

JAERI-Research

96-051



PWRプラントシミュレータを用いた
ニューラルネットワーク原子炉
異常診断技術の研究

1996年10月

鍋島邦彦・野瀬正一*・工藤和彦*・鈴木勝男

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刊している研究報告書です。
入手の問い合わせは、日本原子力研究所研究情報部研究情報課（〒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 Research Information Division, Department of Intellectual Resources, Japan Atomic Energy Research Institute, Tokai-mura, Naka-gun, Ibaraki-ken 319-11, Japan.

© Japan Atomic Energy Research Institute, 1996

編集兼発行 日本原子力研究所
印刷 財団法人原子力弘済会資料サービス

PWRプラントシミュレータを用いた
ニューラルネットワーク原子炉異常診断技術の研究

日本原子力研究所東海研究所原子炉工学部
鍋島 邦彦・野瀬 正一*・工藤 和彦*・鈴木 勝男

(1996年9月4日受理)

本論文では、いろいろな異常事象を容易に模擬できるPWR運転訓練用シミュレータを使用し、ニューラルネットワーク原子力プラント監視システムの有効性を検証する。原子力プラントは、バックプロパゲーション学習則を用いた3層オートアソシアティブネットワークでモデル化される。この異常検知手法の基本的な考え方は、実プラントからのプロセス信号とニューラルネットワークによるモデルからの出力信号の偏差を監視することにある。定常運転時からの4種類の異常事象に対して適用した結果、ニューラルネットワーク監視システムが、従来の警報システムよりも早い段階で異常を検知できることが明らかになった。さらに感度解析を行った結果、ニューラルネットワークによるプラントのモデル化が適切であることが示された。

*九州大学

A Study of Reactor Diagnosis Method with Neural Network
using PWR Plant Simulator

Kunihiko NABESHIMA, Shoichi NOSE*, Kazuhiko KUDO*,
and Katsuo SUZUKI

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

(Received September 4, 1996)

The purpose of this paper is to demonstrate the capability of the nuclear power plant monitoring system with a neural network, using a PWR plant training simulator by which many kinds of anomaly conditions can be easily simulated. The dynamics model of reactor plant was constructed by using a three layered auto-associative neural network with backpropagation learning algorithm. The basic idea of anomaly detection method is to monitor the deviation between process signals measured from an actual plant and corresponding output signals from the neural network plant model. Four kinds of simulated malfunctions caused by equipment failure during steady state operation were selected to evaluate the capability of the neural network monitoring system. The results show that this monitoring system can detect the symptoms of small anomalies earlier than the conventional alarm system. Furthermore, sensitivity analysis makes it clear that the modeling by the neural network is adequate.

Keywords: Neural Network, Plant Diagnosis, PWR Simulator, Monitoring System,
Sensitivity Analysis, Expert System

* Kyushu University

目 次

1. 序 論	1
2. PWRプラントシミュレータの概要	3
2.1 システム構成	3
2.2 シミュレーションモデル	3
3. 原子炉のモデル化	8
3.1 プラント監視信号の選択	8
3.2 換算係数の導出	8
4. ニューラルネットワーク	16
4.1 ニューロンの動作モデル	16
4.2 誤差逆伝播（バックプロパゲーション）アルゴリズム	17
4.3 ネットワーク初期値の設定	17
4.4 初期学習方法	18
4.5 ニューラルネットワークを用いた診断手法	19
5. 感度解析	24
6. 診断結果	26
6.1 主給水部分喪失	26
6.2 大気放出弁の漏洩	27
6.3 一次冷却材部分喪失	27
6.4 体積制御タンク低水位誤検知	27
7. 結 論	45
参考文献	46

Contents

1. Introduction	1
2. Outline of PWR Plant Simulator	3
2.1 System Component	3
2.2 Simulation Model	3
3. Reactor Modeling	8
3.1 Selection of Plant Monitoring Signal	8
3.2 Calculation of Scaling Factor	8
4. Neural Network	16
4.1 Neuron Model	16
4.2 Backpropagation Algorithm	17
4.3 Initial Setting of Network Parameter	17
4.4 Initial Learning Method	18
4.5 Diagnosis Method with Neural Network	19
5. Sensitivity Analysis	24
6. Diagnosis Results	26
6.1 Partial Loss of Feedwater	26
6.2 Leakage of Atmospheric Steam Dump Valve	27
6.3 Partial Loss of Reactor Coolant System Flow	27
6.4 Volume Control Tank Level Control Fails Low	27
7. Conclusions	45
References	46

1 序 論

原子力プラントの運転状態をオンラインで監視することは、プラントの安全性及び運転・保守の観点から非常に重要である。しかしながら、従来の原子力プラント監視システムは、監視する信号が設定された許容範囲を超えた場合にのみ異常を検知し、運転員に知らせる仕組みになっている。そのためゆっくりとした異常事象の場合には、異常がある程度大きくなるまで検知できないという欠点がある。また、原子炉の起動・停止を含めた過渡運転時には、原子炉が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起こりうる。

これまでに、原子炉のオンライン異常診断手法についてのいろいろな研究が行われてきた。炉雑音信号を用いたスペクトル解析は、定常運転時のオンライン異常検知に非常に有効である¹⁾が、原子炉の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、常に運転員が関与する必要があるため、異常検知の自動化は難しい。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原子炉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。原子炉をモデル化し、プラント変数の実際の測定値とモデルによる予測値との誤差に着目してプラント状態を把握することは、監視システムを構築する上で非常に有効な方法である。しかしながら、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システム全体のモデル化は困難である。したがって、物理モデルから異常検知に利用できるだけの精度を達成することは難しい。また、ほとんどの事故解析コードは多くの計算時間を必要とするため、実時間の監視には向いていない。

そこで、ニューラルネットワークに過去の正常な運転データの学習させることによって原子炉のモデル化を行い、原子力プラントの異常診断に利用する方法を考える²⁾。ここでは、主要なプラント変数からなる運転データを入力信号とし、それらをそのまま出力信号として推定させるオートアソシアティブネットワークを用いる。学習によってモデル化されたニューラルネットワークに正常な運転データが入力された場合、各プラント変数のネットワーク推定値（出力信号）は測定値（入力信号）と一致する。もし異常な運転パターンがネットワークに入力された場合、各プラント変数のネットワーク推定値は測定値と大きく異なってくるはずである。したがって、その偏差を監視することにより、微少な異常兆候を検知できる。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、オフラインで初期学習を行い、オンラインで異常診断を行えば、実時間で利用も十分可能である。

現在まで、オランダのPWRプラントを対象とした原子力プラント監視システムの開発を行ってきた。その結果、この監視システムが微少な異常兆候を早期に検知できることが明らかになった³⁾。しかしながら、実際の原子炉からいろいろな種類の事故、故障時のデータを得る機会はほとんどない。そこで今回、運転員訓練用PWRプラントシミュレータにより模擬された原子炉機器の故障時のデータを利用して、ニューラルネットワークを用いた監視シ

システムの有効性を検証する。もちろん、実炉とシミュレータでは原子炉モデルが異なるため、同一のネットワークにはならないが、同じPWR型の原子炉であるのでプラントの挙動は似ており、ネットワークの初期状態の設定、学習過程に対しては同様な手法を利用することが出来る。

本論文の目的は、PWRプラントで様々な異常が発生した場合に、ニューラルネットワークでそれら異常事象を検知できるかどうか、また従来の警報システムと比較してどの程度早く検知できるのかを調べることにある。また、入出力信号間の相関を調べる感度解析を行い、ニューラルネットワークによるプラントのモデル化が適正に行われているかどうかを検証する。

2 PWRプラントシミュレータの概要

本研究で使用したシミュレータはアメリカの PWR (Pressurized Water Reactor) プラント Surry-1 を模擬したものである。この原子炉は電気出力822MWeで、冷却系は3ループから構成されている。

2.1 システム構成

本シミュレータの構成は、Fig. 2. 1 に示すようにモザイクミミックパネルと制御盤を中心に中央演算装置、ディスク、インストラクタ用コンソール、システムコンソール、8チャンネルペンレコーダから成っている。本シミュレータは、フルスケールの運転訓練用シミュレータの制御盤及び表示パネル (Fig. 2. 2) のみを簡略化したもので、プラントモデル等はフルスケールシミュレータと全く同じものが採用されている。しかしながら、これまではシミュレーション結果を、プリンター、ペンレコーダ、ディスプレイ上に表示できるのみで、ディスクに保存することが出来なかった。そこで今回、シミュレータの改造を行い、ミミックパネル及びペンレコーダに出力される計88チャンネルのプラントアナログ信号を取り出した。取り出された信号は、PC上でAD変換され、インターネットを通してワークステーションにオンライン転送される。したがって、シミュレーション結果をオンラインまたはオフラインで利用することが可能となった。本論文では、オフライン解析結果について記述する。

2.2 シミュレーションモデル

本シミュレータは、冷態停止状態から燃焼末期の定格出力までの広い範囲を模擬することが可能であり、その数学モデルでは、主に以下の項を模擬している。

- (1) 炉心は半径方向4領域、軸方向3領域の合計12領域に分割され、各領域に中性子動特性方程式を用いることにより空間的効果が入り込められている。
- (2) ^{135}Xe 、 ^{135}I の反応度効果がモデル化されている。
- (3) 制御棒は4グループに分かれ手動、自動モード切換の他、個別に手動操作できる。
- (4) 核計装は線源領域、中間領域、出力領域の3領域に対し、検出器が模擬されている。
- (5) 一次冷却ループは3ループから成り、各々のループとその付属機器は独立に模擬されている。
- (6) 加圧器のスプレイ (定常スプレイ、補助スプレイ)、ヒーター (定常ヒーター、バックアップヒーター)、逃がし弁、安全弁等の動作特性が含まれている。
- (7) 加圧器の液相、気相の熱水力特性がモデル化されている。
- (8) 蒸気発生器の二次側モデルは、冷却水の自然循環モデル、給水や圧力の急激な変化に

