

JAERI-Research  
95-076



ニューラルネットワークによる  
原子力プラント監視手法と実炉への応用

1995年11月

鍋島邦彦・鈴木勝男・篠原慶邦\*・E. TÜRKCAN\*\*

日本原子力研究所  
Japan Atomic Energy Research Institute

本レポートは、日本原子力研究所が不定期に公開している研究報告書です。  
入手の間合わせは、日本原子力研究所技術情報部情報資料課（〒319-11 茨城県那珂郡東海村）あて、お申し越してください。なお、このほかに財団法人原子力弘済会資料センター（〒319-11 茨城県那珂郡東海村日本原子力研究所内）で複写による実費頒布をおこなっております。

This report is issued irregularly.

Inquiries about availability of the reports should be addressed to Information Division, Department of Technical Information, Japan Atomic Energy Research Institute, Tokai-mura, Naka-gun, Ibaraki-ken 319-11, Japan.

© Japan Atomic Energy Research Institute, 1995

編集兼発行 日本原子力研究所

印刷 原子力資料サービス

ニューラルネットワークによる原子力プラント監視手法と実炉への応用

日本原子力研究所東海研究所原子炉工学部

鍋島 邦彦・鈴木 勝男・篠原 慶邦\*

E. TÜRKCAN\*\*

(1995年10月13日受理)

本論文では、原子炉プラントの主要なプロセス変数の計測データを用いてニューラルネットワーク上に構築したプラントモデルの予測値と実際の信号との誤差監視に基づく異常兆候の早期検知手法、及びそのプログラムについて述べる。ここで用いたニューラルネットワークは、3層からなる12入力12出力のauto-associative型ネットワークで、その学習則には誤差逆伝播アルゴリズムを採用した。さらに原子炉の動特性のモデル化の精度を向上させるために、初期学習と適応学習に分ける新しい学習方法を開発した。このニューラルネットワークを実際の原子力プラントの実時間監視システムとして使用した結果、原子炉の起動・停止及び定常運転の広出力範囲にわたって、微少な異常兆候を早期に検知することができた。

---

東海研究所：〒319-11 茨城県那珂郡東海村白方白根2-4

\* 原子力技術開発機構

\*\* オランダエネルギー研究所(BNC)

Nuclear Power Plant Monitoring Method by Neural Network  
and Its Application to Actual Nuclear Reactor

Kunihiko NABESHIMA, Katsuo SUZUKI, Yoshikuni SHINOHARA\*  
and E. TÜRKCAN\*\*

Department of Reactor Engineering  
Tokai Research Establishment  
Japan Atomic Energy Research Institute  
Tokai-mura, Naka-gun, Ibaraki-ken

(Received October 13, 1995)

In this paper, the anomaly detection method for nuclear power plant monitoring and its program are described by using a neural network approach, which is based on the deviation between measured signals and output signals of neural network model. The neural network used in this study has three layered auto-associative network with 12 input/output, and backpropagation algorithm is adopted for learning. Furthermore, to obtain better dynamical model of the reactor plant, a new learning technique was developed in which the learning process of the present neural network is divided into initial and adaptive learning modes. The test results at the actual nuclear reactor shows that the neural network plant monitoring system is successful in detecting in real-time the symptom of small anomaly over a wide power range including reactor start-up, shut-down and stationary operation.

Keywords: Neural Network, Real-time Monitoring, Anomaly Detection,  
Plant Modeling, Backpropagation

---

\* Nuclear Power Engineering Corporation

\*\* Netherlands Energy Research Foundation, ECN

## 目 次

1. 序 論 .....	1
2. ニューラルネットワーク .....	2
2.1 階層型ネットワーク .....	2
2.2 誤差逆伝播アルゴリズム .....	4
2.3 学習の高速化 .....	4
2.4 適応学習 .....	5
2.5 入出力データの規格化 .....	8
2.6 初期値の設定 .....	8
3. 原子力プラントのモデル化 .....	9
3.1 Borssele 炉の概要 .....	9
3.2 Borssele 炉のモデル化 .....	9
4. プラント監視への応用 .....	11
4.1 従来の監視方法 .....	11
4.2 ニューラルネットワークを用いた監視方法 .....	11
4.3 実時間データへの適用例 .....	15
5. 結 論 .....	19
参考文献 .....	19
付録1 サブルーチン一覧 .....	20
付録2 入出力データ一覧 .....	21
付録3 入力データ形式（初期学習モード） .....	22
付録4 入力データ例（初期学習モード） .....	26
付録5 入力データ形式（適応学習モード） .....	28
付録6 入力データ例（適応学習モード） .....	29
付録7 プラント信号データ例 .....	30
付録8 出力データ例（初期学習モード） .....	31

## Contents

1. Introduction .....	1
2. Neural Network .....	2
2.1 Layered Network .....	2
2.2 Backpropagation Algorithm.....	4
2.3 Acceleration of Learning .....	4
2.4 Adaptive Learning .....	5
2.5 Normalization of Input/Output Signal .....	8
2.6 Initial Value Setting of Neural Network .....	8
3. Nuclear Power Plant Modeling .....	9
3.1 Overview of the Borssele Reactor .....	9
3.2 Modeling of the Borssele Reactor .....	9
4. Application to Plant Monitoring .....	11
4.1 The Conventional Monitoring Methods .....	11
4.2 Monitoring Method with Neural Network .....	11
4.3 Typical Application to Actual Data .....	15
5. Conclusion .....	19
References .....	19
Appendix 1 List of Subroutine .....	20
Appendix 2 List of Input/Output Data .....	21
Appendix 3 Input Data Format (Initial Learning) .....	22
Appendix 4 Sample of Input Data (Initial Learning) .....	26
Appendix 5 Input Data Format (Test & Adaptive Learning) .....	28
Appendix 6 Sample of Input Data (Test & Adaptive Learning) .....	29
Appendix 7 Sample of Plant Signal Data .....	30
Appendix 8 Sample of Output Data (Initial Learning) .....	31

# 1. 序 論

人工ニューラルネットワークは、生物の脳の神経細胞（ニューロン）の結合及び構築の状態を単純化したモデルで表わしたもので、数学的には複数の入力から複数の出力への非解析的な非線形写像を与えるものである。また、情報処理の観点から見れば信号変換、特にパターン認識の機能を有している。このためニューラルネットワークはいろいろな情報処理問題に応用が可能である。その1つに、振舞が複雑でよく解明されていないシステムの実効的な入出力関係を学習という方法を通してモデル化することが挙げられる。

原子炉は非常に複雑でかつ非線形なシステムであるので、低出力から定格出力までの広範囲にわたる一元的なモデル化は困難である。物理モデルを基礎として作られた既存の計算コードは通常長い計算時間を必要とするため、実時間処理にはほとんど適用できない。そこで、これらの問題を解決し、原子炉の実時間監視システムを構築するため、ニューラルネットワークを用いて過去の運転データの学習から原子炉のモデル化を行った。もちろんニューラルネットワークはその学習過程において比較的長い計算時間を必要とするが、一旦学習を終えた後は、その並列型情報処理により実行速度は速く、実時間処理が可能であるので、オンラインによるプラント監視に十分利用できる。


現在のところ原子力プラントへの応用<sup>1)</sup>は研究開発段階のものが殆どで、実用例はそれ程多く見られない。なぜなら、一般にプラント監視システムは、原子炉の起動から停止に至るまでの広い炉出力範囲にわたる全運転期間を通して適用できるものでなければならない。しかし、原子炉プラントは1回の燃料サイクルの間に、運転条件の変更や燃焼による反応度の変化、等によってプラント特性が徐々に変化し、燃料サイクル初期段階と終期におけるプラント特性は大幅に異なるからである。そこで、この緩やかなプラント特性の変化に対応するために、ニューラルネットワークの内部構造を、モデル化したプラントと同様に徐々に更新していく適応学習法を開発した。このような学習方法を用いたニューラルネットワークで原子炉プラントのモデル化を行うと、原子炉起動・停止及び出力運転の広出力範囲にわたって微少な異常兆候を早期検知することが可能であることがわかった。本報は、実際の原子炉プラントに実時間ニューラルネット監視技法を適用した結果についての報告である。

## 2. ニューラルネットワーク


### 2.1 階層型ネットワーク

ニューラルネットワークの構造には大きく分けて、図2.1のような階層型と相互結合型の2種類がある。階層型ニューラルネットワークは、入力層、適当な数の隠れ層（中間層）、出力層から構成されており、入力層は情報を入力するための第1層、出力層は情報を出力するための最終層である。入力層と出力層の間に存在する隠れ層は、1層以上で、適用する問題によって任意に決定できる。階層型ネットワークは、通常各層間の結合のみで、同一層内でのユニットの結合は考えていない。また、この種のネットワークでは、情報がネットワーク中を1方向へ1度流れて状態変化が終了する。最もよく用いられている階層型は、誤差逆伝播アルゴリズムを用いたネットワークで、フィードバック結合がなく、教師信号を必要とする。

一方、相互結合型ニューラルネットワークは、階層構造を作らず、近傍にあるユニット間の相互結合によって構成されており、入力ユニットと出力ユニットが共通である。ある初期状態から出発したネットワークは、ユニットの状態変化が繰り返されるうちにある安定な平衡状態に到達する。この種のネットワークには、ネットワーク構造に自己組織化を組み込んだものや、学習の際に教師信号を必要としないものも存在する。相互結合型の代表的なものに、コホーネンネット、ホップフィールドモデル、ボルツマンマシンなどが挙げられるが、現在のところ画像や文字認識等の特殊な分野にのみ適用可能な状況にある。



階層型ネットワーク



相互結合型ネットワーク

図2.1 ニューラルネットワークの構造



本研究では、フィードバック結合のない3層の階層型ネットワークを採用する。まず、図2.2に示されるような個々のニューロン（ユニット）について説明する。<sup>2)</sup> k層のj番目にあるユニットに注目すると、このユニットへの入力 $I_j^k$ は、(2.1)式のように、k-1層にあるユニットからの出力 $O_i^{k-1}$ に重み $W_{ij}^{k-1,k}$ をかけたものの総和として表わされる。

$$I_j^k = \sum_i W_{ij}^{k-1,k} \times O_i^{k-1} \tag{2.1}$$

さらに、この入力 $I_j^k$ は、入出力関数 $f(x)$ により出力 $O_j^k$ に変換されるが、ここでは入出力関数としてシグモイド関数を使用した。

$$f(x) = \frac{1}{1+e^{-(x-\theta)}} \tag{2.2}$$

そこで出力信号は、

$$O_j^k = f(I_j^k) = \frac{1}{1+e^{-(I_j^k-\theta_j^k)}} \tag{2.3}$$

となる。

なお、(2.3)式で、 $\theta_j^k$ は個々のユニットにおけるしきい値である。




図2.2 ネットワーク内部のニューロン（ユニット）の結合

## 2.2 誤差逆伝播 (バックプロパゲーション) アルゴリズム

階層型ニューラルネットワークの学習則としてもっともよく用いられるアルゴリズムが、誤差逆伝播法 (一般化デルタルール) である。このアルゴリズムは、教師付き学習方法の1つで、ネットワークの出力値と実際の正解値の二乗誤差を最小にするようにユニット間の重みを変えていく。この学習の際、正解値と出力値との誤差 (偏差) を入力として、出力層から入力層の方向へ、信号の伝播と逆方向に重みを付けた和をとりながら伝播させて行くようになっている。

出力層Mのニューラルネットワークで、k層のj番目にあるユニットにおける学習回数t+1回目の新しい重み  $W_{ij}^{k-1,k}(t+1)$  は、以下のようにして求められる。

$$W_{ij}^{k-1,k}(t+1) = W_{ij}^{k-1,k}(t) + \Delta W_{ij}^{k-1,k}(t) \quad (2.4)$$

$$\Delta W_{ij}^{k-1,k}(t) = \eta \delta_j^k \times O_i^{k-1} \quad (2.5)$$

ここで、 $\eta$  は学習率と呼ばれるもので、1回の学習で修正される大きさを決めるパラメータである。また誤差信号 $\delta$ は、以下の式で表わされる。

