

ニューラルネットワークによる過渡事象の診断

Study of a Transient Incident Identification System Using a Neural Network

倉田 敏一 (Toshikazu Kurata)* 小林 修二 (Shuji Kobayashi)*
 白崎 秀和 (Hidekazu Shirosaki)† 増田 次郎 (Jiro Masuda)‡
 大嶽 通明 (Michiaki Ohtake)‡ 清水 勝 (Masaru Simizu)‡
 笠井 雅夫 (Masao Kasai)§

要約 本論文は、PWRプラントに発生した異常過渡事象をニューラルネットワークにより同定する新しい方法について述べたものである。

ニューラルネットワークで過渡事象を同定するには、それぞれの過渡事象発生時における各種プラントパラメータの時系列変化の特徴を見極め、適切な特徴量を定義し入力しなければならない。このため、事象が発生した時のプラントパラメータの動き（以下 変化パターンと言う）をテンプレートで表現する方法を考案した。この方法は予め設定した関数を用いて、プラントパラメータの時系列データを最小二乗法でフィッティングし、関数の特性定数の符号を特徴量としてニューラルネットワークに入力し事象の同定に用いたものである。

ニューラルネットワークによる同定は学習と診断の2過程から成り立っている。即ち、まず、学習課程において学習用入力に対して正しい診断結果が出力されるようにニューラルネットワークの構成を設定する。診断過程においては診断用入力に対して正しい診断結果が得られたかどうか試験する。多数の例について試験を行った結果、階層構成型ネットワークにより良好な診断結果が得られた。

プラントにおける実機診断には、過渡事象発生中の任意の時刻に診断できるようにするため、フィッティング処理速度の早いテンプレート（関数の特性定数の数を少なくしたテンプレート）が一番適していることがわかった。

キーワード ニューラルネットワーク、過渡事象、PWRプラント、プラントパラメータ、テンプレート、最小二乗法、階層構成型ネットワーク

Abstract This paper describes a new technique for identifying abnormal transient events occurring in a PWR plant. On-site identification is achieved by means of a hierarchical system of neural networks. The system consists of a discriminator and two subsections, each of them being a neural network.

The transient sometimes causes reactor trip. Transients that result in reactor trip are differentiated from non-trip events by the discriminator and diagnosed by the trip-subnetwork, while the non-trip events are processed by the non-trip subnetwork.

Input to the system is a set of values which characterize the transient behaviors of the plant(process) parameters. For determining the set of characteristic values, three different types of template functions have been prepared. Each of the functions are represented by a small number of characteristic constants. The characteristic constants are estimated by using the least-squares fitting of one of the functions to the transient. The values of the constants thus determined are used as the inputs data to the system.

The output layer consists of a set of items which are respectively assigned to the events to be identified. The hidden layer of each neural network is adjusted and optimized by "learning" so that correct output is provided for the corresponding "learning" input.

Performing tests on a large number of examples, favorable diagnostic results were obtained. Quick on-site diagnosis during the course of transient incidents occurring in a plant has been achieved by

* (株)原子力安全システム研究所 技術システム研究所
 † (株)原子力安全システム研究所 技術システム研究所
 現 関西電力(株)本店 原子力発電課

‡ 三菱重工業(株)神戸造船所 炉心安全設計部

§ 三菱重工業(株)原子力技術センター新型炉・燃料サイクル技術部

choosing the most suitable template function.

Keywords neural network, transient event, PWR plant, plant parameters, template, least-squares fitting, hierarchical network

1. はじめに

原子力発電プラントの通常運転中に発生する異常事象を運転中に識別し、運転員に必要な情報を提供するモニタリングシステムの開発は、安全性・信頼性の観点からも重要である。異常事象を識別する方法として、AI手法に基づく方法や物理的なモデルを使用する方法が考えられるが、原子力プラントのように複雑なシステムでは、広範な知識の構築やシステム全体のモデリングが困難である。これらに対して、ニューラルネットワークはAI手法における知識の構築に該当する部分を、観測データに基づく「学習」によって行うことが可能であり、また内挿能力にも優れているため簡単に診断できるのが特徴である。