よる水位の変化のモデルが取り扱われている。

- (9) 化学体積制御系にはレットダウン系、充填系、体積制御タンク、ほう酸系が模擬されている。
- (10) 安全注入系は3ループ独立に高圧注入系、低圧注入系が模擬されている。
- (11) 主蒸気系は蒸気ダンプ弁、隔離弁、逆止弁、安全弁、湿分分離器等が含まれている。
- (12) タービン系には、タービンの起動、ターニング、昇速の他、タービントリップ、オーバースピードの模擬も含まれている。
- (13) 発電機系統には、主遮断装置、電圧調整器の他、同期、非同期の状態も模擬されている。
- (14) 主復水系には、復水器、真空ブレイカー、真空ポンプ等が含まれている。
- (15) 給水系は3ループ独立に主給水、補助給水が接続され、給水ヒーター、ドレンタンク、ドレンポンプも模擬されている。
- (16) 格納容器内の圧力、温度、湿度、サンプ水位、格納容器スプレイが模擬されている。
- (17) プラントの主要制御系は次の項が模擬されている。

原子炉制御系

ほう酸濃度による制御系

加圧器圧力制御系

加圧器水位制御系

給水制御系

蒸気ダンプ制御系

余熱除去制御系

体積制御タンク水位制御系

タービン制御系

復水器ホットウェル水位制御系

レットダウン圧力制御系

- (18) プラントの警報と保護系として各種の信号は制御盤に点灯表示されると共に音響も発信される。

また、本シミュレータには、制御棒、プラントの弁、ポンプ等機器の故障を模擬したマルチファンクションがTable 2.1に示すように49種類用意されている^{4),5)}。本報告書では、このうち4種類の項目について解析を行い、得られたデータを使用してニューラルネットワーク監視システムの有効性を調べる。

Table 2.1 シミュレータのマalfアンクシヨnリスト

<u>一次系マalfアンクシヨn</u>	
1.一次冷却材ポンプ1台(B)停止	30.復水器循環水全喪失
2.一次冷却材ポンプ2台(B,C)停止	31.高圧給水加熱器ドレンポンプトリップ
3.一次冷却材ポンプ全停止	<u>タービン発電機マalfアンクシヨn</u>
4.一次冷却材ループ小破断	32.タービントリップ
5.ダブルエンディッド一次冷却管破損	33.発電機トリップ
6.燃料被覆破損	34.タービン自動ランバック機能の喪失
7.蒸気発生器伝熱管(B)破損	<u>核計装系マalfアンクシヨn</u>
8.一次冷却材ポンプ1台軸固着	35.線源領域検出器の計数高誤検知
9.加圧器スプレイ弁フェイルオープン	36.中間領域検出器の計数高誤検知
10.両加圧器スプレイ弁フェイルクローズ	37.オーディオカウンタ信号の異常高
11.加圧器バックアップヒーターフェイルオープン	38.オーディオカウンタ信号の異常低
12.加圧器定常ヒーターフェイルオフ	<u>制御系マalfアンクシヨn</u>
13.充填流量の停止	39.加圧器圧力制御系の高圧誤検知
14.蒸気発生器蒸気管破断	40.加圧器圧力制御系の低圧誤検知
15.加圧器逃がし弁閉固着	41.コールドレグ(A)温度計の高温誤検知
<u>制御棒マalfアンクシヨn</u>	42.制御棒制御系の引き抜き誤信号
16.制御棒1本 (p-6, Bank A)落下	43.体積制御タンク高水位誤検知
17.制御棒1本 (D-12, Bank C)飛び出し	44.体積制御タンク低水位誤検知
18.制御棒連続挿入	45.主蒸気ヘッダ---圧力制御器の圧力高誤検知
19.制御棒連続引き抜き	46.主蒸気ヘッダ---圧力制御器の圧力低誤検知
20.制御棒駆動制御装置故障	47.蒸気発生器C水位制御装置の水位高誤検知
21.原子炉自動スクラムの不動作	48.蒸気発生器C水位制御装置の水位低誤検知
22.制御棒最高速度駆動	49.EHC(Electric Hydraulic Control)自動制御系の故障
23.制御棒最低速度駆動	
<u>二次系マalfアンクシヨn</u>	
24.タービンガバナ弁フェイルオープン	
25.タービンガバナ弁フェイルクローズ	
26.大気放出弁の漏洩	
27.主給水部分喪失	
28.主給水全喪失	
29.復水器循環水部分喪失	