出力層Mでのj番目のユニットの誤差信号は、

$$\delta_j^M = (Y_j - O_j^M) \times f'(I_j^M) \quad (2.6)$$

それ以外の中間層では、

$$\delta_j^{k-1} = O_j^{k-1} \times (1 - O_j^{k-1}) \times W_{ij}^{k-1,k} \times \delta_j^k \quad (k=M, M-1, \dots, 3) \quad (2.7)$$

と表わされる。また、入出力関数として、(2.2)式のようなシグモイド関数を用いているので $f'(x)$ は

$$f'(x) = f(x) \cdot (1-f(x)) \quad (2.8)$$

したがって、(2.7)式中の $f(I)$ は、

$$f(I_j^k) = O_j^k \times (1 - O_j^k) \quad (2.9)$$

と簡単に表わすことができる。

## 2.3 学習の高速化

### (1) モーメントム項

学習の振動を減らし、学習の収束を速めるために、標準誤差逆伝播の重みの修正式(2.5)に、モーメント項と呼ばれる第2項を追加する。

$$\Delta W_{ij}^{k-1,k}(t) = \eta \delta_j^k \times O_i^{k-1} + \alpha \Delta W_{ij}^{k-1,k}(t-1) \quad (2.10)$$

ここで $\alpha$ はモーメント項の係数で、一般的に正の小さい数である。またモーメント項には、最終的に求めたい最小値ではなく学習途中の極小値に陥るのを防ぐ効果もある。

### (2)学習係数の変更

一般的に、学習率 $\eta$ は、学習の初期段階においては大きい方が、またある程度学習が進んで誤差が小さくなってくると小さい方が収束が速くなる、と言われている。そこで、学習率 $\eta$ とモーメント項の係数 $\alpha$ を学習回数に応じて変更できるようになっている。実際の適用例では、学習率 $\eta$ を、1.2から0.1へ、またモーメント項の係数 $\alpha$ を0.6から0.1へ段階的に小さくする。

### (3)忘却項

ユニット間の結合の重みに忘却を導入する事により、隠れ層のユニットの最適化だけでなくユニット間の不要な結合状態を消滅させ、最適なネットワーク構造を形成するために提案された。<sup>3)</sup>ユニット間の結合の重みへの忘却の導入は、通常の誤差逆伝播学習による重みの変化に加えて、学習の繰り返し毎に重みを減衰させるものである。ここでは、学習時の評価として、さらに式(2.10)に結合の重みの絶対値和の項を追加する。

$$\Delta W_{ij}^{k-1,k}(t) = \eta \delta_j^k \times O_i^{k-1} + \alpha \cdot \Delta W_{ij}^{k-1,k}(t-1) - \epsilon \cdot \text{sgn}(W_{ij}^{k-1,k}(t-1)) \quad (2.11)$$

ここで、 $\epsilon$ は、繰り返し毎の忘却量、

$$\text{sgn}(x) = \begin{cases} 1, & x > 0 \\ 0, & x = 0 \\ -1, & x < 0 \end{cases} \quad (2.12)$$

この忘却項により必要な結合のみが生き残り、それ以外は消滅する。これらの結合及びユニットの消滅により、単純化されたネットワーク形成されるため、各入出力変数の相関を調べる場合に有効である。しかし、学習の繰り返し毎に強制的に全ての重みを減衰させるため、最終的な誤差の収束は悪くなる。したがって、ニューラルネットワークを原子力プラントのモデル化に使用する場合には適しておらず、通常この項は感度解析の場合にのみ用いる<sup>4)</sup>。

## 2.4 適応学習

ニューラルネットワークは、過去の運転データを学習によって、原子炉のような非常に複雑な非線形系をモデル化することが可能である。しかし、原子炉プラントのモデルを構築する場合には対象となるシステムが時間とともに変化していくため、学習課程を2つに

分ける必要がある。そこで図2.3に示されているように、典型的な運転パターンを学習する初期学習と、時間とともに変化していく対象にあわせてニューラルネットワークの内部構造を変えていく実時間適応学習の2つのモードに分ける。初期学習では、過去における原子炉の起動、定常運転、停止の3つの通常運転パターンを広出力範囲にわたって学習する。この際、いろいろな出力範囲の学習データをなるべく一様に選択することが重要である。また、本来ニューラルネットワークは学習データの範囲外での適用が難しいので、少なくとも適用する出力範囲の最大値と最小値のデータは初期学習に加えておく必要がある。初期学習の際に、ランダムにデータを学習するモードと与えられた順序で行うモードの2つの方法が選択できるが、一般的にはランダム学習の場合が学習の収束が速くしかも誤差が小さくなる。なお、初期学習において、用いられた学習データは以後使用されることなく、重み、しきい値等のネットワーク情報のみが監視・適応学習モードの初期値として記憶される。

初期学習後、原子炉から実時間で送られてくるプラント信号を入力としてニューラルネットワークによる推定を行う。ニューラルネットワークは正常な運転パターンのみを学習してモデル化を行っているので、もし、学習されていない運転パターンが入力として入ってくる場合には、各信号の推定値は、実際の値と異なってくるはずである。したがって、その誤差（偏差）を監視しておけば、微少な異常兆候を検知できることになる。

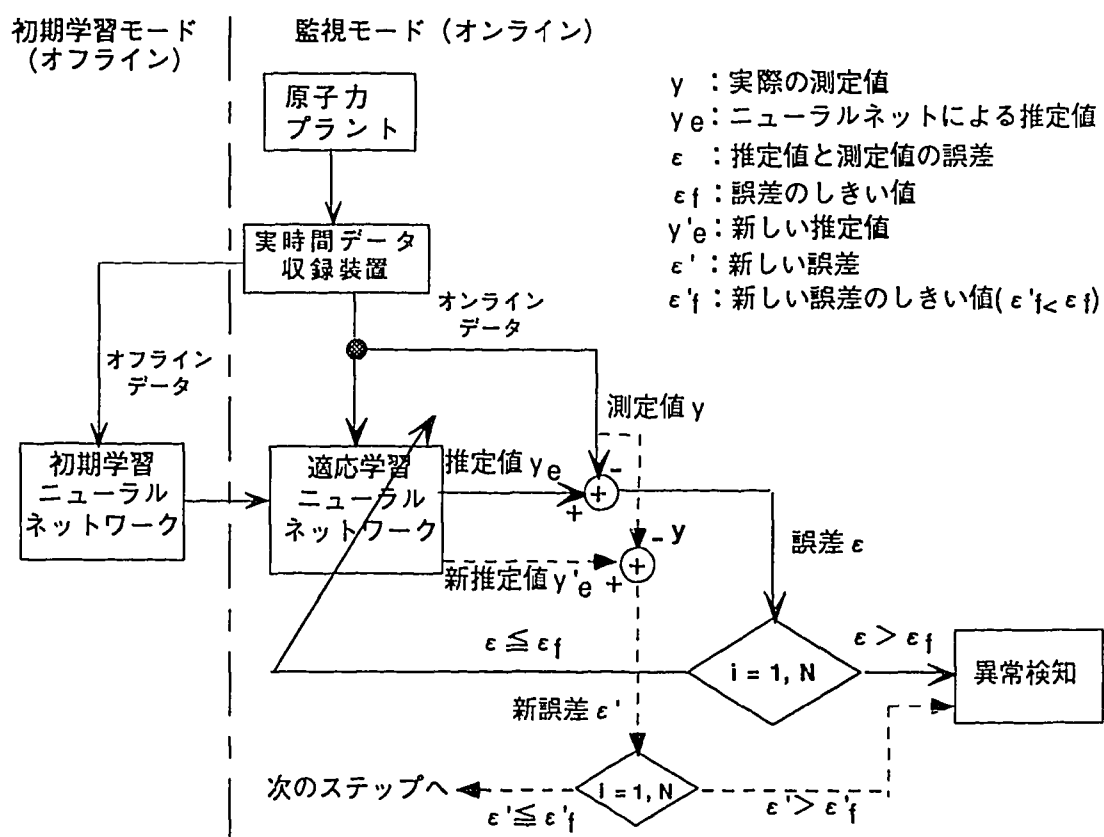


図2.3 学習アルゴリズム

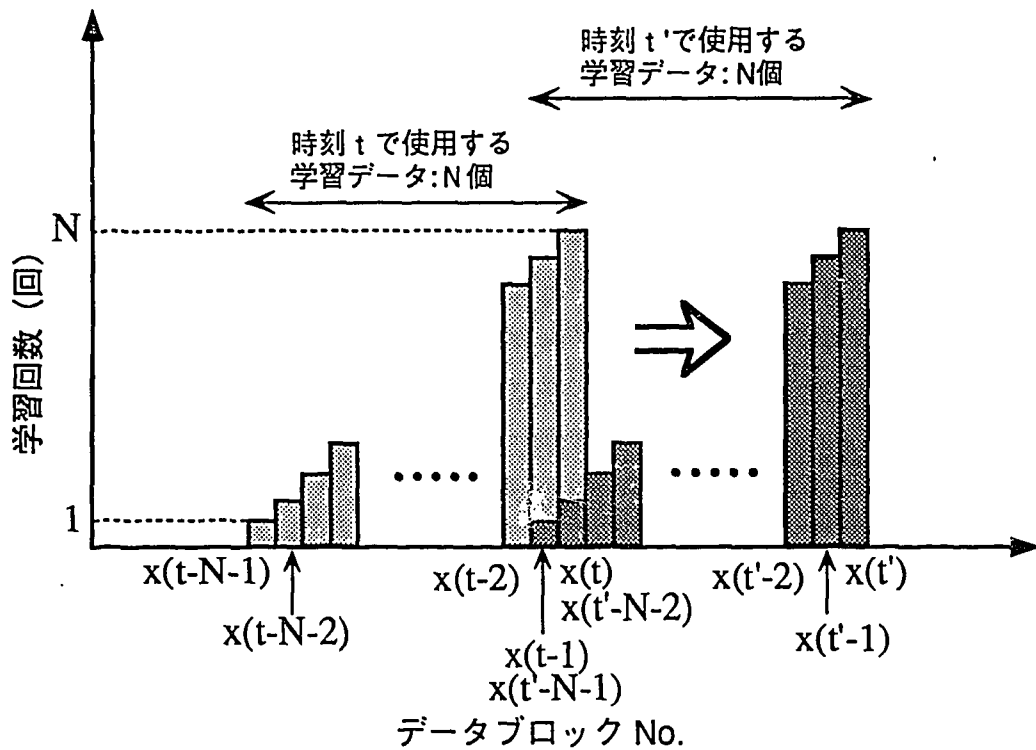


図2.4 適応学習に用いられるデータの範囲

推定値と実際の信号値の偏差が許容範囲（しきい値）内にある場合には、正常とみなし、さらにその最新のデータを使って適応学習を行う。この時のしきい値は、初期学習における最大誤差を参考にして設定される。実時間適応学習では、学習時間に制限があるため、最新のデータから過去一定範囲内にあるものを学習に用いる。この適応学習範囲（N個）の設定は、データのサンプリング間隔とコンピュータの計算速度から決定される。適応学習範囲内にある個々のデータの学習回数は一様ではなく、新しいデータほど学習の回数が多くなるよう考慮されている（図2.4参照）。つまり、時刻tにおいて、最新のデータX(t)はN回適応学習に用いられ、時刻t-1のデータX(t-1)はN-1回、時刻t-2のデータX(t-2)はN-2回、…となり、時刻t-N+1のデータX(t-N+1)は1回だけ使用される。また学習の順序はランダムではなく、

$$X(t-i) ; ((i=0, j-1), j=1, N) \tag{2.13}$$

となっている。図2.4の示されている様に、これらの適応学習データは、新しいデータがくる度に1つずつ右にシフトしていく。

一方、どれか一つでも信号誤差がしきい値を超えた場合には学習は行わず、どの信号が異常であるかのメッセージを画面に出力し、次のデータが来るのを待つ。さらにここでは、しきい値による判定を二段階に分けて行う。つまり、ネットワーク