このため、本研究では、PWRプラントの異常事象の識別にニューラルネットワークを適用し、異常

事象をニューラルネットワークを用いて識別できるかどうか検討を行った⁽¹⁾⁽²⁾。

ニューラルネットワークを用いた過渡事象診断は既に報告されているが⁽³⁾⁽⁴⁾⁽⁵⁾、本論文ではプラントパラメータの動きをテンプレートで表現する方法を考案し、その特性定数をニューラルネットワークに入力することにより事象の同定を行った。

2. システム成立性の評価（予備検討）

2.1 対象事象

ニューラルネットワークを用いて、プラントに発生した異常事象の識別が可能か原理の検証を行うため、簡易シミュレータのデータを用いて診断した。

対象事象として安全評価において重要な表1の10事象14ケースを選定した。

表1 対象事象（出力層）

No.	対 象 事 象	試験ケース	診 断	
			学 習	試 験
①	制御棒クラスタバンクの異常な引抜き	ケース①		
②	制御棒クラスタバンクの落下	100ppm/2s (*) 25ppm/2s (*)	ケース②・1 ケース②・2	
③	1次冷却材中のほう素濃度の異常な希釈		ケース③	
④	1次冷却材流量の部分喪失		ケース④	
⑤	蒸気負荷の急増	電気出力100 105 % 電気出力100 110 %	ケース⑤・1 ケース⑤・2	
⑥	SGへの過剰給水	主給水弁 A,B同時120%開 主給水弁 Aのみ120%開	ケース⑥・1 ケース⑥・2	
⑦	SGへの主給水喪失	FWP 1台トリップ 主給水弁A開固着	ケース⑦・1 ケース⑦・2	
⑧	1次冷却材系統の異常な減圧		ケース⑧	
⑨	負荷の喪失		ケース⑨	
⑩	2次系の異常な減圧		ケース⑩	

(*) ホウ素濃度の濃縮により事象模擬

ニューラルネットワークへ入力するパラメータは、それぞれの事象の特徴をうまく表さなければ良好な診断結果が得られないため、次の3種類のパラメータ群を選び診断した。

- 簡易シミュレーから採取できる全18パラメータ
- 専門家が選定した8パラメータ
- 相関行列から求めた相関の強い6パラメータ

2.2 ネットワークの構造

ネットワークの構造を図1に示す。出力層ユニット数は、診断対象の10個に、また、入力層ユニット数については、各プラントパラメータの変化パターンを8箇所の時系列データ点で表現したため[8×プラントパラメータ数]とした。