NPP Monitoring System

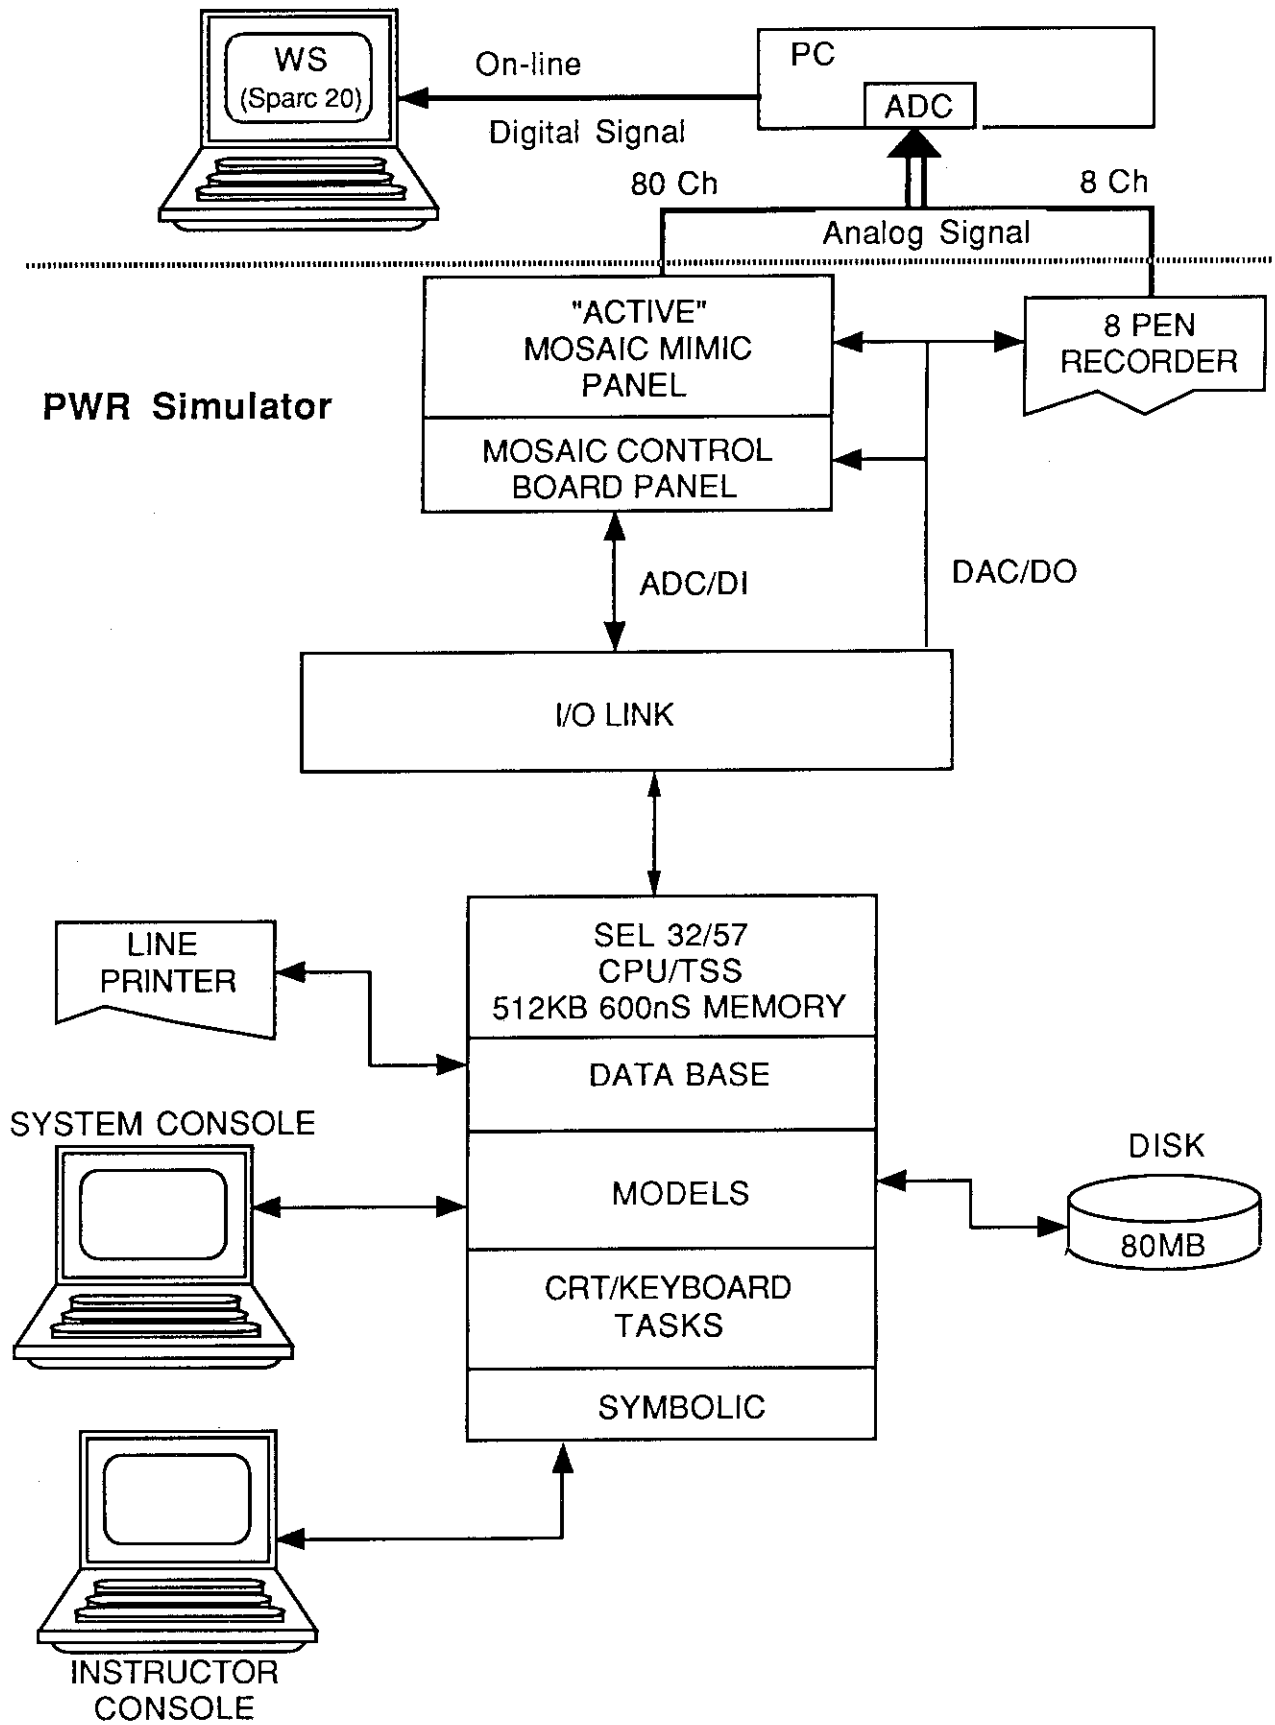


Fig. 2.1 シミュレータ構成図

- 監視信号点 (12)
- ★ 異常事象発生点 (4)

MIMIC PANEL

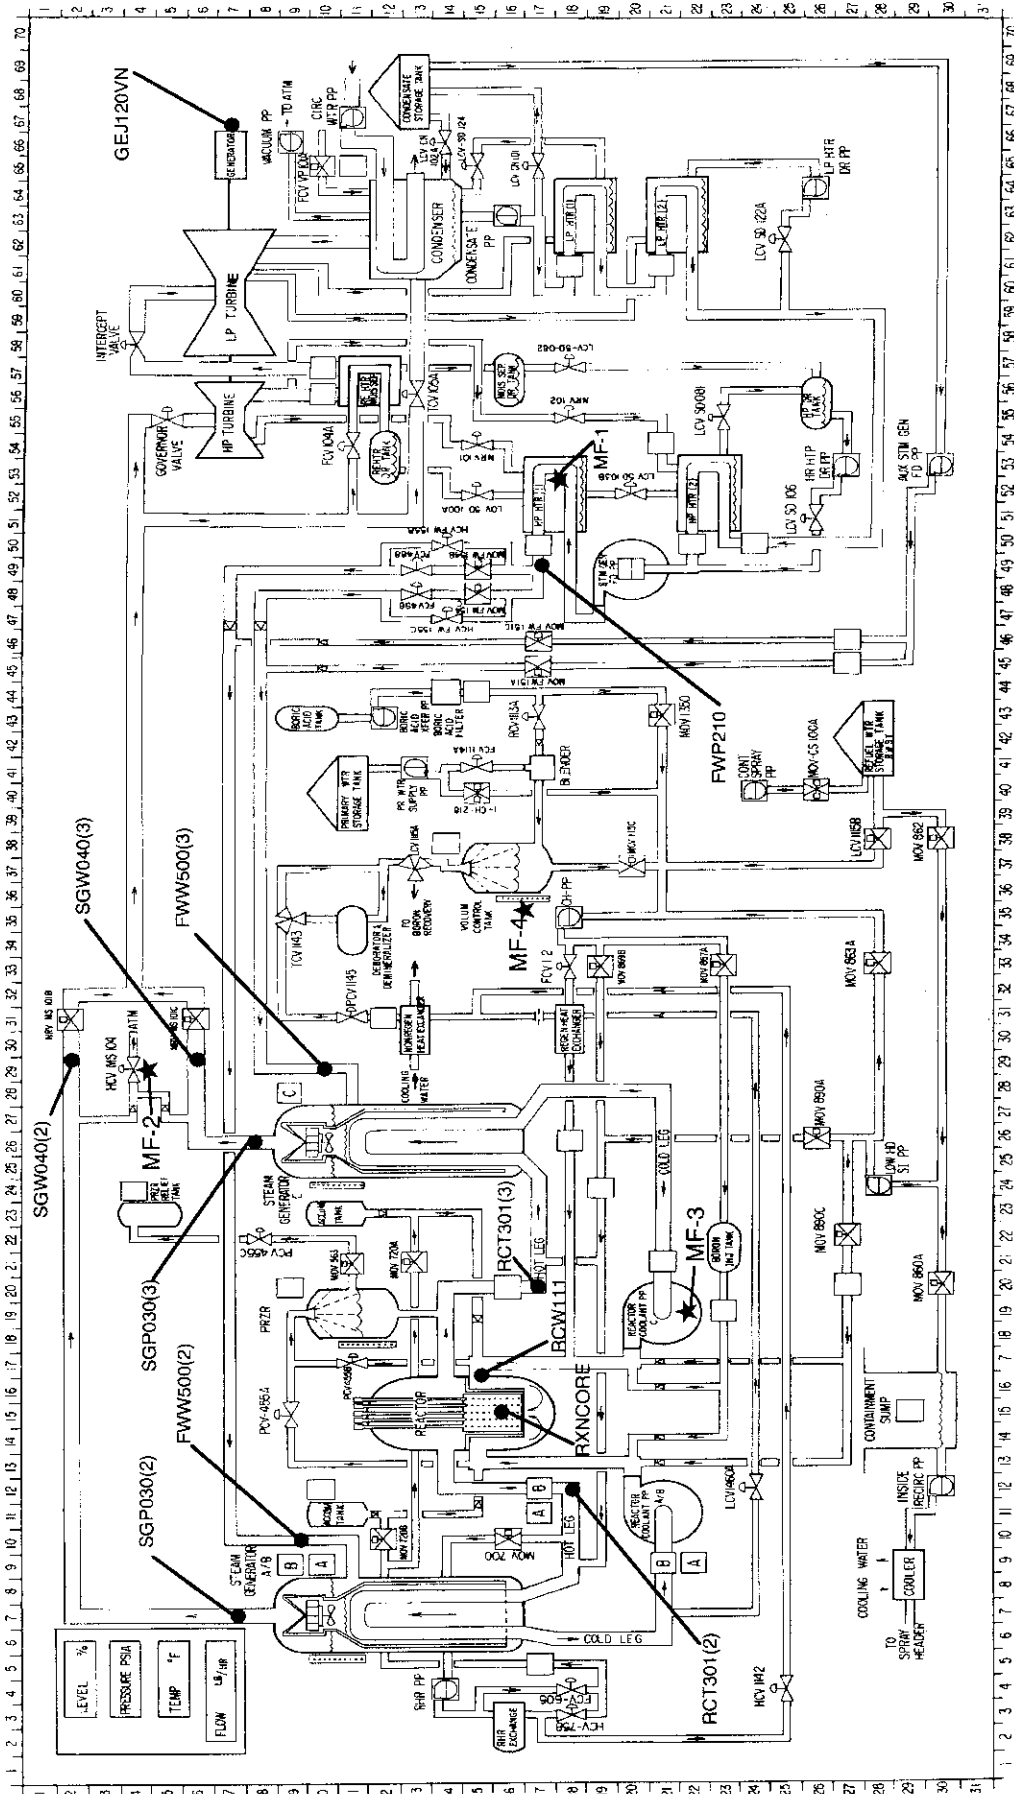


Fig. 2.2 PWR プラントモデル図 (ミミックパネル)

3 原子炉のモデル化

3.1 プラント監視信号の選択

本手法では、主要なプラント変数を用いて原子炉プラントのモデル化及び監視を行うが、使用するプラント変数の選択は重要な課題の一つである。そこで、実際にオランダのPWRプラント監視システム⁶⁾で使用されているニューラルネットワークの構成を基本的に考えて、主要なプラント変数12個 (Table 3.1参照) を選択した。オランダの原子力プラントは2ループの冷却系から構成されているのに対し、シミュレータの原子炉も同じPWR型であるが、冷却系はA、B、Cの3ループから成っている。しかし、Fig. 2.2 のようにミミックパネル図では、A、Bループは共通に表示されており、シミュレータに用意されているマルフアンクションも、ほとんどがBまたはCループに印可される。したがって、Aループのプラント変数は常にBあるいはCループの変数と同じ値になるため、監視信号として用いるプラント変数もB、Cループに限定してよい。

以上のことから、監視信号に用いるプラント変数として、まず原子炉からは炉外中性子束が、一次系からは1次冷却材流量 (全ループの合計)、B、Cループにおけるホットレグ温度が、また二次系からはB、Cループの蒸気流量、蒸気圧力、及び給水流量が選択された。これらに、給水圧力 (全ループの代表値) と電気出力を加えた12個の信号がニューラルネットワークの入力及び出力信号になる。ここで、ホットレグ温度を使用した理由は、原子炉出力が100%から20%の間で、ホットレグの温度が約30℃変化するのに対し、コールドレグの温度は約1℃しか変化しないからである。

3.2 換算係数の導出

プラント変数をニューラルネットワークの入力として用いるためには、シミュレータのミミックパネルから取り出したアナログ電圧値をデジタル値に変換した後、物理量に換算する必要がある。そこで、これらの変数のスケールリングファクターを求める。現在使用できる信号は、Table 3.2 に示されている様に、ミミックパネルから直接取り出される79チャンネル (No.1~69、78~87) とペンレコーダに出力される8チャンネル (No.70~77) の計87チャンネルである。ここで、ペンレコーダに出力される8チャンネルの信号は、システムコンソールで変数名を指定することにより、シミュレータで用いられているあらゆるプラント信号を選択することが可能である。