が原子炉の状態を正常であると見なしても、適応学習後にもう1度推定を行い、偏差が新しいしきい値（第1段階より厳しい）以内に収まっていることを確認する。もし、この偏差が新しいしきい値を超えている場合には、新しい適応学習によって更新された重み等を破棄し、1ステップ前の状態に戻す。そして、異常のメッセージを出力した後、次のデータが来るのを待つ。このような二段階による判定によって、異常事象の検知にロバスト性を持たせている。

## 2.5 入出力データの規格化

入力信号は、学習に用いるデータの最大値と最小値が、それぞれ0.5と-0.5になるよう線形に規格化した。

$$X_i^{\text{norm}} = \frac{X_i^{\text{original}} - X_i^{\text{min}}}{X_i^{\text{max}} - X_i^{\text{min}}} \quad (2.14)$$

一方、出力信号は学習に用いるデータの最大値 ( $X_i^{\text{max}}$ ) と最小値 ( $X_i^{\text{min}}$ ) が、それぞれ0.9と0.1になるよう線形に規格化した。

$$Y_i^{\text{norm}} = \frac{Y_i^{\text{original}} - Y_i^{\text{min}}}{Y_i^{\text{max}} - Y_i^{\text{min}}} \times 0.8 + 0.1 \quad (2.15)$$

ここで、 $X_i^{\text{original}}$ 、 $Y_i^{\text{original}}$ は物理単位の入力と出力、 $X_i^{\text{norm}}$ 、 $Y_i^{\text{norm}}$ は規格化された入力と出力である。なお、この規格化は入力データによって変更が可能となっている。

## 2.6 初期値の設定

ユニット間の重み及びしきい値の初期値は、それぞれのユニットの機能分化を促すために、ランダムに設定されている。重みの初期値は-0.5から0.5の間の乱数を発生させて設定し、しきい値の初期値は-1.0～1.0の範囲内のランダムな値から始められる。用いる乱数によって、初期のネットワーク構造は全く違うものになり、最終的に学習が収束した後の重み等も大きく異なってくるが、最終的な学習誤差はほとんど同じ値になっている。これは、ネットワークで原子炉のモデル化を行う場合、幾通りものモデル化が可能であり、ネットワークの初期値はそれほど重要でないことを意味している。したがって、今回のようにニューラルネットワークをモデル化に用いる場合には、初期値の設定に神経質になる必要はない。

このことは、隠れ層のユニット数の設定にも言えることで、今回の適用例では、隠れ層のユニット数が6個以下では初期学習の誤差が大きく収束しなかった。したがって隠れ層のユニットは最低7個以上必要となるが、ネットワークの隠れ層ユニット数が8から20個の間で、学習結果に目立った差異は見られなかった。

### 3. 原子カプラントのモデル化

#### 3.1 Borssele炉の概要

今回対象にしたプラントはオランダのBorssele原子力発電所である。図3.1にBorssele炉の簡単なプラント図を示す。この原子炉は、電気出力47万kWのPWR型で、二次系は2ループからなっている。データ収録システムは、発電所からオランダエネルギー研究所 (ECN) までの250kmの距離を電話回線を通して研究所のコンピュータとオンラインで接続されており、常時32種類のプラント信号が4秒毎に送られて来ている。<sup>5)</sup>

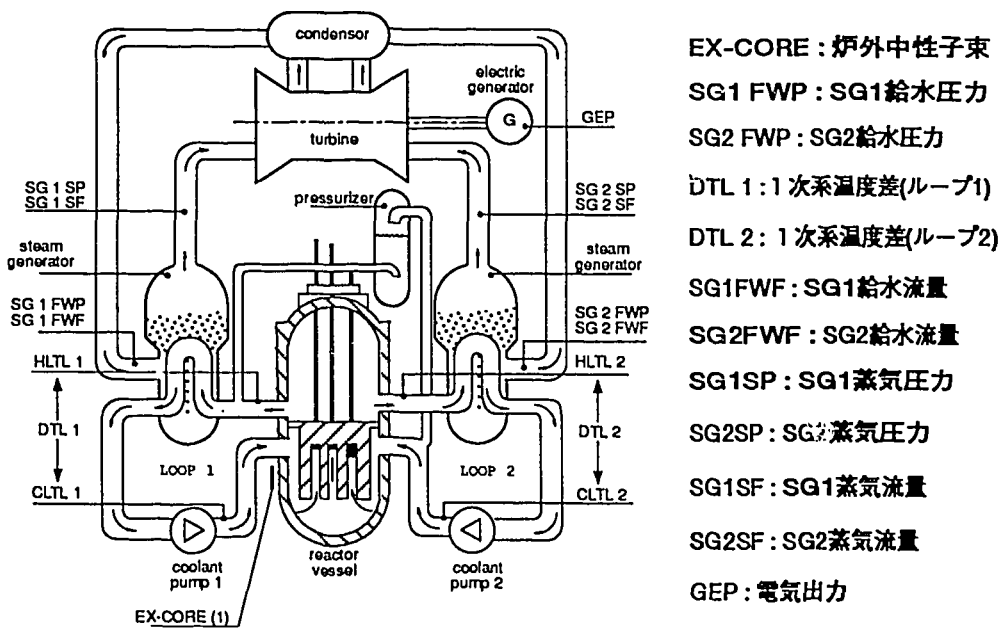


図3.1 Borssele炉のプラントモデルと監視に用いた信号

#### 3.2 Borssele炉のモデル化

使用したニューラルネットワークは、3層構造のfeedforward型で、図3.2に示されるような12入力12出力のauto-associative (自己連想型) ネットワークである。auto-associativeネットワークでは、入力層のユニットと出力層のユニットが対称になっており、学習時における入力値と出力値は全く同じ値になる。ここでは、12個の入力信号として、Borssele炉の32チャンネルのプラントパラメータの中から、もっとも重要だと考えられるものを選択した。原子炉一次系からは炉外中性子束、各ループにおけるホットレグとコールドレグの温度差を、二次系からはそれぞれの蒸気発生器出口での蒸気流量、蒸気圧力、及び蒸気発生器入口での給水流量、給水圧力を選択した。これらの11個の信号に電気出力を加えたものが12の入力及び出力にな

る。ここでホットレグとコールドレグの温度差を採用したのは、この温度差の信号が運転条件によってあまり左右されず、しかも中性子束や電気出力との相関が強い  
ため、ニューラルネットワークによるモデル化が容易であると考えられるからである。

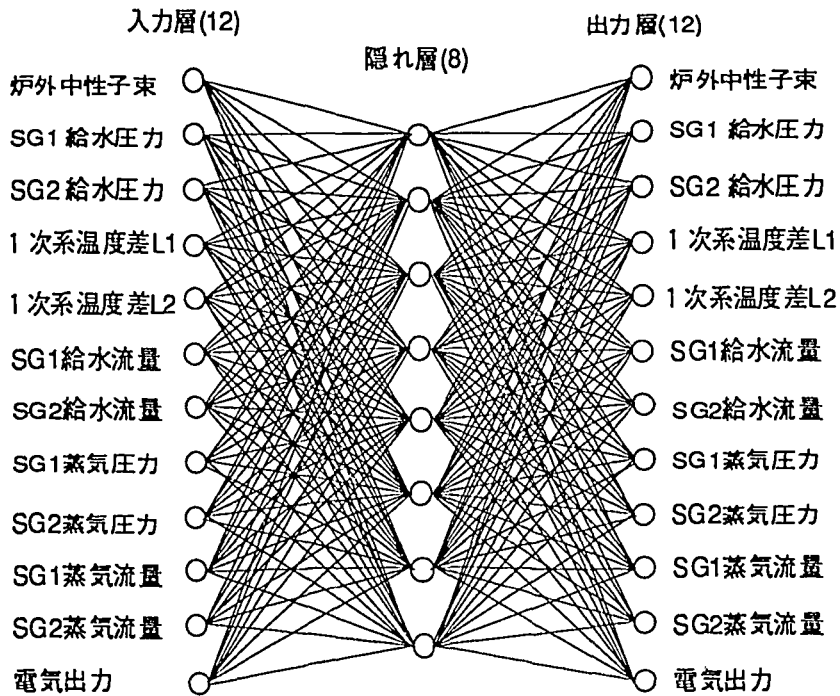


図3.2 auto-associative ニューラルネットワークモデル



## 4. プラント監視への応用

### 4.1 従来の監視方法

従来原子炉プラントの安全保護系は、ある一定のしきい値を設定し、信号がその範囲を超えた場合にのみ警報を発するようになっている。そのためゆっくりとした異常事象の際には、ある程度異常が大きくなってアラームが鳴るまで運転員が気がつかない場合が起り得る。また、原子炉の起動時や大幅な出力変更時には、正常に運転されていても監視信号が警報範囲に入ってアラームが鳴る場合もある。

一方、物理モデルから作成された詳細な事故解析コードを利用してプラント監視システムを構築しようという試みもなされているが、原子炉は非常に複雑でかつ非線形なシステムであるので、低出力から定格出力までの広範囲にわたる一元的なモデル化は困難である。しかも多くの計算時間を必要とするため、実時間の監視には向かない。

また、炉雑音信号を用いたスペクトル解析は、定常運転時には非常に有効であるが、原子炉の起動・停止及び出力変動時には使用できないという欠点がある。さらに、スペクトルの波形から異常を判定する段階では、運転員が関与する必要があり、異常検知の自動化は難しい。

### 4.2 ニューラルネットワークを用いた監視方法

図4.1に原子力プラント監視を実施する場合の簡単な概念図を示す。原子力発電所から数秒毎に送られて来るプラント信号は、ニューラルネットワークの入力として取り込まれる。使用したニューラルネットワークはフィードバックのない3層構造の階層型で、図3.2に示す12入力12出力、隠れ層が8ユニットからなる auto-associative ネットワークである。初期学習において、ニューラルネットワークは正常な運転パターンのみを使用してモデル化を行っているのも、もしこれまで

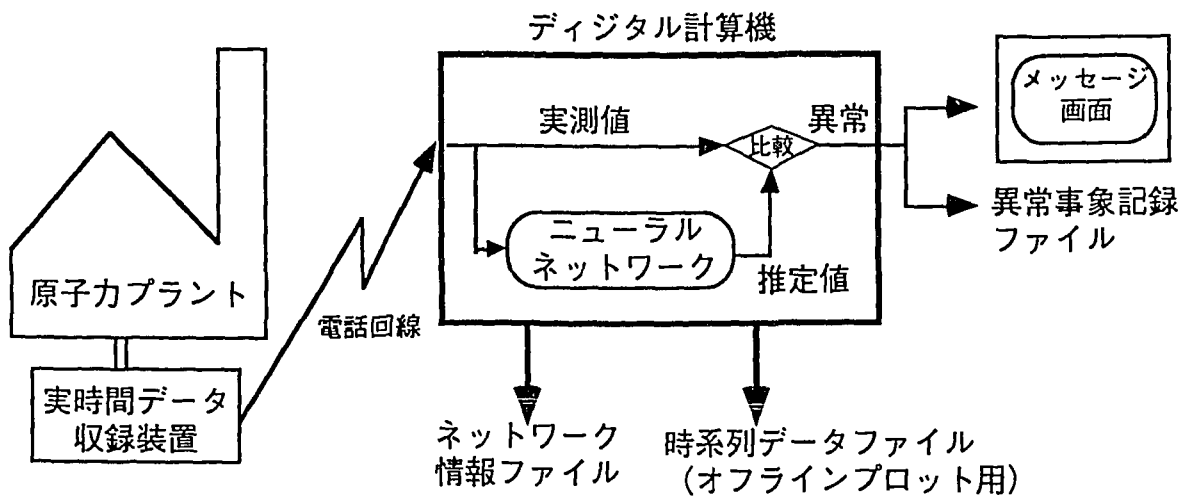


図4.1 原子炉プラント監視システム

に学習されていない未知の運転パターンが入力された場合には、各信号の推定値は、実際の測定値と異なってくる。したがって、その偏差を常時監視しておけば、微少な異常兆候を検知できる。初期学習では、過去における原子炉の起動、定常運転、停止の3つの通常運転モード・パターンを低出力から100%出力までの広範囲にわたって学習する。原子炉起動データは、出力を30%から100%まで6時間かけて上昇させたものでパターン数は687である。定常運転データは、100%定格出力時にコンデンサのリンシングと呼ばれる運転をしたもので、150パターンから成っている。原子炉停止データは、正確には100%から60%程度に出力を下げた運転モードであり、そのパターン数は75となっている。これらの全学習データ912パターンをランダムに各1500回ずつ学習させてネットワークによるモデル化を行った。この初期学習には、Sun-Sparc20計算機で約10分を要した。