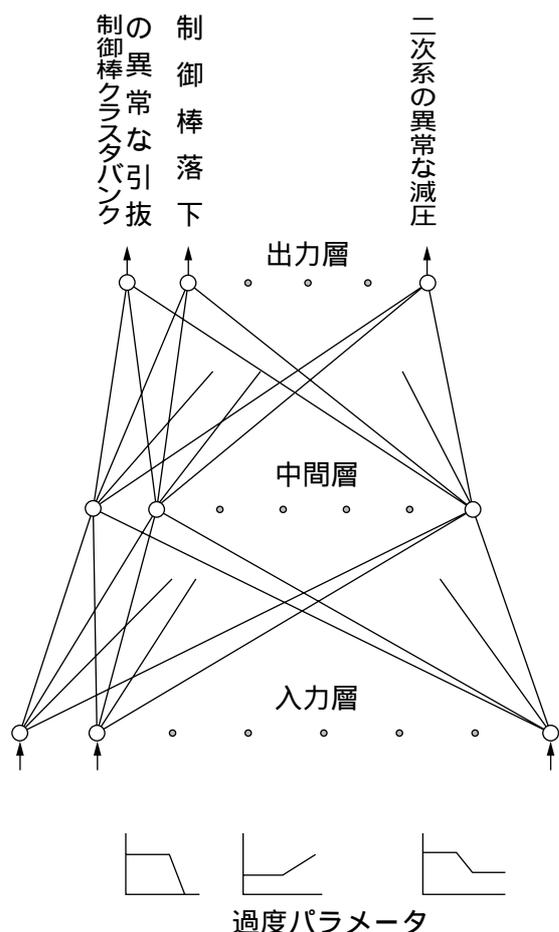


図1 ニューラルネットワークの構造

表2 入力パラメータ

No.	項目	パラメータ数		
		18	8	6
No. 1	原子炉出力			
No. 2	発電機出力			
No. 3	ループ流量A			
No. 4	ループ流量B			
No. 5	SG - A 流量 (蒸気)			
No. 6	SG - A 流量 (給水)			
No. 7	SG - B 流量 (蒸気)			
No. 8	SG - B 流量 (給水)			
No. 9	加圧器 (圧力)			
No.10	加圧器 (水位)			
No.11	A ループ温度 (高温側)			
No.12	A ループ温度 (低温側)			
No.13	B ループ温度 (高温側)			
No.14	B ループ温度 (低温側)			
No.15	SG 圧力A			
No.16	SG 圧力B			
No.17	SG 水位A			
No.18	SG 水位B			

2.3 試験システム

システム成立性の評価を行うため、診断に用いるプラントパラメータ数やそのデータのサンプリング期間を変え、表3に示す5つのシステムを作成した。学習及び試験ケースは表1に示すように、14ケースの内10ケースを学習ケースとし、残りの4ケース(事象の大きさを変えたケースの内、事象の程度の小さなケース)を試験ケースとした。

又、データのサンプル期間として、トリップに至った事象についてはトリップまで、トリップに至らなかった事象については一定期間までのデータ
安定状態に落ちつくまでのデータの2種類とした。

2.4 診断結果

診断に用いるパラメータ数、データのサンプリング期間を変えたニューラルネットワークで診断性能を評価した。学習したケースは全て正しく診断でき

たが試験ケースについては、プラントパラメータ数、データのサンプリング期間の取り方により診断性能は異なるが、ニューラルネットワークを使用して過渡事象を診断できることがわかった。

表3 原理検証の診断結果

システム	データのサンプリング期間		パラメータ数	診断結果	
	トリップ事象	非トリップ事象		学習ケース	試験ケース
1	異常発生からトリップに至るデータ	一定期間	18	100%	25%
2	異常発生からトリップに至るデータ	一定期間	6	100%	75%
3	異常発生からトリップに至るデータ	一定期間	8	100%	0%
4	異常発生からトリップに至るデータ	定常状態に落ちつくまで	18	100%	50%
5	異常発生からトリップに至るデータ	定常状態に落ちつくまで	6	100%	100%

3. テンプレート法による入力処理方法の検討

ニューラルネットワークへ時系列データを入力する方法では、過渡事象発生から事象が落ちつくまでの時系列長を規格化するため、この方法では事象が収束するかトリップした後でしか診断ができない。又、トリップまでの時間が長くなればデータ数も多くなってくる。

ニューラルネットワークで過渡事象を同定するには、それぞれの過渡事象発生時における各種プラントパラメータの時系列変化の特徴を見極め、適切な特徴量を定義し入力しなければならない。このため、事象が発生した時のプラントパラメータの動きをテンプレートで表現する方法を考案した。この方法は予め設定した関数を用いて、プラントパラメータの時系列データを最小二乗法でフィッティングし、関数の特性定数の符号を特徴量としてニューラルネットワークに入力し事象の同定に用いたものである。本手法では時系列長を規格化する必要がないため、

異常発生後トリップを待たずに異常事象を随時診断することができる。

パラメータの変化パターンを表現する方法として、次の3つのテンプレートを考案した。

3.1 テンプレート()