前節の12個のプラント変数のうち、炉外中性子束、B及びCループの蒸気流量、電気出力の4変数をミミックパネルから、残りの8変数をペンレコーダから取り出した。ペンレコーダに信号を割り当てる場合には、変数名及び信号の最大値と最小値をシステムコンソール上で設定する。この際、その設定値がAD変換時の電圧の最大値 (+10V) と最小値 (-10V) に相当するので、簡単に換算係数を求めることが可能である。しかし、実際には信号の

最大値と電圧の最大値、また信号の最小値と電圧の最小値が正確に一致していない。そこで、パネルからの出力信号と同様に、100%、50%及び20%（1次冷却材流量のみは2%）定常出力状態時の各変数の電圧値とシステムコンソール上に表示された物理量を比較し、直線近似によって換算係数を求めた。

Table 3.3～3.5に各出力状態における電圧値と物理量を、またTable 3.6及びFig. 3.1に得られた換算係数を示す。ここで、Table 3.6中のRは線形性を表すパラメータであり、R=1.0の場合は測定点が一直線上に位置していることを意味している。一方、Rの値が1.0より小さくなるほど、計算された換算係数の信頼性は低くなる。この理由としては、パネルに出力される電圧値が正常でないためであると考えられる。

なお、シミュレータ上で使用されている単位系はポンド・ヤード系であるので、得られたデータをさらに標準単位系に変換する必要がある。入力信号の単位換算係数をTable 3.7に示す。

Table 3.1 異常診断システムで用いるプラント信号

No.	プラント監視	
	PWRシミュレータ	変数名 PWR実プラント
1	Power Range-C	炉外中性子束
2★	Feed Water Press.	SG1 給水圧力
3★	Primary Water Flow	SG2 給水圧力
4★	Hot-leg Temp. (B)	1次系温度差ループ1
5★	Hot-leg Temp. (C)	1次系温度差ループ2
6★	Feed Water Flow (B)	SG1 給水流量
7★	Feed Water Flow (C)	SG2 給水流量
8★	Steam Press (B)	SG1 蒸気圧力
9★	Steam Press (C)	SG2 蒸気圧力
10	Steam Flow (B)	SG1 蒸気流量
11	Steam Flow (C)	SG2 蒸気流量
12	Unit Load	電気出力

★ペンレコーダーへの出力信号

Table 3.2 PWRプロセス信号表

NO.	信号名	NO.	信号名
1	HEAT EXCH. BYPASS IND. FT-605	45	STEAM GEN. LEVEL-C IND.
2	RHR-FCV-605 VALVE POSITION	46	FEEDWATER FLOW CON. VALVE-B IND.
3	RHR-HCV-758 VALVE POSITION	47	FEEDWATER FLOW CON. VALVE-C IND.
4	RHR-HCV1142 VALVE POSITION	48	STEAM FLOW-B IND.
5	POWER RANGE-A IND.	49	STEAM FLOW-C IND.
6	POWER RANGE-C IND.	50	FEEDWATER BYPASS VALVE-B IND.
7	START UP RANGE IND.	51	FEEDWATER FLOW-A IND.
8	INTERMEDIATE RANGE IND.	52	FEEDWATER FLOW-C IND.
9	RATE OF CHANGE IND.	53	FEEDWATER BYPASS VALVE-C IND.
10	POWER RANGE-B IND.	54	MAIN STEAM HEADER PRESS. IND.
11	POWER RANGE-B IND.	55	MAIN STEAM RELIEF VALVE IND.
12	SHAPE INDEX IND.	56	STEAM DUMP VALVE IND.
13	ROD GROUP POSITION IND.	57	ADMISSION VALVE POS. IND.
14	INDIVIDUAL ROD POSITION IND.	58	TURBINE LOAD RATE IND.
15	ROD SPEED IND.	59	SPEED IND.
16	HOT TEMPERATURE IND.	60	UNIT LOAD IND.
17	AVERAGE TEMPERATURE IND.	61	MEGAVARS IND.
18	COLD TEMPERATURE IND.	62	INCOMING FREQUENCY IND.
19	TEMPERATURE DIFFERENCER IND.	63	RUNNING FREQUENCY IND.
20	NARROW RNG. PRESSURIZER PRESS IND.	64	INCOMING VOLTAGE IND.
21	PRESS. SPRAY VALVE A-POS. IND.	65	RUNNING VOLTAGE IND.
22	PRESS. HEATEER CONT. IND.	66	VOLTAGE REGULATOR BALANCE IND.
23	PRESURIZER PRESS. INDICATOR D	67	SYNCRONIZATION LAMP DRIVE
24	PRESS. SPRAY VALVE B-POS. IND.	68	TREF IND.
25	PRESS. SPRAY VALVE C-POS. IND.	69	CHARGING FLOW CON. VALVE IND.
26	PRESS LEVEL IND.	70	RECORDER CHANNEL 1
27	LP LETDOWN PRESS. IND.	71	RECORDER CHANNEL 2
28	CVCS-PCV	72	RECORDER CHANNEL 3
29	VOL. CON. TANK LEVEL IND.	73	RECORDER CHANNEL 4
30	CVCS-DCV	74	RECORDER CHANNEL 5
31	BORON CONC. IND.	75	RECORDER CHANNEL 6
32	BORIC ACID TK TO BLENDER FLOW IND.	76	RECORDER CHANNEL 7
33	BORIC ACID TK TO BLENDER-LITERS IND.	77	RECORDER CHANNEL 8
34	BORIC ACID FLOW CON. VALVE IND.	78	LED BAR GRAPH. ROD POSITION BANK 1
35	BORIC ACID FLOW IND.	79	LED BAR GRAPH. ROD POSITION BANK 2
36	PRIM WTR TK TO BLENDER FLOW IND.	80	LED BAR GRAPH. ROD POSITION BANK 3
37	DILUTION WATER FLOW CON. VALVE IND.	81	LED BAR GRAPH. ROD POSITION BANK 4
38	PRIMARY WATER FLOW IND.	82	LED BAR GRAPH. ROD POS. PWR SHAPING BANK
39	PRIM WTR TK TO BLENDER-LITERS IND.	83	AUDIO COUNT RATE
40	CONT. PARTIAL PRESS. IND.	84	LED BAR GRAPH. STEAM GEN B LEVEL
41	CONT. PRESS. IND.	85	LED BAR GRAPH. PRESSURIZER LEVEL
42	CONT. TEMP. IND.	86	LED BAR GRAPH. STEAM GEN C LEVEL
43	TURB. IMPULSE IND.	87	LED BAR GRAPH. VCT LEVEL
44	STEAM GEN. LEVEL-B IND.	88	

Table 3.3 出力100%定常運転時のパネル信号の物理値と電圧

	ch	信号名	記号	物理値	電圧 [V]
1	6	POWER RANGE-C IND. [-]	RXNCORE	9.9140E-1	8.3562
2	70	FEEDWATER PRESS. [psi]	FWP210	1.1179E+3	4.0312
3	71	PRIMARY WATER FLOW [lb/hr]	RCW111	1.0156E+8	6.9375
4	72	HOT TEMP.(B) [°F]	RCR301(2)	6.0725E+2	8.2312
5	73	HOT TEMP.(C) [°F]	RCT301(3)	6.0725E+2	8.0937
6	74	FEEDWATER FLOW(B) [lb/hr]	FWW500(2)	3.5174E+6	4.0000
7	75	FEEDWATER FLOW(C) [lb/hr]	FWW500(3)	3.5174E+6	4.0625
8	76	STEAM PRESS.(B) [psi]	SGP030(2)	7.4708E+2	2.4375
9	77	STEAM PRESS.(C) [psi]	SGP030(3)	7.4708E+2	2.2312
10	48	STEAM FLOW-B IND. [lb/hr]	SGW040(2)	3.5093E+6	8.0375
11	49	STEAM FLOW-C IND. [lb/hr]	SGW040(3)	3.5092E+6	7.9500
12	60	UNIT LOAD IND. [-]	GFEJ120VN	8.3634E-1	8.3312

Table 3.4 出力50%定常運転時のパネル信号の物理値と電圧

	ch	信号名	記号	物理値	電圧 [V]
1	6	POWER RANGE-C IND. [-]	RXNCORE	4.8914E-1	4.1562
2	70	FEEDWATER PRESS. [psi]	FWP210	1.3381E+3	6.8375
3	71	PRIMARY WATER FLOW [lb/hr]	RCW111	1.0156E+8	6.9375
4	72	HOT TEMP.(B) [°F]	RCR301(2)	5.7739E+2	6.8875
5	73	HOT TEMP.(C) [°F]	RCT301(3)	5.7739E+2	6.7750
6	74	FEEDWATER FLOW(B) [lb/hr]	FWW500(2)	1.5937E+6	-3.6625
7	75	FEEDWATER FLOW(C) [lb/hr]	FWW500(3)	1.5937E+6	-3.6437
8	76	STEAM PRESS.(B) [psi]	SGP030(2)	8.5167E+2	4.1812
9	77	STEAM PRESS.(C) [psi]	SGP030(3)	8.5167E+2	3.9437
10	48	STEAM FLOW-B IND. [lb/hr]	SGW040(2)	1.6134E+6	3.6875
11	49	STEAM FLOW-C IND. [lb/hr]	SGW040(3)	1.6136E+6	3.6437
12	60	UNIT LOAD IND. [-]	GFEJ120VN	4.5914E-1	4.5687