ここでリンシングと呼ばれる運転モードについて簡単に記述する。この運転は、コンデンサの汚れからくる熱効率の低下を防ぐために、短時間に出力を微小変動させるもので、定常運転時に不定期的に行われる。まず5%程度出力を落とした後、数十秒の周期で出力を1%程度変動させる。この操作を約30分間行った後、再び元の定格値に戻す。なお、このリンシング運転には、現在2つのモードが確認されている。1つは二次系の2つのループの挙動が同位相なもの（正常モード）で、もう1つは、それぞれのループの挙動が逆位相になっているもの（異常モード）である。当然、初期学習には正常モードのデータのみを採用した。

図4.2は、このニューラルネットワークをオフラインで使用した結果で、監視した12個のプラント信号の測定値（実線）、ニューラルネットワークによる推定値（点線）及びこの2つの値の偏差（一点鎖線）を示している。また、水平に描かれた実線は、それぞれの信号のしきい値を表わしており、偏差がこのしきい値を超えた場合にのみ、監視システムはプラントが異常であるという診断を下す。ブロック数が0以前の1825点は、上述の学習データであり、当然ながら偏差は小さい。0より後は、出力390MWから475MWへの出力上昇データ187点、さらに定常運転時に於けるリンシング（逆位相）のデータの319点から成っている。

図4.2からわかるように、出力上昇時は通常の運転状態でありしかも異常事象も無いため、全ての信号の測定値と推定値の偏差は小さく、常にしきい値の範囲内にある。しかし、リンシング運転の際には、2次系信号のNo.1ループとNo.2ループの挙動が反転しているため、蒸気圧力、蒸気流量と言った信号の偏差が大きくなり許容範囲を超えている。したがって、その区間ではニューラルネットワークはプラント異常メッセージを発している。一方、電気出力の信号をみると、その偏差は常に許容範囲内にある。その理由は、これら2次系の2つのループの反転現象は、1ループに合流するタービン部分以降では、その効果が相殺されて発電機には直接影響を及ぼさないからである。

このように、正常運転状態のみのデータを学習させたニューラルネットワークは、異常状態の有無だけでなく、どの信号が異常であるかも適格に判定できるため、異常事象の原因を突き止める際にも非常に有効であると考えられる。