過渡時のプラント・パラメータの変化パターンは、概略次の7つのパターンに分類される。

- 単調増加
- 増加 - 安定(一定)
- 増加 - 減少
- 一定(変化なし)
- 単調減少
- 減少 - 安定(一定)
- 減少 - 増加

これらの7つのパターンは、図2に示す7つの曲線で表され、これらの曲線は下記に示す3つの関数式によって近似できる。

テンプレート関数(1):

$$f(t) = A \cdot (1 - \exp(-t))$$

テンプレート関数(2):

$$f(t) = A \cdot (1 - \exp(-t)) + B \cdot t$$

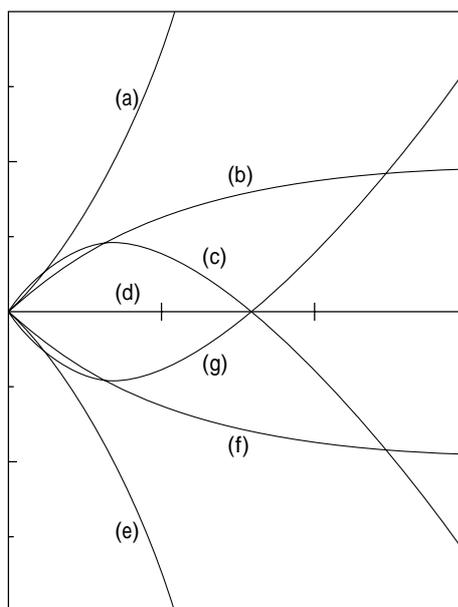


図2 テンプレート(I) 変化パターン

テンプレート関数(3):

$$f(t) = A$$

図2の曲線(a)~(g)は、テンプレート関数(1),(2)および(3)で下記のように表現される。

曲線(a): 関数(1)において、 $A < 0, \tau_1 < 0$ の場合

曲線(b): 関数(1)および関数(2)において、 $A > 0, \tau_1 > 0$ の場合 ($|B| = 0$)

曲線(c): 関数(2)において、 $A > 0, \tau_1 > 0, B < 0$ の場合

曲線(d): 関数(3)の場合、即ち、変化なし

曲線(e): 関数(1)において、 $A > 0, \tau_1 < 0$ の場合

曲線(f): 関数(1)および関数(2)において、 $A < 0, \tau_1 > 0$ の場合 ($|B| = 0$)

曲線(g): 関数(2)において、 $A < 0, \tau_1 > 0, B > 0$ の場合

ニューラルネットワークへの入力データとしては次の情報を入力する。

各テンプレート関数とデータとの2乗誤差(3変量)

3種類のテンプレート関数と実データとの2乗誤差を計算する。最も大きな2乗誤差を1に規格化した時の各関数の値を入力する。

テンプレート関数に現れるパラメータの正負の情報(4変量)

テンプレート関数のパラメータの符号を導入することにより、関数形のみでは表せないプラント・パラメータの変化パターンを表現する。ここで、パラメータ「B」については、関数(2)にしか現れていないため、その符号を取り上げる必要はない。従って、パラメータ「A」と「 τ 」についてのみ符号情報を利用する。ここでは、符号が正の場合に1を、負の場合に0を入力することとした。

以上により、ニューラルネットワークの入力層ユニット数は「7×プラントパラメータ数」となる。

3.2 テンプレート()

テンプレート()より複雑な時系列の変化パターンを表現できるようにするためテンプレート()を考案した。テンプレート()の関数は次のように表せる。

テンプレート関数(1):

$$f(t) = A \cdot \exp(-\tau_1 t) \cdot \{1 \cdot \exp(-\tau_2 t)\}$$

テンプレート関数(2):

$$f(t) = A \cdot \exp(-\tau_1 t) \sin\{2 \exp(-\tau_2 t) \cdot t\}$$

テンプレート関数(3):

$$f(t) = A$$

関数(1)と(2)が、 τ_1, τ_2 , あるいは τ_1, τ_2 によりどのような様な変化パターンを表現することができるか図3に示す。テンプレート()では、表現できる変化パターンの幅が広いことがわかる。

なお、変化が負の方向に振れている場合には、係数Aを負にすることで表現することができる。

ニューラルネットワークへの入力データとしては次の情報を入力する。

各テンプレート関数とデータとの2乗誤差(3変量)