Table 3.5 出力20%定常運転時のパネル信号の物理値と電圧

	ch	信号名	記号	物理値	電圧 [V]
1	6	POWER RANGE-C IND. [-]	RXNCORE	1.8107E-1	1.4375
2	70	FEEDWATER PRESS. [psi]	FWP210	1.3918E+3	7.5187
3	71	PRIMARY WATER FLOW [lb/hr]	RCW111	1.2797E+6*	-9.7687*
4	72	HOT TEMP.(B) [°F]	RCR301(2)	5.5986E+2	6.0937
5	73	HOT TEMP.(C) [°F]	RCT301(3)	5.5986E+2	5.9937
6	74	FEEDWATER FLOW(B) [lb/hr]	FWW500(2)	5.3633E+5	-7.8875
7	75	FEEDWATER FLOW(C) [lb/hr]	FWW500(3)	5.3707E+5	-7.8750
8	76	STEAM PRESS.(B) [psi]	SGP030(2)	9.4248E+2	5.6875
9	77	STEAM PRESS.(C) [psi]	SGP030(3)	9.4249E+2	5.4375
10	48	STEAM FLOW-B IND. [lb/hr]	SGW040(2)	5.6857E+5	1.2937
11	49	STEAM FLOW-C IND. [lb/hr]	SGW040(3)	5.7049E+5	1.2812
12	60	UNIT LOAD IND. [-]	GFEJ120VN	1.8179E-1	1.8000

* 出力2%定常運転時

Table 3.6 ニューラルネットワークに用いるアナログ信号の換算係数
 $Y = AX + B$ (Y: 物理量, X: 電圧[V])

	ch	信号名 Y	記号	傾き A	切片 B	R
1	6	炉外中性子束 [-]	RXNCORE	1.1733E-1	8.2860E-3	1.000
2	70	給水圧力 [psi]	FWP210	7.8516E+1	8.0135E+2	1.000
3	71	一次冷却材流量 [lb/hr]	RCW111	6.0027E+6	5.9918E+7	1.000
4	72	ホットレグ温度(B) [°F]	RCR301(2)	2.2176E+1	4.2469E+2	1.000
5	73	ホットレグ温度(C) [°F]	RCT301(3)	2.2575E+1	4.2451E+2	1.000
6	74	給水流量(B) [lb/hr]	FWW500(2)	2.5081E+5	2.5137E+6	1.000
7	75	給水流量(C) [lb/hr]	FWW500(3)	2.4966E+5	2.5033E+6	1.000
8	76	蒸気圧力(B) [psi]	SGP030(2)	6.0118E+1	6.0047E+2	1.000
9	77	蒸気圧力(C) [psi]	SGP030(3)	6.0949E+1	6.1116E+2	1.000
10	48	蒸気流量(B) [lb/hr]	SGW040(2)	4.3604E+5	4.8559E+3	1.000
11	49	蒸気流量(C) [lb/hr]	SGW040(3)	4.4061E+5	6.8321E+3	1.000
12	60	電気出力 [-]	GEJ120VN	1.0022E-1	1.3466E-3	1.000

Table 3.7 ニューラルネットワークに用いる信号の単位の換算係数
 $Y' = C(X' - D)$ (Y' : 標準単位, X' : ポンド・ヤード系)

	ch	信号名 Y'	C	D
1	6	炉外中性子束 [%]	100.00	0
2	70	給水圧力 [kgf/cm ²]	7.0307E-2	0
3	71	一次冷却材流量 [$\times 10^3$ ton/hr]	4.5359E-7	0
4	72	ホットレグ温度(B) [°C]	5.5556E-1	32
5	73	ホットレグ温度(C) [°C]	5.5556E-1	32
6	74	給水流量(B) [ton/hr]	4.5359E-4	0
7	75	給水流量(C) [ton/hr]	4.5359E-4	0
8	76	蒸気圧力(B) [kgf/cm ²]	7.0307E-2	0
9	77	蒸気圧力(C) [kgf/cm ²]	7.0307E-2	0
10	48	蒸気流量(B) [ton/hr]	4.5359E-4	0
11	49	蒸気流量(C) [ton/hr]	4.5359E-4	0
12	60	電気出力 [MW]	1000.0	0

質量流量 1 [lb/hr] = 4.5359E-4 [ton/hr]
 圧力 1 [psi] = 7.0307E-2 [kgf/cm²]
 温度 t [°C] = (t-32)/1.8 [°F]

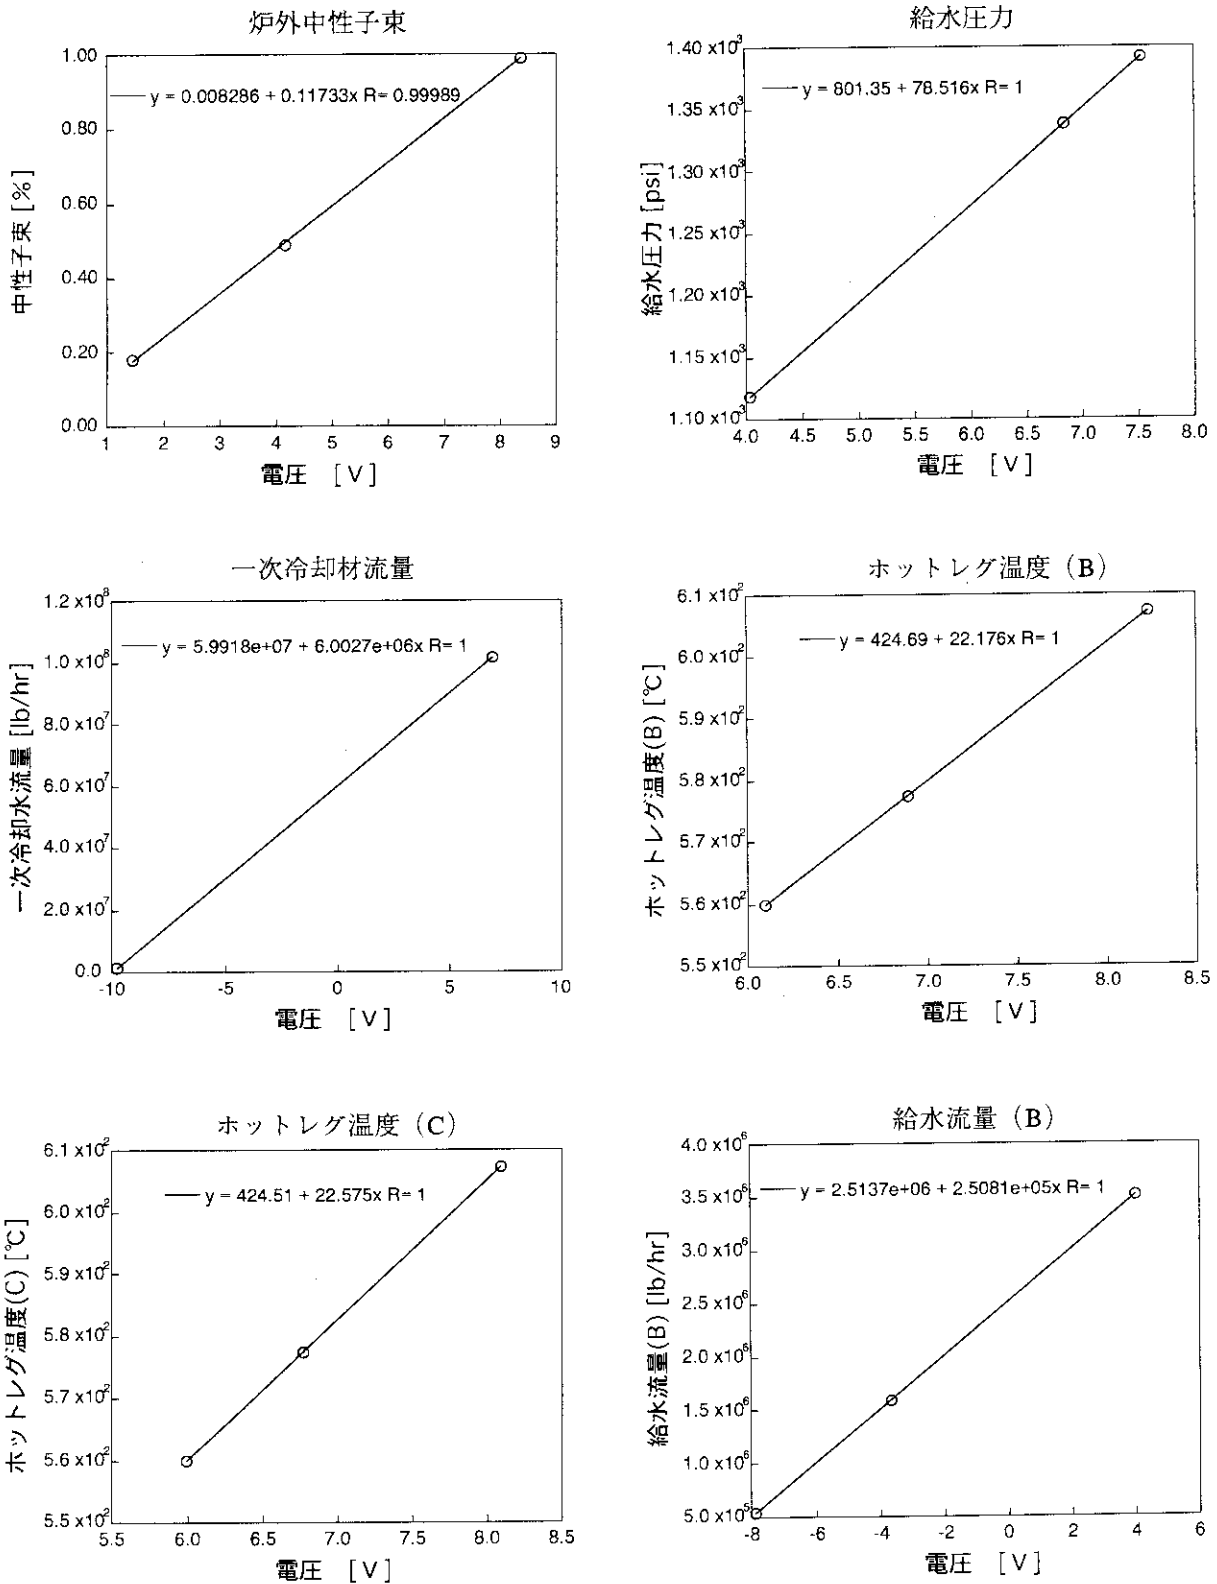


Fig. 3.1(a) パネル出力信号の換算係数 (1)