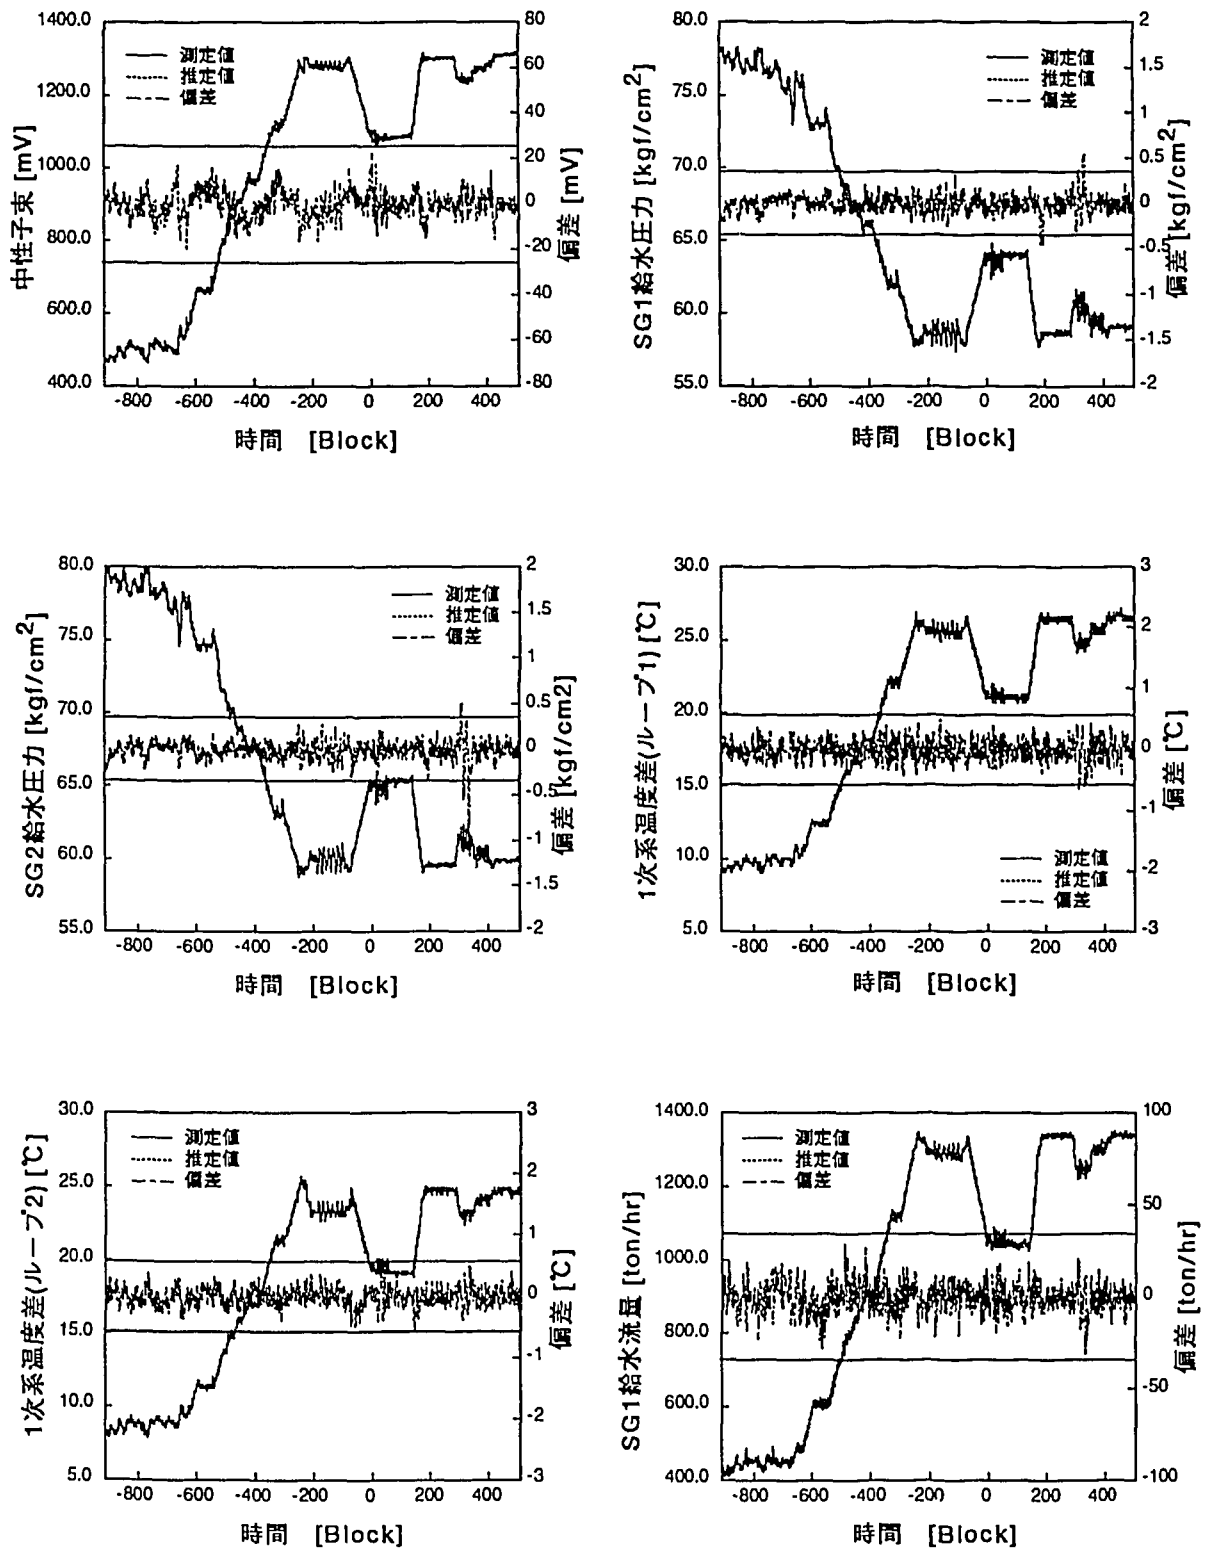


図4.2 ニューラルネットワークによる初期学習及びオフライン監視結果

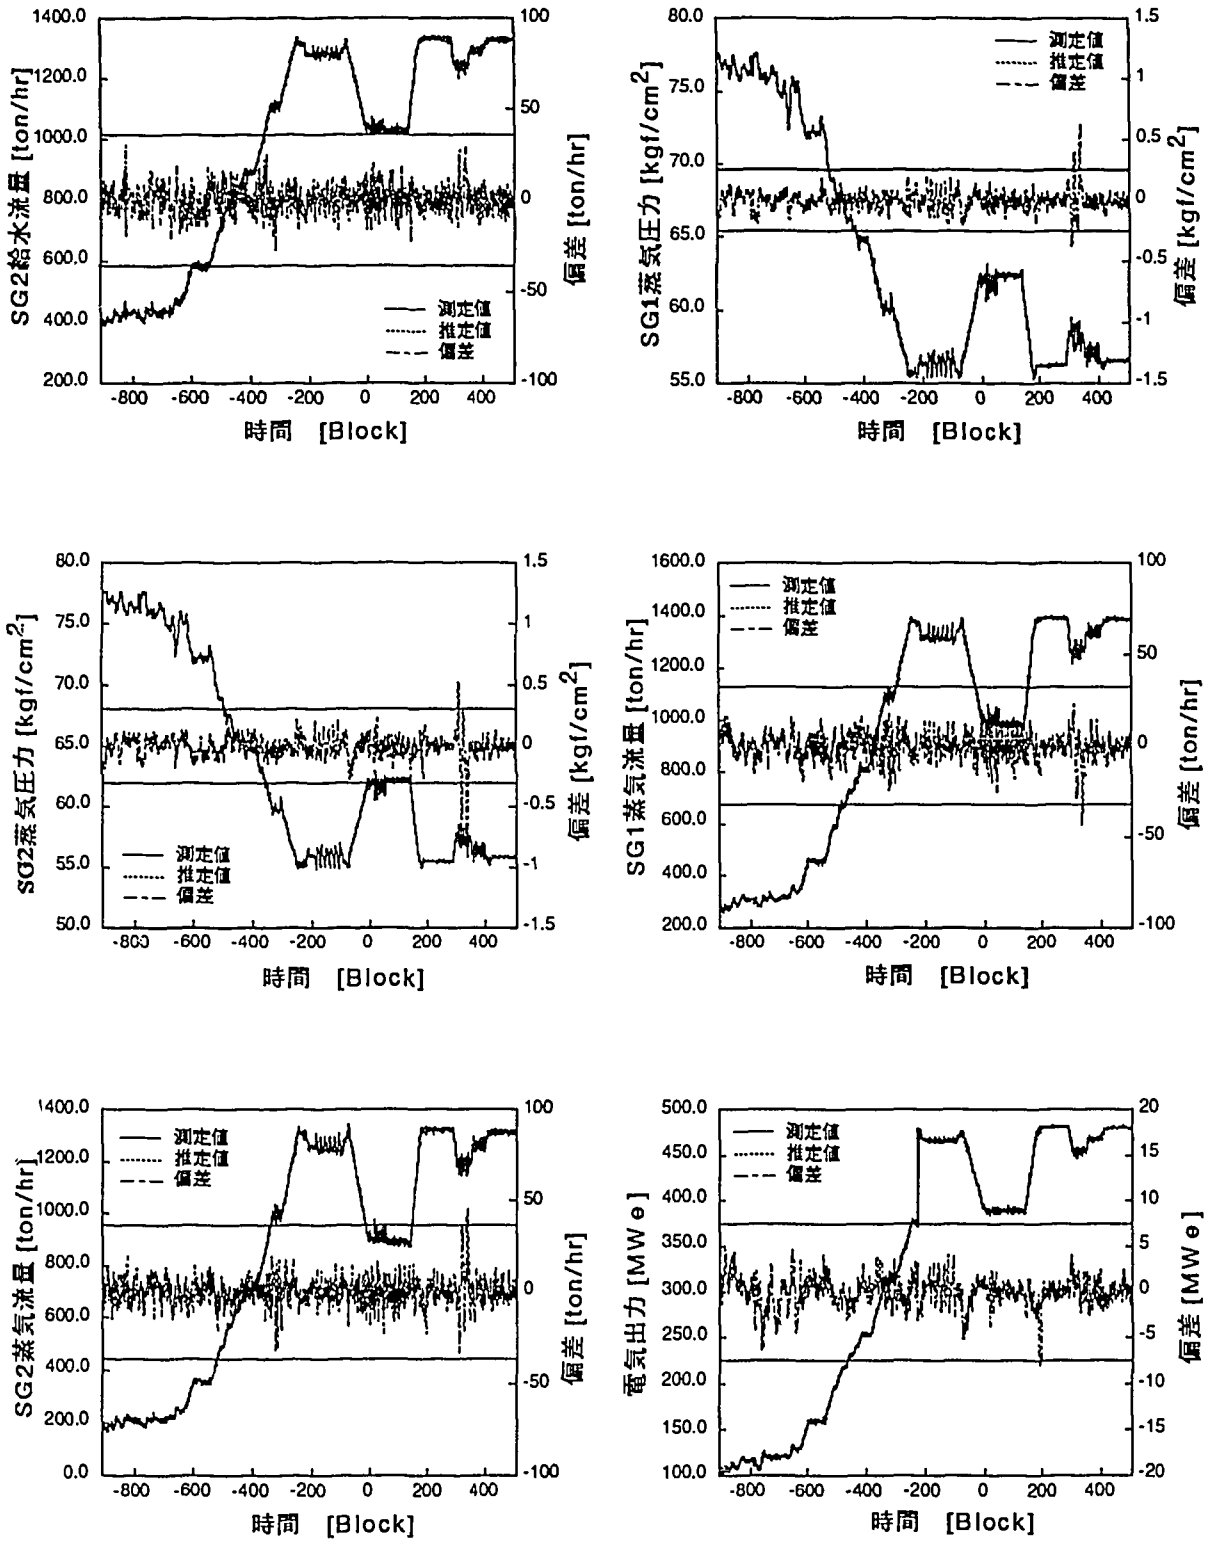


図4.2 ニューラルネットワークによる初期学習及びオフライン監視結果 (続き)

#### 4.3 実時間データへの適用例

最後に、このニューラルネットワークを用いた監視システムをオンラインで適用した結果を、図4.3に示す。<sup>5)</sup>このデータは、燃料サイクルの最後の炉停止時のもので、各プラント信号は4秒毎に送られて来ている。100%から徐々に出力を下げて行った後、しばらくの間出力200MWで定常運転を行っている。その間にコンデンサのリンシングを試みているが、この場合には2次系の2つのループの挙動が反転している。

監視システムは、炉停止を含めた通常運転時にはプラントが正常であるという診断を、またコンデンサのリンシング時には、原子炉二次系のNo.2ループの圧力、流量等が正常ではないという診断を行っている。図4.4は、リンシング運転時の2つのループの蒸気圧力信号を拡大して示した図である。この図から明らかなように、No.2ループの挙動がNo.1ループと逆転しており、同時にNo.2ループの実際の測定信号と推定値も反転している。この結果は本来No.2ループの蒸気圧力がNo.1ループと同じ挙動なるべきであることを示しており、したがってNo.2ループの偏差は大きく許容範囲を超えている。また、No.1ループの蒸気圧力信号の偏差は、同じように許容範囲を超えているものの、その値はNo.2ループに比べてかなり小さい。一方、2次系の2つのループ間の反転効果が相殺される1次系及び電気出力の偏差は、許容範囲内にとどまっている。

さらに480min以降になると、全ての信号の偏差がその許容範囲を超えている。これは、初期学習において電気出力が100MWe以下のパターンを全く学習していないからである。一般的に、ニューラルネットワークは学習データの範囲外の外挿は不得意であるので、初期学習のデータ選択には十分な配慮が必要である。