3種類のテンプレート関数と実データとの2乗誤

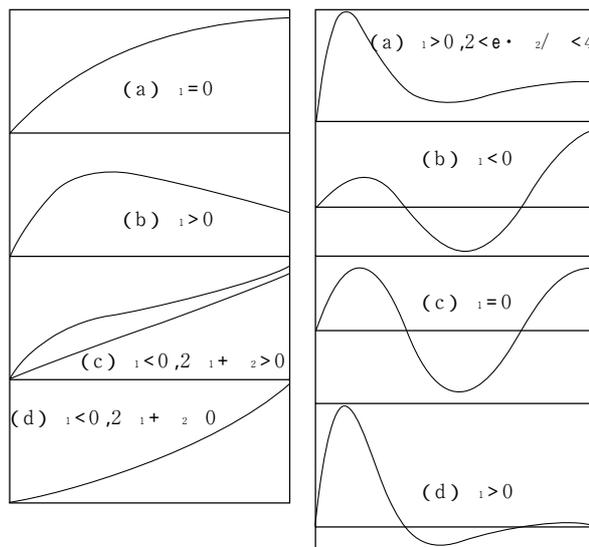


図3 テンプレート()変化パターン

差を計算する。最も大きな2乗誤差を1に規格化した時の各関数の値を入力する。

係数Aの符号(3変量)

3種類のテンプレート関数に現れる係数Aの符号により、下記のようにニューラルネットワークへの入力値を設定する。

A > 0の場合：入力値 = 1.0

A = 0の場合：入力値 = 0.5

A < 0の場合：入力値 = 0.0

テンプレート関数のパラメータ間の関係(2変量)

テンプレート関数(1)および(2)に現れる x_1 は、その符号により時系列データが発散するか収束するかの判定に用いることができる。一方、 x_2 を事象進展の速さを現すパラメータと考え、 $x_2 \cdot t$ あるいは $x_2 \cdot T$ とおくと、 x_1 は $x_1 \cdot T / x_2$ あるいは $x_1 \cdot T / x_2 \cdot t$ と書き換えられる。従って、 x_1 / x_2 あるいは $x_1 / x_2 \cdot t$ の比を取り、シグモイド関数を用い、この比をニューラルネットワークへの入力値として設定する。

以上により、ニューラルネットワークの入力層ユニット数は「8×プラントパラメータ数」となる。

3.3 テンプレート()

テンプレート関数() ()を用いた方法は、それぞれ3つの関数にフィッティングする処理を行い、そのフィッティング情報をニューラルネットワークに入力するものであり、フィッティングのための演算処理に長時間を要する。これは、実機適用時において、非常に大きな制約となる。従って、より高速に処理でき、かつ診断においてテンプレート() ()と同程度の認識性能を与え得るテンプレート()を考案した。

テンプレート()は、定常時と異常発生時の値

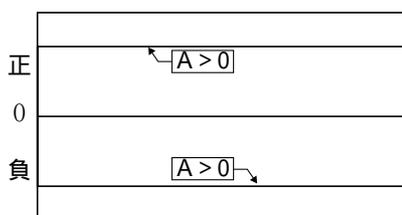


図4 テンプレート()変化パターン

の偏差を求め、その偏差が正か負かという情報をニューラルネットワークに入力するものである。

テンプレート()へのフィッティングから得られる情報は1つのパラメータ当たり1つとなる。

なお、本関数の演算処理に要する時間は、無視し得る程小さい。

4. ニューラルネットワークによる診断

4.1 対象事象

診断の対象とする異常事象としては、設置許可申請書添付十に記載された「異常な過渡変化」と「事故」を対象とした。但し、事故発生後数秒でトリップに至る事象については、診断システムが起動する前に事象が収束すること、故障機器の警報から事象の識別が可能なことから対象外とした。この結果「異常な過渡変化」は9事象、「事故」は5事象を対象とした。

過渡事象時のプラントパラメータについては、実機プラントに近いデータを採取するため、発電所に設置されているエンジニアリングシミュレータを用い、故障機器・外乱等を変えて過渡事象を発生させた時の136ケースのデータを採取した。これらの過渡事象の内、88ケースを学習データに、48ケースを試験データにし、ニューラルネットワークにより診断を行った。