Fig. 3.1(b) パネル出力信号の換算係数 (2)

4 ニューラルネットワーク

4.1 ニューロンの動作モデル

人工ニューラルネットワークは、Fig. 4.1(a)のように生物の脳の神経細胞の結合状態を(b)のような単純化した工学的モデルで表したものである。一般的な神経細胞のモデルは多入力1出力の素子と考えてよく、他の細胞の出力はシナプス結合を介して入力として与えられる。入力の総和がその細胞のしきい値 θ を超えた場合に細胞が興奮して出力が1、そうでない場合には出力は0となるのが基本的な神経細胞のモデルである。

また、生物の神経系においては、神経細胞間のシナプス結合の強さを変化させることによって学習を行っていると考えられている。つまり、過去の出来事を記憶したり、訓練によって優れた運動能力を獲得する際には、神経回路網が適切な形状に変化しているのである。この自己組織化(学習)のモデルには、いろいろなアルゴリズムが提案されているが、それらのほとんどで「細胞Aの出力が細胞Bに入力されている場合、この2つの細胞が同時に興奮した時にそのシナプス荷重が大きくなる」(Hebbの原理)という仮説が用いられている。

まず、Fig. 4.1(b)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。 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、(4.1)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 $W_{i,j}^{k-1,k}$ をかけたものの総和として表わされる。

$$I_j^k = \sum_i W_{i,j}^{k-1,k} \times O_i^{k-1} \quad (4.1)$$

さらに、この入力 I_j^k は、入出力関数 $f(I)$ により出力 O_j^k に変換される。この入出力関数 f に非線形関数を用いることによって、ニューラルネットワークは非線形系のモデル化を行うことが可能となる。上述のように、生物の神経系は2値モデルであり、非線形関数は単位段階関数

$$f(I) = \begin{cases} 1, & I - \theta > 0, \\ 0, & I - \theta \leq 0 \end{cases}$$

で近似される。しかし、今回のようにニューラルネットワークをプラントのモデル化に利用する場合は入出力信号が連続値であること、また、次節の学習過程で必要な入出力関数の微分値 f' が簡便に計算できることを考慮して、ここでは入出力関数にシグモイド関数を採用する。したがってユニット内のしきい値を θ_j^k とすると、出力信号 O_j^k は、

$$O_j^k = f(I_j^k) = \frac{1}{1 + e^{-(I_j^k - \theta_j^k)}} \quad (4.2)$$

のように表される。

Fig. 4.2 に、今回の原子力プラント監視に用いたニューラルネットワークの簡単な概念図を示す。使用したネットワークは、入力層、出力層及び1つの隠れ層からなる3層構造の階層型である。隠れ層は8ユニット、入力層と出力層は全く同じ12ユニットからなるオートアソシアティブネットワークである。入力層と隠れ層のユニット間及び隠れ層と出力層のユニット間は全て結合されており、フィードバックはない。

4.2 誤差逆伝播 (バックプロパゲーション) アルゴリズム

本研究では、学習則としてもっとも広く用いられている誤差逆伝播 (バックプロパゲーション) アルゴリズムを採用した⁷⁾。Fig. 4.1 の中のk-1層のi番目とk層のj番目のユニット間の結合の重みの変化 $\Delta W_{ij}^{k-1,k}$ は以下のようにして求められる。

$$\Delta W_{ij}^{k-1,k}(t) = \eta \cdot \delta_j^k \times O_i^{k-1} + \alpha \cdot \Delta W_{ij}^{k-1,k}(t-1). \quad (4.3)$$

ここで、 η は標準誤差逆伝播法における学習率、 δ_j^k はk層j番目のユニットについての誤差信号で、出力層Mにおいては、

$$\delta_j^M = (T_j - O_j^M) \times f'(I_j^M) = (T_j - O_j^M) \cdot O_j^M(1 - O_j^M), \quad (4.4)$$

その他の中間層においては、

$$\delta_j^k = f'(I_j^k) \cdot \sum_q \delta_q^{k+1} \cdot W_{j,q}^{k,k+1} = O_j^k(1 - O_j^k) \cdot \sum_q \delta_q^{k+1} \cdot W_{j,q}^{k,k+1} \quad (k=M-1, \dots, 2) \quad (4.5)$$

となる。ここで、 δ_q^{k+1} はk+1層における誤差信号、 $W_{j,q}^{k,k+1}$ はk層j番目とk+1層q番目のユニット間の結合の重みである。(4.4)式の T_j は教師信号、 f は入出力関数の微分であるが、(4.2)式のようなシグモイド関数を用いているため(4.5)式のように簡単な形で表すことができる。また、(4.3)式の右辺第2項はモーメント項と呼ばれ、学習の振動を減らして学習の収束を速め、求めるべき最小値に到達する途中の極小値で学習が収束するのを防ぐために加えられる。 α はモーメント項の係数である。

今回の計算では、学習回数が増えるとともに、 η は1.2~0.1に、 α は0.6~0.1に段階的に小さくなるように設定した。

4.3 ネットワーク初期値の設定

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。一方、出力信号は、最大値と最小値がそれぞれ0.9と0.1に規格化されている。

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。重みとしきい値の初期値はそれぞれ-0.5~0.5、-1.0~1.0の間の乱数を発生させて設定した。用いる乱数によって、初期のネットワーク構造は全く異なるものになり、学習が収束した後の重み等も大きく違ってくるが、今回行った十数種の初期値による計算では、最終的な学習誤差に大きな差は見られなかった。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原子炉プラントの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、ネットワークの隠れ層ユニット数が8以上20以下の場合で、学習誤差及び学習結果に目立った差異は見られなかった。なお、このニューラルネットワークプログラムは、FORTRANで書かれており、ワークステーション上で実行される。

4.4 初期学習方法

ニューラルネットワークは、過去の運転データを学習することによって、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。本来初期学習のデータには、定常運転時と起動、停止時の正常なデータをなるべく一様に使用することが望ましいが、今回用いたシミュレータには原子炉の起動、大幅な出力変動、停止を自動的に再現する機能がない。そこで、初期学習データにはシミュレータで本来用意されている3つの定常運転時のデータのみを使用した。燃料サイクル初期における20%、50%、100%出力の定常運転時のデータをそれぞれ1秒ごとに100点測定し、これらのデータ計300パターンをニューラルネットワークの初期学習に用いた。このように、初期学習において広範囲な学習データを使用する理由は、ニューラルネットワークが学習範囲外のデータに対してほとんど適用できないからである。つまり、与えられた学習データの内挿に関して十分な性能を示すが、外挿は全く不得意である。したがって、ニューラルネットワークを利用する場合には、学習データの選択に十分な注意を払う必要がある。今回は、各データをランダムな順序で1000回ずつ学習し、ニューラルネットワークによるPWRプラントのモデル化を行った。初期学習の際に、データをランダムに学習する方が、一定の順序で行う場合よりも学習の収束が速く、しかも誤差が小さくなった。初期学習に要した時間は、ワークステーション Sparc20上で約1分であった。Fig.4.3は、12個のプラント信号についての初期学習の結果を示している。ここで、実線は測定値、点線は推定値で、二つの値がほとんど一致していることから初期学習がうまく行われていることがわかる。20%出力時に各信号が少し変動しているのは、低出力状態でシステムが安定していないからであると考えられる。図中の◆は二つの値の偏差を表しており、初期学習における最大偏差は、異常診断の際のしきい値を設定する際に参照される。

4.5 ニューラルネットワークを用いた診断手法


初期学習後、シミュレータから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。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原子炉プラントのモデル化を行っているので、入力データが正常ならばニューラルネットワークの出力（推定値）と入力データ（測定値）はほぼ同じ値になるはずである。一方、学習されていない異常な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、実際の測定値と異なってくることになる。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することができる。

ここで、異常と判断する際の偏差のしきい値の設定は、異常診断を行う場合に非常に重要となる。本研究では、各信号における初期学習時の偏差の最大値（最大誤差； ϵ_{\max} ）と100%または50%定常出力運転時の標準偏差の2倍の値（ ϵ_{sd} ）を比較し、大きい方の値を1.25倍したものをしきい値（ ϵ_f ）として定義した。各出力信号に対するそれらの値をTable 4.1に示す。最大誤差のみでなく標準偏差も参照した理由は、信号の種類によってアナログ値からデジタル値への変換時の誤差が大きくなるもの、出力状態による変化が少ない割に一定出力時の変動が大きいものが存在するためである。今回の適用例でも、一次冷却材流量、蒸気圧力等は最大誤差より標準偏差の2倍の値の方が大きくなっている。また、給水流量のしきい値が蒸気流量に比べて5倍程度大きいのは、ニューラルネットワークによる学習がうまく収束しなかったからではなくシミュレーション誤差が大きいからだと考えられる。100%定常出力時の標準偏差も蒸気流量の5倍程度になっている。


なお、しきい値に掛けられた1.25倍は、本監視システムを実プラントに適用した際に、経験的に得られた値であり³⁾、実際の原子炉に適用した場合、この係数を1.25以下に設定すると、正常運転時においても頻繁に監視信号がそのしきい値を超えて誤報を發した。