以上のことから、今後このニューラルネットワークを用いたシステムが、プラントのオンライン異常監視として適用できる可能性を十分に示した。

この監視システムは、現在でも原子炉からオンラインで送られてくるプラントデータを用いて稼働しており、原子炉の異常予知診断に役立っている。

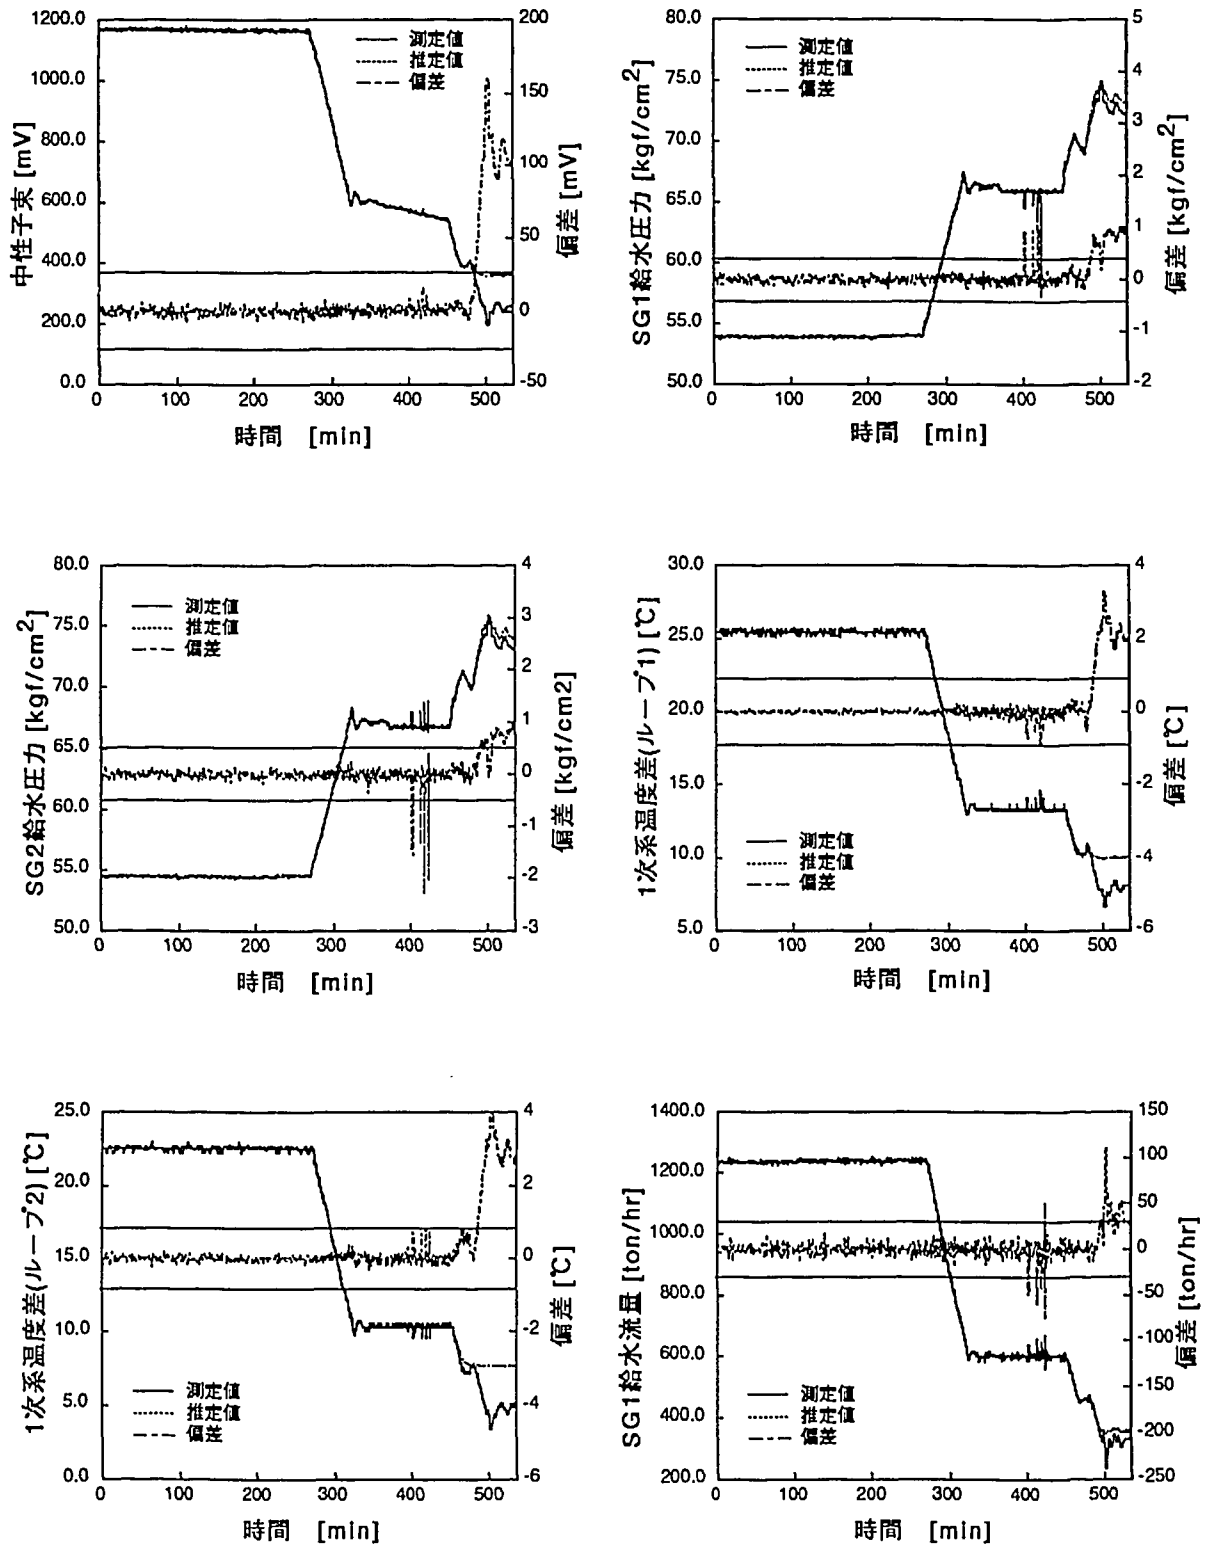


図4.3 ニューラルネットワークによるオンライン監視結果

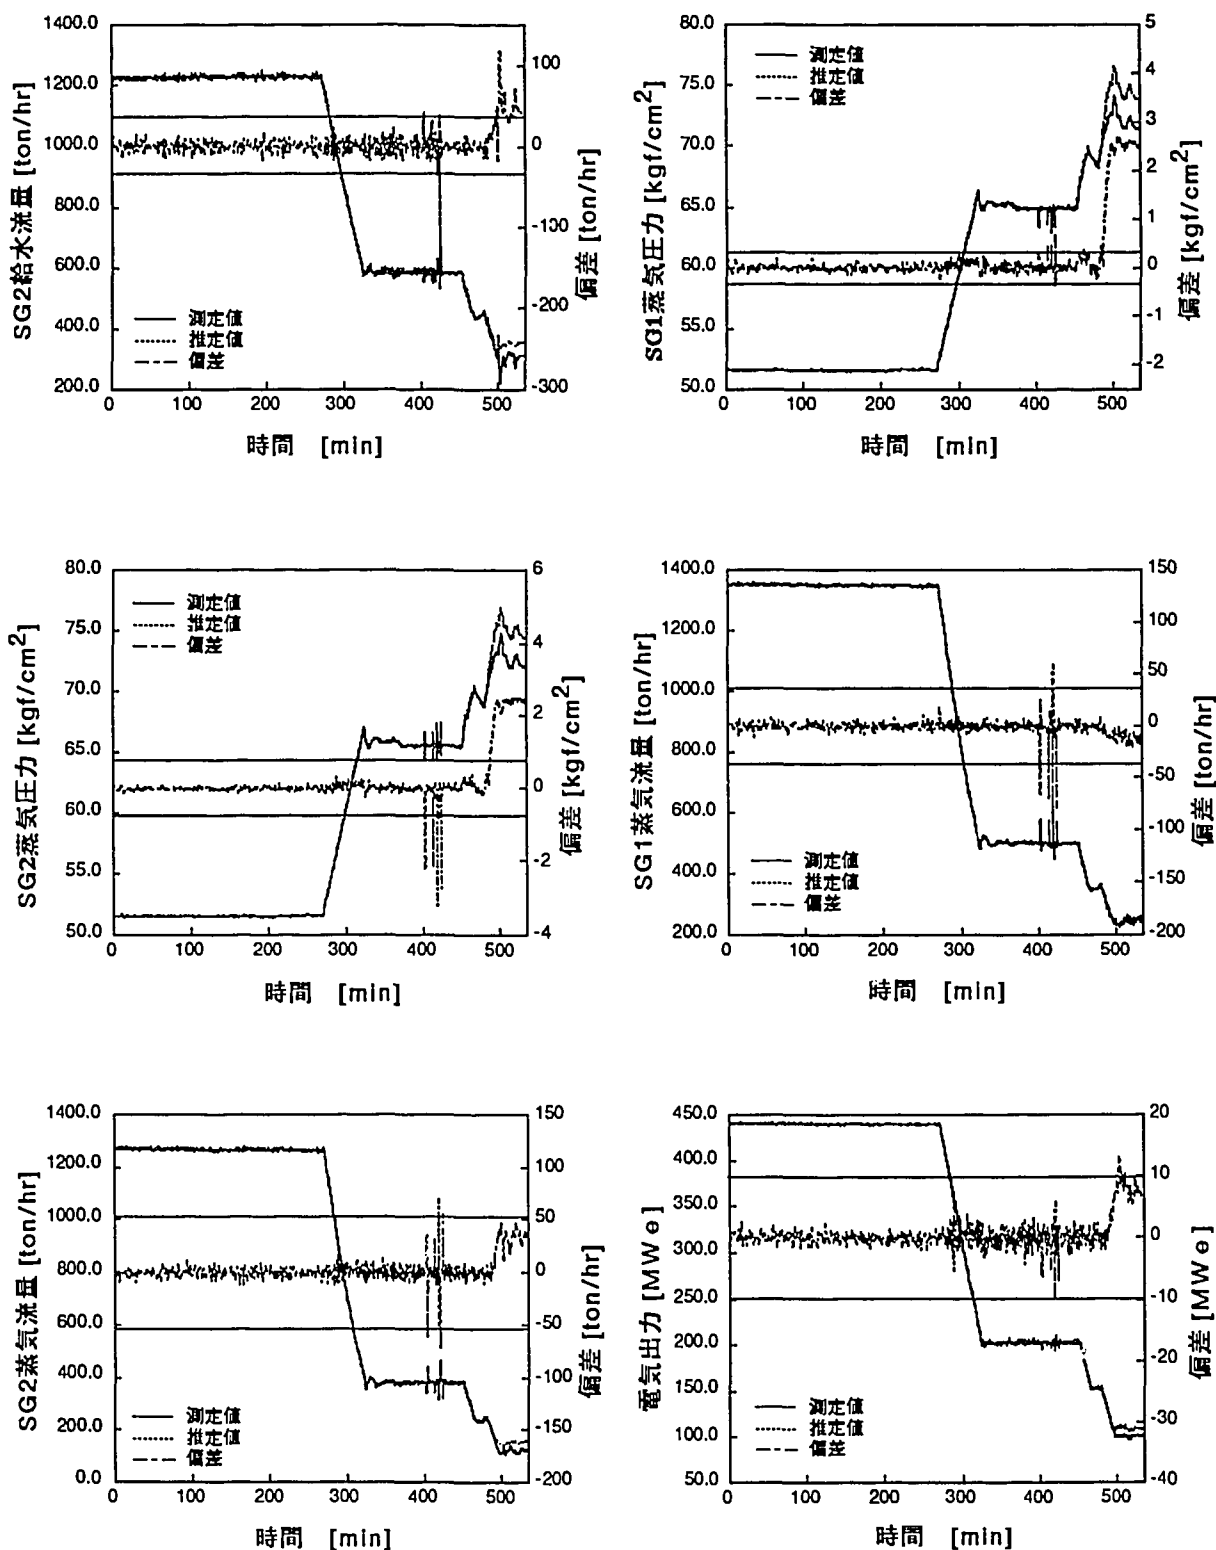


図4.3 ニューラルネットワークによるオンライン監視結果 (続き)




図4.4 蒸気圧力信号のオンライン監視結果 (リンシング部拡大図)



## 5. 結 論

本手法は、ニューラルネットワークに過去の運転データを学習させることにより原子炉のモデルを構築し、実際の信号とこのモデルによる予測値との誤差を監視することによって微少な異常兆候を早期に発見するものである。

用いたニューラルネットワークは、3層からなる階層型で、学習時には誤差逆伝播アルゴリズムを採用した。また運転モードの変更や燃料の燃焼とともに変化していく原子炉特性をモデル化するため、学習過程を初期学習と適応学習に分ける。このような学習方法を用いたニューラルネットワークで原子炉プラントのモデル化を行うと、原子炉起動・停止及び出力運転の広出力範囲にわたって微少な異常兆候を早期検知することが可能であることがわかった。

以上のことから、ニューラルネットワークを原子炉プラントの監視システムとして利用する方法は、その強力な異常検知能力から鑑みて、今後非常に有効になると考えられる。しかし、異常箇所の特定や原因究明などの運転支援を目指した異常検知・診断システムを高度化するためには、ニューラルネットワークだけでなく、知識ベースと推論エキスパートシステムの利用が不可欠である。

## 参 考 文 献

- 1) Uhrig, R.E.: "Potential Application of Neural Networks to the Operation of Nuclear Power Plants", Nuclear Safety, Vol.32 No.1, 1991
- 2) 麻生英樹：ニューラルネットワーク情報処理, 産業図書, 1988
- 3) 石川真澄：忘却を用いたコネクショニストモデルの構造学習アルゴリズム, 人工知能学会, Vol.5, No.5, 1990
- 4) K.Nabeshima, K. Suzuki, E. Türkcan and Ö. Ciftcioglu, "On-line Nuclear Power Plant Monitoring with Neural Network", Proc. of Third International Conference on Nuclear Engineering, Vol.3, pp1551-1556, 1995.
- 5) Nabeshima, K., et al: Real-Time Nuclear Power Plant Monitoring with Adaptively Trained Neural Network, ECN-RX-93-066
- 6) Turkcan, E. et al: Neural networks for real-time NPP monitoring, Nuclear Europe Worldscan, No.11/12, 1993, p.31.

## 付録1 サブルーチン一覧

プログラム…………… REALNNR.FOR

FORTRANで書かれており、以下のサブルーチンから構成されている。

## SUBROUTINE LIST

MAIN	Input Control
NLDTMK	Input Data Control
NEURALL	Main Program of Neural Network
ININET	Network Initialization
NORNET	Input and Output Data Normalization
ITRNET	Backward Calculation of Backpropagation Algorithm
DASKIP	Skipping Data that the Error is Bigger than Certain Limit during Initial Learning
OTNET	Output Data Control
FORCAL	Forward Calculation of Backpropagation Algorithm
RANU2	Random Number Generation
NNTEST	Testing Mode of Neural Network

## 付録2 入出力データ一覧

## (1) 入力データ..... REALNN.DAT

入力データの書式はフリーフォーマットであるが、初期学習モードと監視モードでは形式が大きく異なる。詳細は付録3～6を参照。

## (2) プラント信号データ..... \*\*\*\*\*.FRM

時刻及び32チャンネルのプラント信号からなるデータで、データセット名は、(1)入力データの中(付録3の3.)で指定される。また、32チャンネルの信号の内、ニューラルネットワークで用いる信号は、同様に、(1)入力データの中(付録3の3.3～3.7)で指定される。なお、このデータの書式は、付録7の様になっている。

## (3) ネットワーク情報データ..... OUTNET\*.DAT

ネットワーク情報データは、初期学習モードで作成され、監視モードの場合にはそれらの情報を基にして推定及び適応学習が行われていく。したがって、監視モードの際には、必ず参照すべき過去のネットワーク情報データが存在しなければならない。このデータ名の中の下線部の1文字は、一桁の数字またはアルファベットで、入力データREALNN.DATの中で指定する(付録3の4.参照)。また同時に、この1文字を使用した出力データ、プロット用データ、異常記録データが、自動的に作成される。付録3の例では、入力データREALNN.DATで、"A"と指定されている。

監視モード終了時には、適応学習によって更新されたネットワーク情報一式が、このデータの最後に付加される。そのため、このデータを見ると、これまで適応学習によってどのように重み等が変化しているのかがわかる。

## (4) 出力データ..... OUT\*.DAT

初期学習モードでは、学習時のいろいろな情報が学習回数とともに書き込まれる(付録7参照)。一方、監視モードでは、実測値と推定値、偏差及び、異常が発生した信号が出力される。

