期待される。一方、数学モデルとして見た場合、ニューラルネットは非線形項を含む点が特徴の一つである。この特徴により、線形のモデルでは扱えなかった問題が処理できるが、かなり“くせ”のあるモデルでもある。ニューラルネットワーク技術を使いこなすためには、ネットワークモデルの基本的な特性および対象とす

るシステムやデータの性質を十分考慮する必要がある。

4. ま　と　め

以上、ニューラルネットワークモデルの中から代表的なモデルであるホップフィールドモデル、バックプロパゲーションモデル、自己組織特徴マップモデルを取り上げ、その機能と鉄鋼業への応用例について紹介した。

ニューラルネットワークは人間の行っている主観的な処理を得意とするのに対し、従来の数理的な手法やエキスパートシステムの手法は論理的な処理を特徴としている。従って、従来技術とニューラルネット技術の融合は互いの技術の長所を生かす意味でも有効と思われる。

文　　献

- 1) J. J. HOPFIELD and D. W. TANK: Biological Cybernetics, 52 (1985), p. 141

- 2) D. E. RUMELHART, J. L. McCLELLAND and the PDP Research Group: *Parallel Distributed Processing*, Vol. 1, 2 (1986) [MIT Press]
- 3) T. KOHONEN: *Self-Organization and Associative Memory* (1989) [Springer-Verlag]
- 4) 大堀真司, 竹腰篤尚, 山本正治, 江種俊夫, 永山隆治: 材料とプロセス, 3 (1990), p. 1256
- 5) 大塚喜久, 田村直樹, 松田浩一, 小西正躬, 門口維人: 鉄と鋼, 77 (1991), p. 79
- 6) 平田達朗, 山村耕造, 横口宗之, 森本 忍, 高田 寛: 材料とプロセス, 2 (1989), p. 992
- 7) 小幡昊志, 野村 真, 牧勇之輔, 小林敬司, 伊藤慶明: 材料とプロセス, 3 (1990), p. 988
- 8) 鎌田憲幸, 内藤修治, 小南秀隆, 福永新一, 田中健彦, 遠藤秀一, 川崎 貴: 材料とプロセス, 3 (1990), p. 1248
- 9) 松田浩一, 大塚喜久, 田村直樹, 有馬慎弥: 材料とプロセス, 3 (1990), p. 78
- 10) 大塚喜久: システム/制御/情報, 35 (1991), p. 41