Table 4.1 ニューラルネットワークに用いるアナログ信号のしきい値

	ch	信号名 Y	記号	最大誤差 (E_{max})	標準偏差×2 (E_{sd})	しきい値 (E_f)
1	6	炉外中性子束 [%]	RXNCORE	0.567	0.158	0.70894
2	70	給水圧力 [kgf/cm ²]	FWP210	0.4984	0.1140	0.62303
3	71	一次冷却材流量 [$\times 10^3$ ton/hr]	RCW111	0.0084	0.1224	0.15301
4	72	ホットレグ温度(B) [°C]	RCR301(2)	0.2782	0.1498	0.34774
5	73	ホットレグ温度(C) [°C]	RCT301(3)	0.2887	0.1406	0.36093
6	74	給水流量(B) [ton/hr]	FWW500(2)	50.558	5.828	63.198
7	75	給水流量(C) [ton/hr]	FWW500(3)	51.773	5.707	64.717
8	76	蒸気圧力(B) [kgf/cm ²]	SGP030(2)	0.1213	0.1443	0.18032
9	77	蒸気圧力(C) [kgf/cm ²]	SGP030(3)	0.1166	0.1503	0.18793
10	48	蒸気流量(B) [ton/hr]	SGW030(2)	9.518	1.324	11.898
11	49	蒸気流量(C) [ton/hr]	SGW030(3)	10.470	1.692	13.088
12	60	電気出力 [MW]	GFEJ120VN	8.880	4.076	11.101



(a) 神経細胞



(b) 工学的モデル

Fig. 4.1 神経細胞のモデル

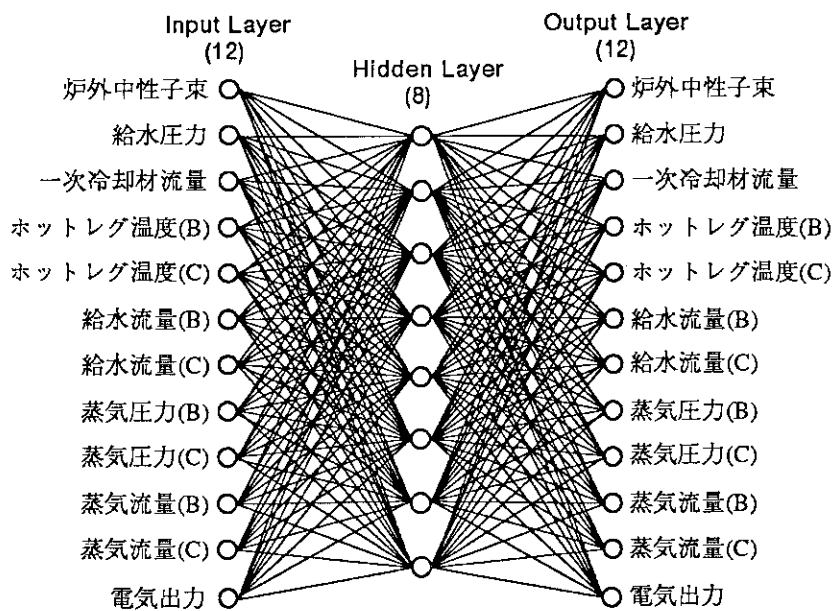


Fig. 4.2 オートアソシアティブネットワークモデル

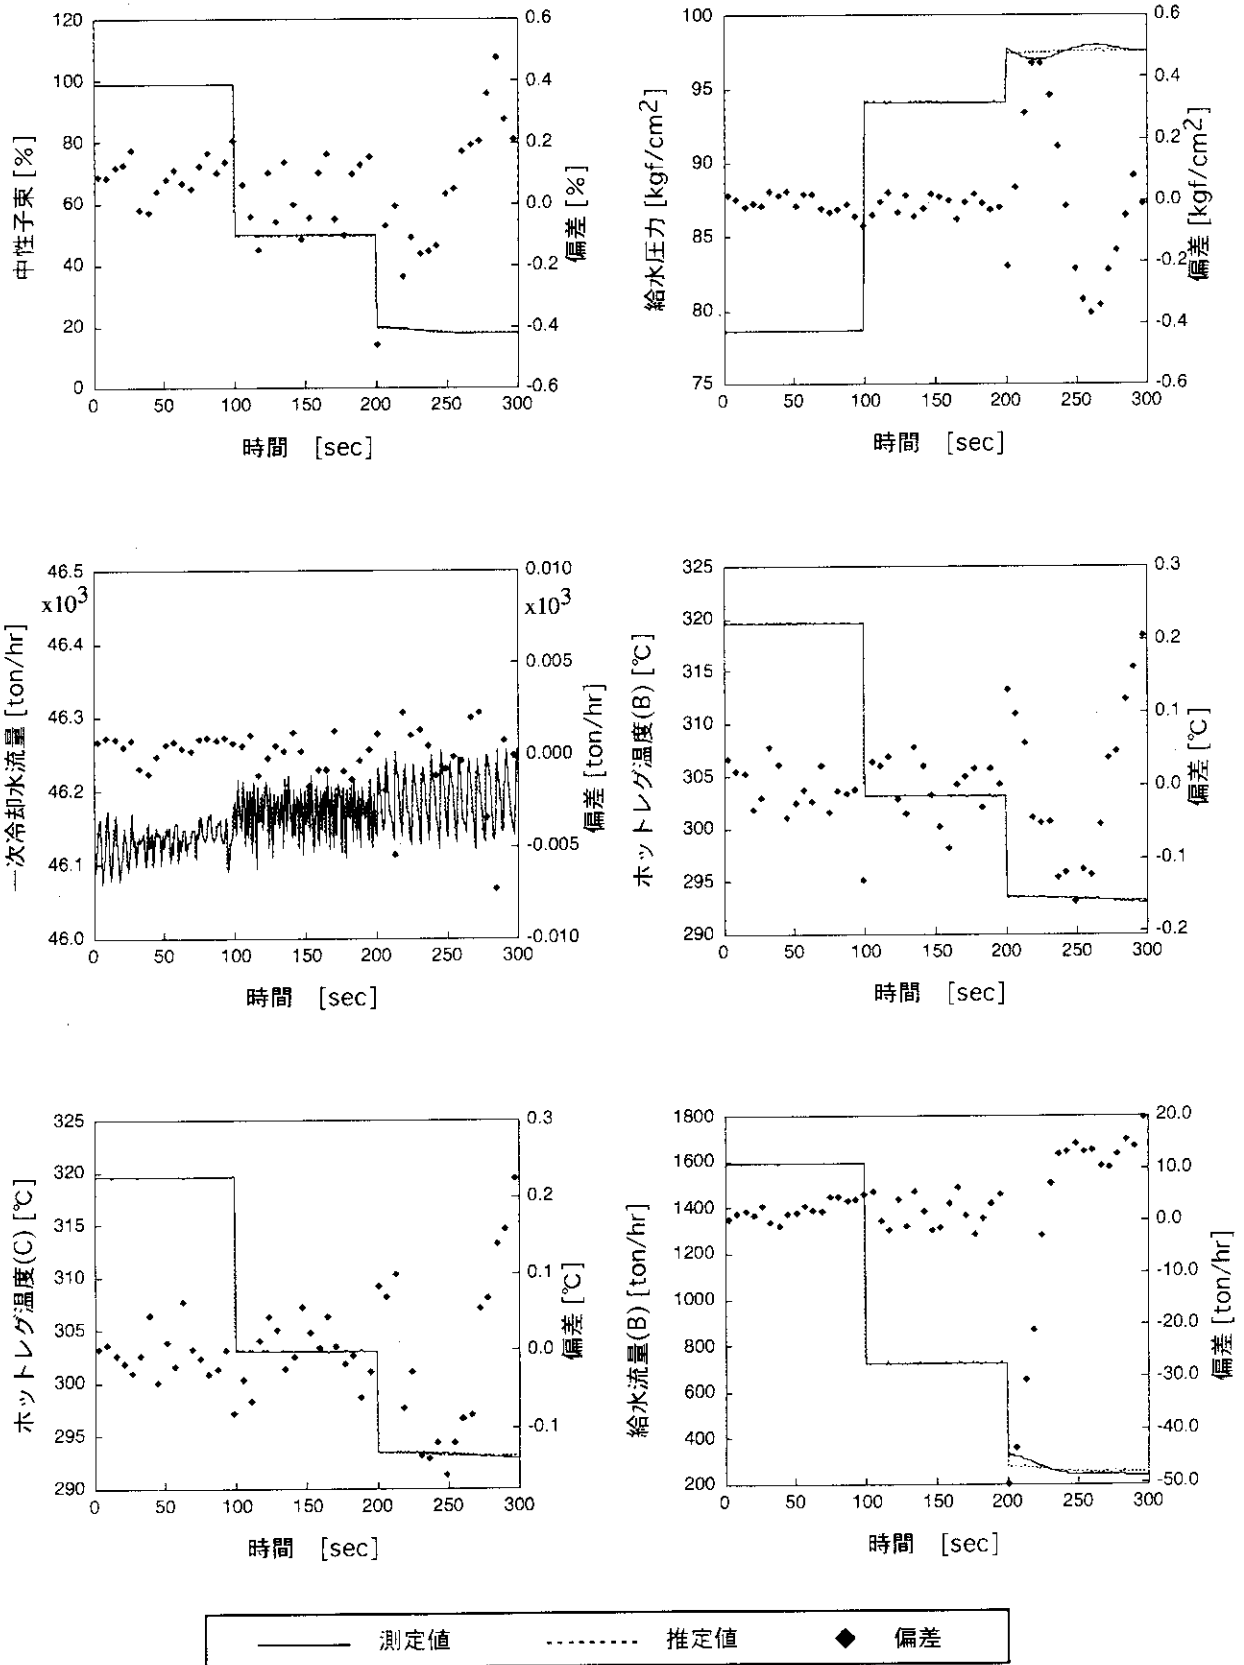


Fig. 4.3(a) 初期学習結果 (1)