## (5) プロット用データ..... OUTFPLT\*.DAT

オフラインプロット用に、各時刻の実測値と推定値、偏差が記録される。

## (6) 異常記録データ..... OUTER\*.DAT

初期学習モードでは、学習回数10回毎の誤差の二乗和が書き込まれる。監視モードでは、異常を検知した場合にのみ、異常発生時間、異常信号等を記録する。

## 付録3 入力データ形式 (初期学習モード)

C

C----- Input Date for FIRST LEARNING ( Initial Learning) MODE -----

C

1. \$' First Learning (F) or Real Time Learning (R) ?'  
F
2. \$'OUTPUT FILE NAME (.NNA) ?'  
B19MY.NNA ..... input data for Other Neural Network program (ASCII Format)
3. \$'INPUT FILE NAME (.FRM) ? (IF STOP, RETURN OR Z) '  
B19019C.FRM
  - 3.1 \$'FIRST AND END POINT OF DATA ?'  
1 13777
  - 3.2 \$'SKIP NUMBER ? (IF NO SKIP, PLEASE TYPE 1) '  
8
  - (1) 3.3 - 3.10 is only for first time
    - 3.3 \$' How many input channels do you need ? '  
12
    - \*\*\* (2) iteration (number of input node)
    - \* 3.4 \$'Which channel do you need for No.1 input ?'  
\* 1  
\*
    - \* 3.5.a1 \$'Do you want to make difference data for input? (Y/N)'  
\* N  
\* ∴
    - \* 3.4 \$'Which channel do you need for No.4 input ?'  
\* 15  
\*
    - \* 3.5.b1 \$'Do you want to make difference data for input? (Y/N)'  
\* Y  
\*
    - \* 3.5.b2 \$'Which channel do you use for difference data ?'  
\* \$' Ch. 15 - which ch. No. ? '  
\* 14  
\* ∴

```

*      3.4      $ 'Which channel do you need for No.12 input ?'
*
*      29
*
*      3.5.a1   $ 'Do you want to make difference data for input? (Y/N)'
*
*      N
***(2)

3.6     $ ' Are you sure ? (Y/N)'
        Y

3.7     $ ' How many output channels do you need ? '
        $ ' If it is same as input, please type 0 ' <--- auto-associative mode
***(3) auto-associative mode (output channel is exactly same as input)
        3.7a   0

***(3') hetero associative mode ( iteration of output node)
*      3.7b1   1
*
*      3.7b1    $ 'Which channel do you need for No.',I,'output ?'
*
*      29
*      3.7b2    $ 'Do you want to make difference data for output? (Y/N)'
*
*      N
***(3')

3.8     $ ' Are you sure ? (Y/N)'
        Y

***(4) iteration (number of output node)
*      3.9     $ 'Allowed absolute error of channel No.',1
*
*      7.9766
*
*      :
*
*      :
*
*      :
*      3.9     $ 'Allowed absolute error of channel No.',12
*
*      0.30948
***(4)

3.10    $ ' How many previous step do you use ?'
        0 ..... ( Now only 0 is available for auto-associative network )

```

—(1) end

3. \$ 'INPUT FILE NAME (.FRM) ? (IF STOP, RETURN OR Z) '  
 B19068A.FRM
- 3.1 \$ 'FIRST AND END POINT OF DATA ? '  
 1 1200
- 3.2 \$ 'SKIP NUMBER ? (IF NO SKIP, PLEASE TYPE 1) '  
 1
3. \$ 'INPUT FILE NAME (.FRM) ? (IF STOP, RETURN OR Z) '  
 Z
4. \$ ' OUTPUT FILE NUMBER (0-9,A-Z)? '  
 A
- |   |              |     |                                              |
|---|--------------|-----|----------------------------------------------|
| c | outa.dat     | ... | output data                                  |
| c | outera.dat   | ... | sum of square error every 10 learning cycles |
| c | outfplta.dat | ... | data for plotting ( FRM Format )             |
| c | outneta.dat  | ... | network information data                     |
5. \$ ' NUMBER OF HIDDEN UNIT ? '  
 8
6. \$ ' DO YOU WANT TO CHANGE NORMALIZING FACTOR (Y/N) ? '  
 \$ ' DEFAULT : INPUT(0.1 - 0.9) OUTPUT(0.1 - 0.9) '
- \*\*\* (5) use default normarization factor
- 6.a N
- \*\*\* (5') change the normalization factor of input and output data
- \* 6.b1 Y
- \* 6.b2 \$ ' TYPE MIN. VALUE AND MAX. VALUE OF NORMALIZED OUTPUT '  
 \*\*\* 0.2 0.8
7. \$ ' NUMBER OF CHANGE ETA AND ALPHA ? '  
 3
8. \$ ' CYCLE OF CHANGE ETA AND ALPHA ? INPUT ',3  
 50 500 700 ( third one is dummy. )
9. \$ ' ETA ? PLEASE INPUT ',3 (学習率  $\eta$ )  
 1.2 0.6 0.2
10. \$ ' ALPHA ? PLEASE INPUT ',3 (モーメントム係数  $\alpha$ )  
 0.6 0.3 0.2

- 11. \$ ' INITIAL RANDOM VALUE (1-10000)? '  
60
- 12. \$ ' SEQUENTIAL LEARNING (S) OR RANDOM LEARNING (R) '  
R
- 13. \$ ' DO YOU WANT TO USE OLD NETWORK (Y/N) ? '  
N
- 14. \$ ' DO YOU WANT TO CHANGE PRINT INTERVAL (Y/N) ? '  
\$ 'Default is 50 100 500 1000 2000 3000 5000'

\*\*\* (6) use default print interval ( last time interval means learning cycle )  
14.a N

\*\*\* (6') change print interval

- \* 14.b1 Y
- \*
- \* 14.b2 \$ ' TYPE INTERVAL ( LAST IS NO.7 ) '  
\*\*\* 5 100 200 300 500 700 1000

- 15. \$ ' DO YOU WANT TO SKIP THE DATA HAS BIG ERROR(Y/N) ?'

\*\*\* (7) No learning data is skipped even if the learning error is big.  
15.a N

\*\*\* (7') Some learning data are skipped if the learning error is still big after certain learning  
\* cycle.

- \* 15.b1 Y
- \*
- \* 15.b2 \$ ' TYPE LEARNING CYCLE WHEN YOU WANT TO SELECT DATA '  
\* \$ ' AND THE ERROR LIMIT (NORMALIZED ERROR > ?) '  
\*\*\* 500 0.07

付録4 入力データ例 (初期学習モード)

F  
B19.NNA  
B19LRN1.FRM  
1 1825  
3  
14  
1  
N  
5  
N  
6  
N  
7  
N  
8  
N  
15  
Y  
14  
17  
Y  
16  
18  
N  
19  
N  
24  
N  
25  
N  
26  
N  
27  
N  
29  
N  
Y  
0



Y

7.9766

0.37170

0.35750

0.30948

0.34254

0.44186

0.40126

14.2556

14.2458

0.18146

0.23232

11.4396

14.0964

1.5777

0

B19170a2.FRM

2200 3000

2

Z

0

12

Y

-0.5 0.5

0.15 0.85

3

150 500 1000

1.2 0.6 0.1

0.6 0.3 0.1

3279520

R

N

Y

50 100 200 300 500 1000 2000

N

## 付録5 入力データ形式 (適応学習モード)

C

C----- Input Data for TESTING and ADAPTIVE LEARNING -----

C

1. \$ 'First Learning (F) or Real-Time Learning (R)  
R
2. \$ 'INPUT FILE NAME (.FRM) ? '  
B19404.FRM
3. \$ 'FIRST AND END POINT OF DATA ? '  
1 2000
4. \$ ' How many steps do you use for Training Window ? '  
30
5. \$ ' OUTPUT FILE NUMBER (0-9)? '  
B ... You need the network information data "outnetb.dat" before the program  
running.
6. \$ ' ETA ? PLEASE INPUT ' (学習率  $\eta$ )  
0.005
7. \$ ' ALPHA ? PLEASE INPUT ' (モーメントム係数  $\alpha$ )  
0.005
8. \$ ' ALLOWED TESTING & LEARNING ERROR (NORMALIZED) ? '  
1.25 1.2

付録6 入力データ例 (適応学習モード)

R  
B19404.FRM  
1 2000  
30  
B  
0.005  
0.005  
1.25 1.2

## 付録7 プラント信号データ例

Time:	Blk/Pnt:	ch:	1	2	3	4	5
			6	7	8	9	10
			11	12	13	14	15
			16	17	18	19	20
			21	22	23	24	25
			26	27	28	29	30
			31	32			
19:59:21	1	1	0.11698E+04	0.14046E+04	0.12618E+04	0.14973E+04	0.15777E+03
			0.15873E+03	0.53846E+02	0.54423E+02	0.56828E+01	0.54342E+01
			0.82811E+03	0.81379E+03	0.25751E+04	0.28241E+03	0.30779E+03
			0.28409E+03	0.30682E+03	0.12435E+04	0.12323E+04	-.27260E+00
			-.74131E-01	0.27174E+03	0.27655E+03	0.51643E+02	0.51615E+02
			0.13475E+04	0.12691E+04	0.15820E+03	0.44017E+03	0.21243E+03
			0.21064E+03	0.10804E+02			
19:59:25	2	1	0.11613E+04	0.13924E+04	0.12563E+04	0.14851E+04	0.15777E+03
			0.15873E+03	0.53944E+02	0.54520E+02	0.57133E+01	0.54647E+01
			0.82858E+03	0.81379E+03	0.25580E+04	0.28216E+03	0.30755E+03
			0.28433E+03	0.30657E+03	0.12425E+04	0.12333E+04	-.28190E+00
			-.58626E-01	0.27174E+03	0.27655E+03	0.51570E+02	0.51542E+02
			0.13436E+04	0.12710E+04	0.15820E+03	0.43978E+03	0.21243E+03
			0.21064E+03	0.10804E+02			
19:59:29	3	1	0.11692E+04	0.14009E+04	0.12599E+04	0.14912E+04	0.15777E+03
			0.15873E+03	0.53846E+02	0.54520E+02	0.56706E+01	0.54342E+01
			0.82858E+03	0.81379E+03	0.25738E+04	0.28216E+03	0.30755E+03
			0.28433E+03	0.30682E+03	0.12435E+04	0.12245E+04	-.24469E+00
			-.58626E-01	0.27174E+03	0.27655E+03	0.51570E+02	0.51542E+02
			0.13494E+04	0.12710E+04	0.15820E+03	0.44112E+03	0.21243E+03
			0.21064E+03	0.10804E+02			
19:59:33	4	1	0.11717E+04	0.13973E+04	0.12612E+04	0.14863E+04	0.15777E+03
			0.15873E+03	0.53846E+02	0.54520E+02	0.56645E+01	0.54159E+01
			0.82858E+03	0.81379E+03	0.25745E+04	0.28216E+03	0.30755E+03
			0.28409E+03	0.30682E+03	0.12464E+04	0.12333E+04	-.26950E+00
			-.80334E-01	0.27174E+03	0.27655E+03	0.51570E+02	0.51542E+02
			0.13524E+04	0.12710E+04	0.15820E+03	0.44055E+03	0.21243E+03
			0.21064E+03	0.10804E+02			
19:59:37	5	1	0.11686E+04	0.13991E+04	0.12526E+04	0.14931E+04	0.15777E+03
			0.15873E+03	0.54041E+02	0.54423E+02	0.56828E+01	0.54525E+01
			0.82858E+03	0.81379E+03	0.25653E+04	0.28216E+03	0.30779E+03
			0.28409E+03	0.30682E+03	0.12445E+04	0.12342E+04	-.24779E+00
			-.83435E-01	0.27174E+03	0.27655E+03	0.51570E+02	0.51542E+02
			0.13465E+04	0.12642E+04	0.15820E+03	0.44036E+03	0.21243E+03
			0.21064E+03	0.10804E+02			

付録8 出力データ例 (初期学習モード)

Tue Aug 29 13:31:41 1995

+++ NEURAL NETWORK PROGRAM FOR BP +++ VER.3.0 BY K.NABESHIMA

INPUT LAYER : 12  
 HIDDEN LAYER : 8  
 OUTPUT LAYER : 12

\*\*\* RANDOM LEARNING \*\*\*

\*\*\* LEARNING PATTERNS \*\*\*

NL = 912

CYCLE	1	---	150	---	500	---	1000	---
ETA		1.20		0.60		0.10		0.10
ALPHA		0.60		0.30		0.10		0.10

INITIAL RANDOM NUMBER : 80

	UNIT	MIN	MAX
INPUT	1	462.38000	1304.69995
INPUT	2	57.45900	78.26100
INPUT	3	58.81700	79.91200
INPUT	4	9.03000	26.85000
INPUT	5	7.83000	25.66000
INPUT	6	401.64999	1347.00000
INPUT	7	387.53000	1334.80005
INPUT	8	55.30500	77.57000
INPUT	9	54.83700	77.68800
INPUT	10	260.53000	1395.30005
INPUT	11	167.49001	1340.40002
INPUT	12	102.90000	478.64999
OUTPUT	1	462.38000	1304.69995
OUTPUT	2	57.45900	78.26100
OUTPUT	3	58.81700	79.91200
OUTPUT	4	9.03000	26.85000
OUTPUT	5	7.83000	25.66000
OUTPUT	6	401.64999	1347.00000
OUTPUT	7	387.53000	1334.80005
OUTPUT	8	55.30500	77.57000
OUTPUT	9	54.83700	77.68800
OUTPUT	10	260.53000	1395.30005
OUTPUT	11	167.49001	1340.40002
OUTPUT	12	102.90000	478.64999