4.2 入力層と出力層

ニューラルネットワークの診断性能は、一般的にネットワークが小さい方が性能が良いとされている。このため、各事象の識別に有効なプラントパラメータが選定できれば入力層の数が少なくなるためネットワークの性能が向上する。

それぞれの事象の特徴を最も良く表しているパラメータは事象毎に異なるため、種々のプラントパラメータ間の相関と制御系の関係から、各事象に共通として有効なパラメータを検討し次の13のパラメータを選定した。

No.01 充てん水流量

No.02 1次冷却材流量

No.03	蒸気発生器主給水流量
No.04	蒸気発生器主蒸気流量
No.05	体積制御タンク水位
No.06	加圧器水位
No.07	蒸気発生器水位
No.08	出力領域平均中性子束
No.09	タービン第1段後圧力
No.10	加圧器圧力
No.11	主蒸気圧力
No.12	1次冷却材平均温度
No.13	格納容器圧力

出力層はニューラルネットワーク上で類似の事象と見なされるものについては、同一の出力層として診断するようにしたため、次の13事象を出力層とした。

No.01	出力運転中の制御棒の異常な引き抜き（含む、制御棒飛び出し）
No.02	制御棒の落下及び不整合
No.03	原子炉冷却材中のほう素の異常な希釈
No.04	原子炉冷却材流量の部分喪失
No.05	蒸気負荷の異常な増加（含む、主蒸気管破断(CV外)）
No.06	蒸気発生器への過剰給水
No.07	主給水流量喪失（含む、主給水管破断(CV外)）
No.08	原子炉冷却系の異常な減圧
No.09	負荷の喪失
No.10	原子炉冷却材喪失
No.11	主給水管破断（CV内）
No.12	主蒸気管破断（CV内）
No.13	蒸気発生器伝熱管破損

4.3 ネットワークの構成

次の2種類のネットワークを作成した。

単一ネットワーク

入力パラメータから直接過渡事象を出力するネットワークで、入力パラメータが過渡事象の特徴を十

分とらえていれば、単純で良いネットワークである。

階層構成型ネットワーク

単一ネットワークでは良い診断性能が得られなかったため図5に示す階層構成型ネットワークを考案した。

本ネットワークでは、メイン・ネットワークにおいて、入力された特徴量からトリップに至る事象が至らない事象かを判断し、トリップに至ると判断された場合にはトリップ事象診断用のサブ・ネットワークが起動され、特徴量から事象が何であるかが診断される。一方、トリップに至らないと判断された場合には、非トリップ事象診断用のサブ・ネットワークが起動され、何の事象かが診断される。

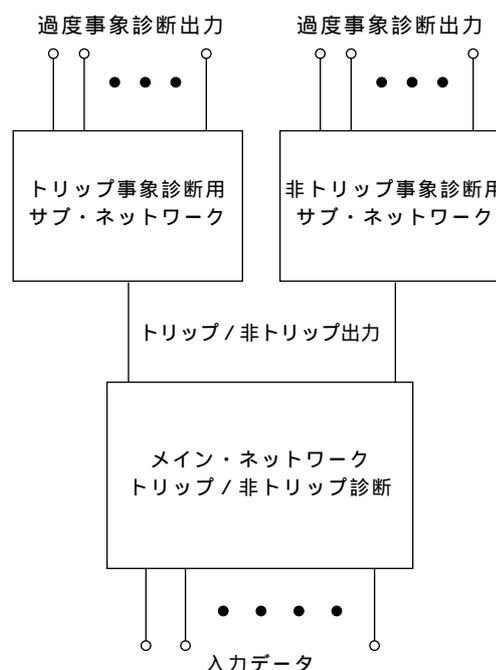


図5 階層構成型ネットワーク

4.4 診断結果

テンプレート(X X)の評価を行うため、各テンプレートについて単一、階層構成型のネットワークをそれぞれ作成し診断試験をした。試験結果を次に示す。

(1) テンプレート()を用いた診断

単一ネットワークを用いた診断では、学習データ・試験データ共診断性能は50%以下であった。

しかし、階層構成型ネットワークでは、トリップ・非トリップに分けることにより過渡事象の変化パターンをうまくとらえることができたため、診断性能は試験データで84.4%まで上げることができた。