1

\*\*\* NORMALIZED DATA LIST \*\*\*

LEARNING DATA : MIN = -0.50 MAX = 0.50  
 TESTING DATA : MIN = 0.10 MAX = 0.90

1

\*\*\* ITERATION = 1500 \*\*\*

I	WI (I, J)							
1	0.04302	-1.42762	-0.53447	1.04215	0.00764	-0.18617	-0.93568	-0.31572
2	-0.91032	-0.70933	2.17140	-0.60669	1.14803	-1.12746	-0.91013	0.87157
3	-0.88709	-1.10224	1.74051	-0.49598	1.14290	-0.90652	-1.20847	0.86854
4	1.05534	-0.75806	0.07780	0.44133	-0.13865	-0.23513	-0.41861	-0.19798
5	1.76915	-0.19121	-0.61828	0.49512	-0.44482	-1.29751	-1.66253	0.10679
6	0.68899	-0.39906	0.94942	1.00756	-0.25241	0.29453	-1.13081	0.06898
7	0.83282	-0.29953	0.14400	0.72803	0.07831	0.31145	-1.11360	0.10997
8	-0.40845	-1.28136	1.54617	-0.45927	1.07849	-1.08007	-1.22034	0.61839
9	-0.06386	-0.48927	1.62606	-0.24621	0.37228	-1.16512	-0.51472	1.12447
10	1.59106	0.61117	0.09321	0.59092	0.09207	0.77193	-0.71920	-0.74800
11	1.15017	-0.04564	0.18893	0.32124	0.16703	0.71193	-0.66744	-0.50426
12	-1.04271	-2.21962	0.43780	1.20948	1.77293	2.81144	1.84114	-1.59989

I	WO (I, J)					
1	0.5121	-1.5804	-1.6739	1.6190	2.4849	1.7921
	1.7931	-1.6522	-1.5803	2.1982	2.0540	-0.7403
2	-2.1123	-0.4338	-0.5095	-1.7465	-1.0847	-1.3525
	-1.2293	-0.1718	-0.3676	-0.6100	-0.6721	-2.7030
3	-0.9357	2.2482	2.4990	-1.3124	-1.7823	-0.5446
	-0.9800	2.2026	2.3647	-0.7203	-0.3796	-0.8929
4	2.6492	-1.5275	-1.3038	1.5657	1.1582	2.2452
	2.0073	-1.4506	-1.3007	1.8364	1.8986	1.9868
5	-1.3005	1.5039	1.4496	-1.4165	-1.0081	-1.1220
	-0.8862	1.7219	1.6056	-0.8500	-0.9659	0.5528
6						

	1.8502	-1.4399	-1.2901	0.9463	-0.5594	1.1550
	1.2457	-1.5559	-1.6528	1.2265	1.5655	3.6381
7						
	-1.7097	-1.1086	-0.8452	-1.1338	-1.7715	-1.4866
	-1.6498	-0.9501	-0.7786	-0.9626	-0.9381	0.9558
8						
	-0.3609	1.2687	1.3291	-0.7009	-0.9207	-0.6931
	-0.8135	1.1348	1.2208	-1.1866	-1.0735	-1.5780

WTI(I)

4.6685 -0.2230 3.8365 -3.8760 -0.7833 4.1142 0.5297 -0.1706

WTO(J)

-0.5483 -0.4183 -0.1325 -1.1602 -1.3113 -0.2589 -0.3853 -0.0940  
 -0.0396 0.0543  
 0.1668 0.4477

ETA = 0.10

ALPHA = 0.10

LEARNING PATTERN = 912

SKIP PATTERN = 0

NORMALIZED LEARNING ERROR\*\*2 = 0.25132

CH.	PATTERN NUMBER	MAX ERROR (NORM)	MAX ERROR (PHYSIC)
1	284	0.023169	19.51536
2	807	0.016540	0.34407
3	664	0.016238	0.34254
4	752	0.027602	0.49187
5	853	0.027382	0.48822
6	422	0.030322	28.66473
7	87	0.032089	30.39687
8	806	0.008961	0.19952
9	844	0.012192	0.27861
10	589	0.021317	24.19041
11	589	0.027393	32.12912
12	150	0.016602	6.23836

1

\*\*\* ITERATION = 1500 \*\*\*

SUM DIF\*DIF = 0.2513

+++ CALCULATION FINISHED +++

Tue Aug 29 13:42:12 1995

# 国際単位系 (SI) と換算表

表1 SI基本単位および補助単位

量	名称	記号
長さ	メートル	m
質量	キログラム	kg
時間	秒	s
電流	アンペア	A
熱力学温度	ケルビン	K
物質	モル	mol
光度	カンデラ	cd
平面角	ラジアン	rad
立体角	ステラジアン	sr

表3 固有の名称をもつSI組立単位

量	名称	記号	他のSI単位による表現
周波数	ヘルツ	Hz	s <sup>-1</sup>
力	ニュートン	N	m·kg/s <sup>2</sup>
圧力, 応力	パスカル	Pa	N/m <sup>2</sup>
エネルギー, 仕事, 熱量	ジュール	J	N·m
工率, 放射束	ワット	W	J/s
電気量, 電荷	クーロン	C	A·s
電位, 電圧, 起電力	ボルト	V	W/A
静電容量	ファラド	F	C/V
電気抵抗	オーム	Ω	V/A
コンダクタンス	ジーメンズ	S	A/V
磁束	ウェーバ	Wb	V·s
磁束密度	テスラ	T	Wb/m <sup>2</sup>
インダクタンス	ヘンリー	H	Wb/A
セルシウス温度	セルシウス度	°C	
光束	ルーメン	lm	cd·sr
照射度	ルクス	lx	lm/m <sup>2</sup>
放射能	ベクレル	Bq	s <sup>-1</sup>
吸収線量	グレイ	Gy	J/kg
線量当量	シーベルト	Sv	J/kg

表2 SIと併用される単位

名称	記号
分, 時, 日	min, h, d
度, 分, 秒	°, ', "
リットル	l, L
トン	t
電子ボルト	eV
原子質量単位	u

1 eV=1.60218×10<sup>-19</sup>J  
1 u=1.66054×10<sup>-27</sup>kg

表4 SIと共に暫定的に維持される単位

名称	記号
オングストローム	Å
バ	b
バール	bar
ガリ	Gal
キュリー	Ci
レントゲン	R
ラド	rad
レム	rem

1 Å=0.1 nm=10<sup>-10</sup> m  
1 b=100 fm<sup>2</sup>=10<sup>-28</sup> m<sup>2</sup>  
1 bar=0.1 MPa=10<sup>5</sup> Pa  
1 Gal=1 cm/s<sup>2</sup>=10<sup>-2</sup> m/s<sup>2</sup>  
1 Ci=3.7×10<sup>10</sup> Bq  
1 R=2.58×10<sup>-4</sup> C/kg  
1 rad=1 cGy=10<sup>-2</sup> Gy  
1 rem=1 cSv=10<sup>-2</sup> Sv

表5 SI接頭語

倍数	接頭語	記号
10 <sup>18</sup>	エクサ	E
10 <sup>15</sup>	ペタ	P
10 <sup>12</sup>	テラ	T
10 <sup>9</sup>	ギガ	G
10 <sup>6</sup>	メガ	M
10 <sup>3</sup>	キロ	k
10 <sup>2</sup>	ヘクト	h
10 <sup>1</sup>	デカ	da
10 <sup>-1</sup>	デシ	d
10 <sup>-2</sup>	センチ	c
10 <sup>-3</sup>	ミリ	m
10 <sup>-6</sup>	マイクロ	μ
10 <sup>-9</sup>	ナノ	n
10 <sup>-12</sup>	ピコ	p
10 <sup>-15</sup>	フェムト	f
10 <sup>-18</sup>	アト	a

(注)

- 表1-5は「国際単位系」第5版, 国際度量衡局 1985年刊行による。ただし, 1 eV および 1 uの値はCODATAの1986年推奨値によった。
- 表4には海里, ノット, アール, ヘクトールも含まれているが日常の単位なのでここでは省略した。
- barは, JISでは流体の圧力を表わす場合に限り表2のカテゴリに分類されている。
- EC閣僚理事会指令では bar, barn および「血圧の単位」mmHgを表2のカテゴリに入れている。

## 換算表

力	N (=10 <sup>5</sup> dyn)	kgf	lbf
	1	0.101972	0.224809
	9.80665	1	2.20462
	4.44822	0.453592	1

粘度 1 Pa·s(N·s/m<sup>2</sup>)=10 P(ポアズ)(g/(cm·s))

動粘度 1 m<sup>2</sup>/s=10<sup>4</sup>St(ストークス)(cm<sup>2</sup>/s)

圧	MPa (=10 bar)	kgf/cm <sup>2</sup>	atm	mmHg(Torr)	lbf/in <sup>2</sup> (psi)
	1	10.1972	9.86923	7.50062 × 10 <sup>3</sup>	145.038
力	0.0980665	1	0.967841	735.559	14.2233
	0.101325	1.03323	1	760	14.6959
	1.33322 × 10 <sup>-4</sup>	1.35951 × 10 <sup>-3</sup>	1.31579 × 10 <sup>-3</sup>	1	1.93368 × 10 <sup>-2</sup>
	6.89476 × 10 <sup>-3</sup>	7.03070 × 10 <sup>-2</sup>	6.80460 × 10 <sup>-2</sup>	51.7149	1

エネルギー・仕事・熱量	J (=10 <sup>7</sup> erg)	kgf·m	kW·h	cal(計量法)	Btu	ft·lbf	eV	1 cal = 4.18605 J(計量法) = 4.184 J(熱化学) = 4.1855 J(15 °C) = 4.1868 J(国際蒸気表) 仕事率 1 PS(仏馬力) = 75 kgf·m/s = 735.499 W
	1	0.101972	2.77778 × 10 <sup>-7</sup>	0.238889	9.47813 × 10 <sup>-4</sup>	0.737562	6.24150 × 10 <sup>18</sup>	
	9.80665	1	2.72407 × 10 <sup>-6</sup>	2.34270	9.29487 × 10 <sup>-3</sup>	7.23301	6.12082 × 10 <sup>19</sup>	
	3.6 × 10 <sup>6</sup>	3.67098 × 10 <sup>5</sup>	1	8.59999 × 10 <sup>5</sup>	3412.13	2.65522 × 10 <sup>6</sup>	2.24694 × 10 <sup>23</sup>	
	4.18605	0.426858	1.16279 × 10 <sup>-6</sup>	1	3.96759 × 10 <sup>-3</sup>	3.08747	2.61272 × 10 <sup>19</sup>	
	1055.06	107.586	2.93072 × 10 <sup>-4</sup>	252.042	1	778.172	6.58515 × 10 <sup>21</sup>	
	1.35582	0.138255	3.76616 × 10 <sup>-7</sup>	0.323890	1.28506 × 10 <sup>-3</sup>	1	8.46233 × 10 <sup>18</sup>	
	1.60218 × 10 <sup>-19</sup>	1.63377 × 10 <sup>-20</sup>	4.45050 × 10 <sup>-26</sup>	3.82743 × 10 <sup>-20</sup>	1.51857 × 10 <sup>-22</sup>	1.18171 × 10 <sup>-19</sup>	1	

放射能	Bq	Ci
	1	2.70270 × 10 <sup>-11</sup>
	3.7 × 10 <sup>10</sup>	1

吸収線量	Gy	rad
	1	100
	0.01	1

照射線量	C/kg	R
	1	3876
	2.58 × 10 <sup>-4</sup>	1

線量当量	Sv	rem
	1	100
	0.01	1



ニューラルネットワークによる原子力プラント監視手法と実用への応用