(2) テンプレート()を用いた診断

単一ネットワークを用いた診断は、テンプレート関数を変え表現できる過渡変化状況を増やしたが、診断性能は悪く50%以下であった。

しかし、階層構成型ネットワークにするとトリップ・非トリップに分けることにより変化パターンをうまくとらえることができるようになったと共に、表現できる過渡変化状況を増やすことができたため、診断性能はテンプレート()より良くなった。

(3) テンプレート()を用いた診断

テンプレート()を用いた場合、テンプレート()階層構成型ネットワークと同程度の診断性能が得られた。

テンプレート()を使用した場合、テンプレート()とは逆に単一ネットワークの方が階層構成型ネットワークより、診断性能が優れた結果となった。

これは、テンプレート()の場合、各プラントパラメータの変化方向を表す1つの変数のみをネットワークへの入力情報としている。従って、トリップ、非トリップにグループ分けして診断することのメリットはなく、逆に、分けたことによって各グループ内での学習ケースが単一ネットワークに比べて

相対的に減少する結果となり、診断性能が低下すると考えられる。

テンプレート()を用いる場合、テンプレート()を用いた場合に比べ、フィッティングに要する時間は格段に短縮されることとなり、過渡事象発生中の任意時刻での診断が可能となる。

5. 実機システム構成の検討

本手法を実機プラント適用にあたっては、異常の発生時点をも、早くかつ正確に判定する必要がある。この方法としては、日常データにより通常状態の統計的平均値と過渡事象発生時の値を比較する事により、異常の発生点が判定できる。その時点から診断用のデータを採取する。

事前に各過渡事象毎に1分間、3分間、5分間他の定められた時間長のデータで学習しておく。そして過渡事象が発生した場合、事前に学習した時間長と同じ時間長のデータをニューラルネットワークに入力し、過渡事象の診断を行う。

なお、事前学習にはできる限り多くの時間長で行った学習データを用意しておき、事象発生時には、まず最も近い時間長の学習データで診断を行い、その後、定められた時間長のデータを適宜採取し診断するようにする。

6. まとめ

ニューラルネットワークの過渡事象診断への適用に関して、本研究での診断システムの大きな特徴は、ニューラルネットワークへの入力データ処理にテンプレートを導入したことである。診断試験のた

表4 各テンプレートの診断性能結果

	テンプレート(Ⅰ)*		テンプレート(Ⅱ)*		テンプレート(Ⅲ)	
	単一ネットワーク	階層構成型ネットワーク	単一ネットワーク	階層構成型ネットワーク	単一ネットワーク	階層構成型ネットワーク
学習データ	47.2%	97.2%	47.2%	98.6%	98.9%	98.9%
試験データ	31.3%	84.4%	31.3%	87.5%	93.8%	85.4%

* 12パラメータ(C/V圧力除く)

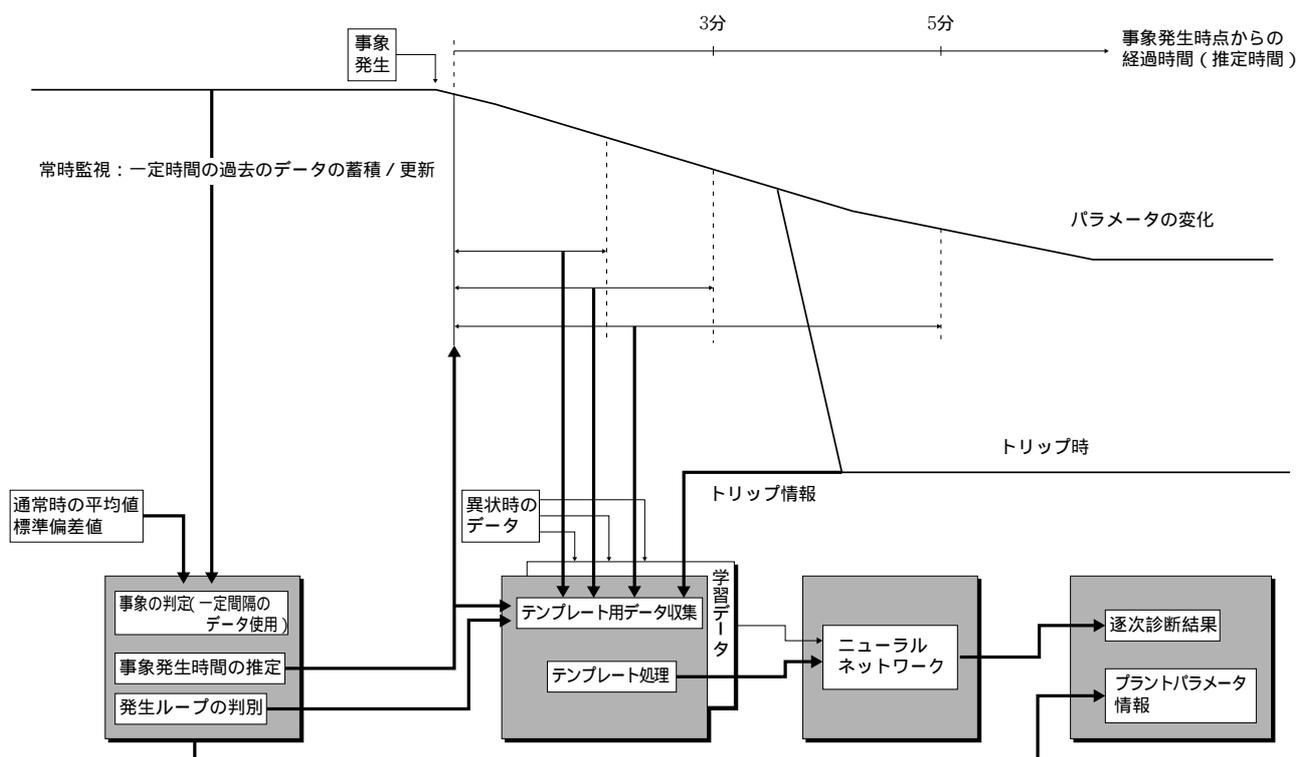


図6 実機システム概念図

め3種類のテンプレートを開発し、これら3種類のテンプレートを使って診断した結果以下のことが言える。

- (1) 入力データ処理方法としては、時系列データ法に比較してテンプレート法が優れている。
- (2) テンプレート()はテンプレート()より優れている。
- (3) テンプレート()の場合、単一ニューラルネットワークでは診断性能は低く、階層構成型(トリップ/非トリップ診断と事象診断)にすることにより優れた性能が得られた。
- (4) テンプレート()を用いた場合、階層構成型ネットワークでは、テンプレート()と同等の性能が得られた。また、単一ネットワークでは、同等以上の性能が得られた。

以上より、入力データ処理法としてテンプレート()を用いた診断の性能が優れていることが確認されたと同時に、テンプレート()は、演算処理

が非常に高速で、実プラントにおいて過渡事象発生中の任意の時刻に診断できる方法として、適したものであると言える。

なお、これまでの検討を踏まえ、このテンプレート()を前提とした、システム全体の概念図を図6に示す。

参考文献

- (1) 石原義尚 白崎秀和 他, PWRプラント異常事象の自動認識システムの検討, 日本原子力学会「1994年秋の大会」予稿集, C39
- (2) Y.Ishihara and T.Kurata et al., Study of a Transient Identification System Using a Neural Network for a PWR Plant Proc. ICONE-4, New Orleans, Vol.1, p1045-, 1996
- (3) Y.Ohga and H.Seki, Abnormal Event Identification in Nuclear Plants Using a Neural Network and Knowledge Processing, Nuclear

- Technology Vol.101, Feb. 1993
- (4) M.Roh, Power Prediction in Nuclear Power Plants Using a Back-Propagation Learning Neural Network, Nuclear Technology Vol.94, May 1991
- (5) H.Kim and S.Lee, Neural Network Model for Estimating Departure from Nucleate Boiling Performance of a Pressurized Water Reactor Core, Nuclear Technology Vol.101, Feb. 1993