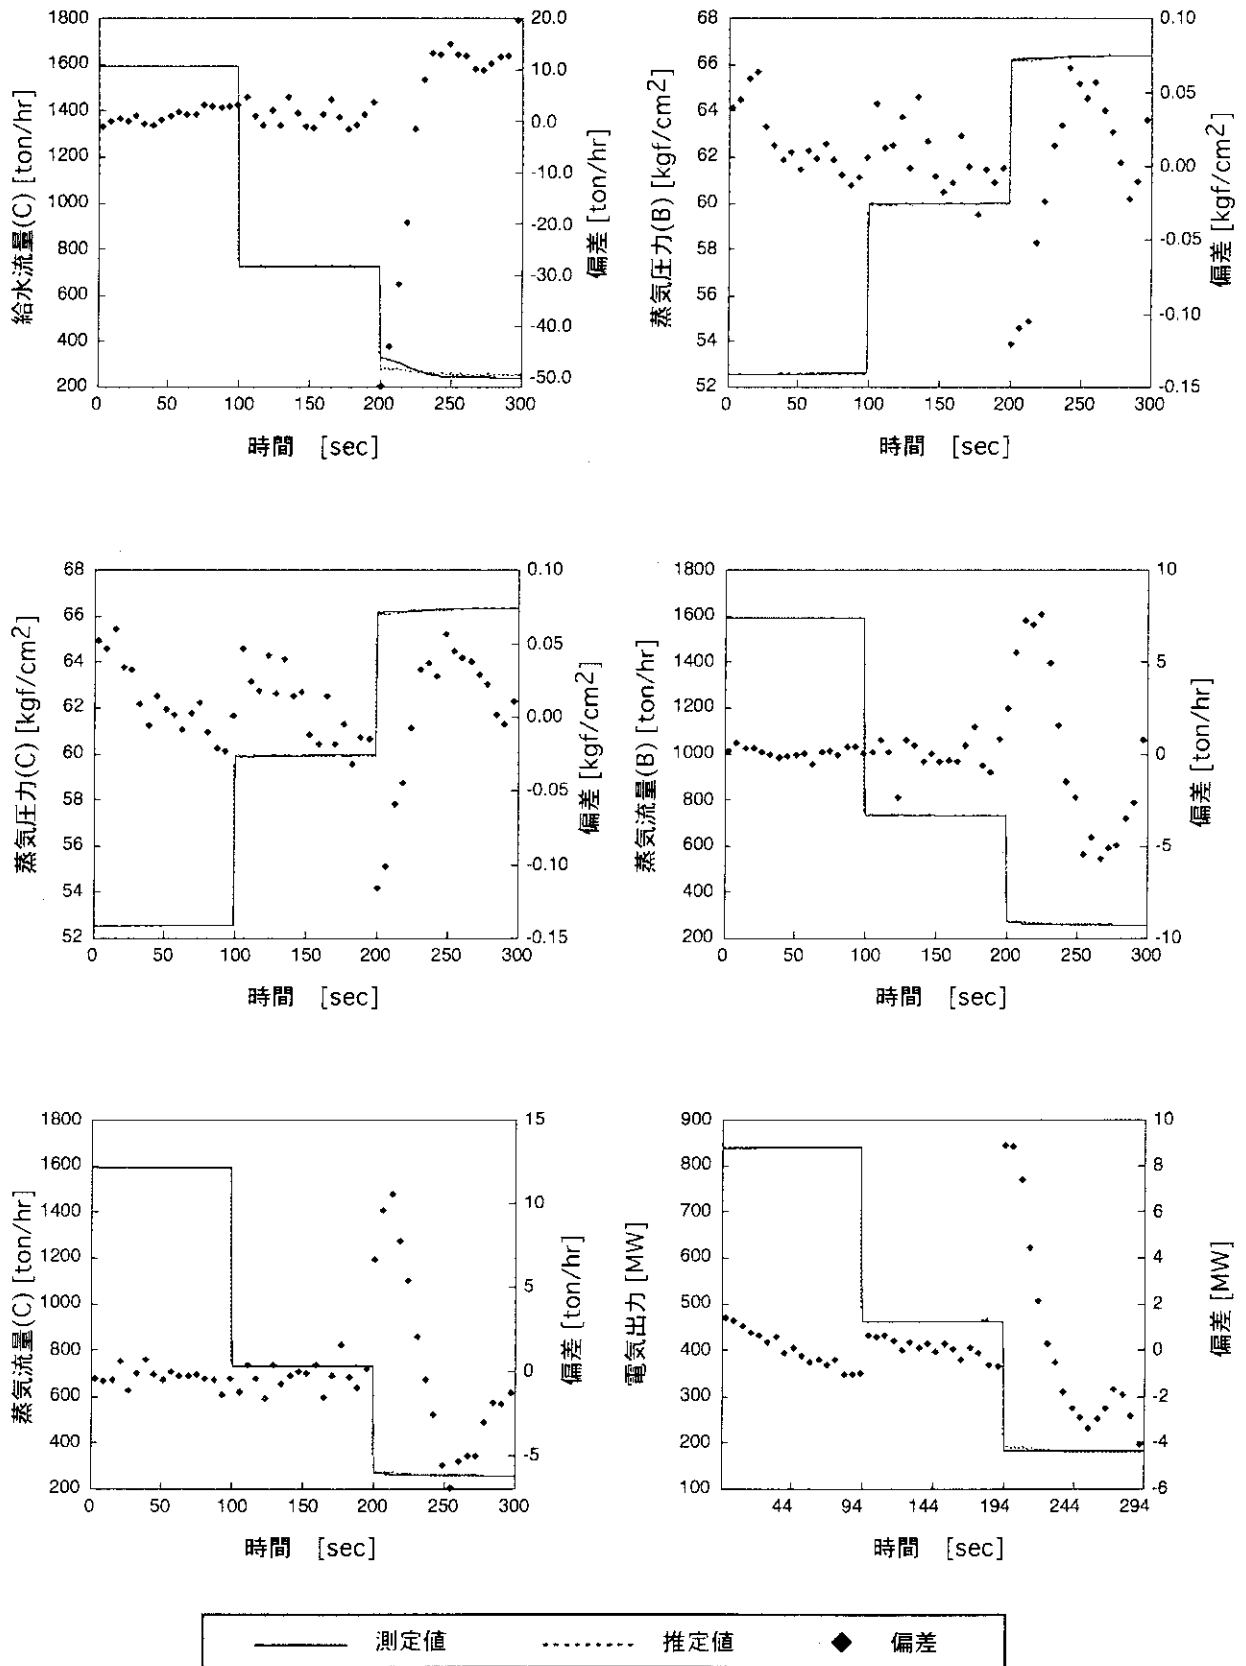


Fig. 4.3(b) 初期学習結果 (2)

5 感度解析

ニューラルネットワークをいろいろな目的に用いる際、もっとも大きな問題の1つは、ネットワークの内部構造が解明されておらず、ブラックボックス的な利用しかできないという点である。そこで、ネットワーク内部がどのように結合されているのかを少しでも理解するために、ここでは感度解析を試み、出力信号がどの入力信号に依存しているのかを調べた。感度解析によってニューラルネットワーク内部の結合状態及び中間層の働きの一部が明らかにできるため、ニューラルネットワークによるプラントのモデル化がうまく行われているかどうかを検証することが可能となる⁸⁾。

まず、ニューラルネットワークの入力 x と出力 y の関係を、次のように表わす。

$$y=f(x)$$

$$y_j = f_j(x_1, x_2, \dots, x_m)$$

$f(x)$ はニューラルネットワークによってモデル化された関数である。
入力 x_i に微小の変動 Δx を加えたときの感度は、

$$\frac{\Delta y_j}{\Delta x_i} = \frac{f_j(x_1, x_2, \dots, x_i + \Delta x, \dots, x_m) - f_j(x_1, x_2, \dots, x_i, \dots, x_m)}{\Delta x_i} \quad (5.1)$$

と定義される。

したがって、出力 y_j の入力 x_i に対する寄与度 P_{ji} は、

$$P_{ji} = \frac{\frac{\partial y_j}{\partial x_i}}{\sum_{k=1}^m \frac{\partial y_j}{\partial x_i}} \times 100 \quad (\%) \quad (5.2)$$

で表わされる。

Fig. 5.1 は、それぞれの入力に5%の外乱 (Δx_i) を加えた場合の、出力信号の入力信号に対する寄与度の割合を表示したものである。なお、この時感度解析に使用するデータは、初期学習データのうち100%出力の100点とした。Fig. 5.1を全体的に見ると、一次冷却材流量を除く各信号の寄与度はそれほど片寄りがなく、しかも自分自身の信号による寄与度は15%程度であることがわかる。また、二つのループ間での同種信号の寄与度は同じ様な傾向を示している。2つの給水流量がほとんどの信号に大きく寄与しているのは、給水制御系の影響であると考えられる。以上のことから、一次冷却材流量を除く11個の信号で、異常診断に必要な原子力プラントのモデル化ができていると考えて良い。しかしながら一次冷却材流量信号のみは、自身の寄与度が約50%と大きく、しかも他の信号への寄与率は非常に

小さい。この結果は、一次冷却材流量信号 (Ch.3) についてはモデル化がうまくいっていないことを意味している。その理由は、一次冷却材流量が初期学習の20~100%出力運転の間でほとんど一定の値になっているからである。このように全ての学習データが一定値で、他の入力との相関がほとんどない信号をニューラルネットワークでモデル化することは不可能に近い。しかし一方では、このような一定値信号の異常検知には、モデルベースによる監視手法を用いる必要はなく、従来のしきい値による単純な診断手法で容易に検知できる。むしろここで注目すべきなのは、プラントのモデル化に必要な信号を入力として用いても、ニューラルネットワークによる他の信号のモデル化には何の悪影響も及ぼさないという点である。

なお、同じ100%出力データに10%の外乱を加えた場合、また、それぞれ20%及び50%出力のデータを用いた場合についての感度解析を行ったが、全てについて同様の結果が得られた。以上のことから、この感度解析がニューラルネットワーク内部構造の解明に有効であることがわかった。

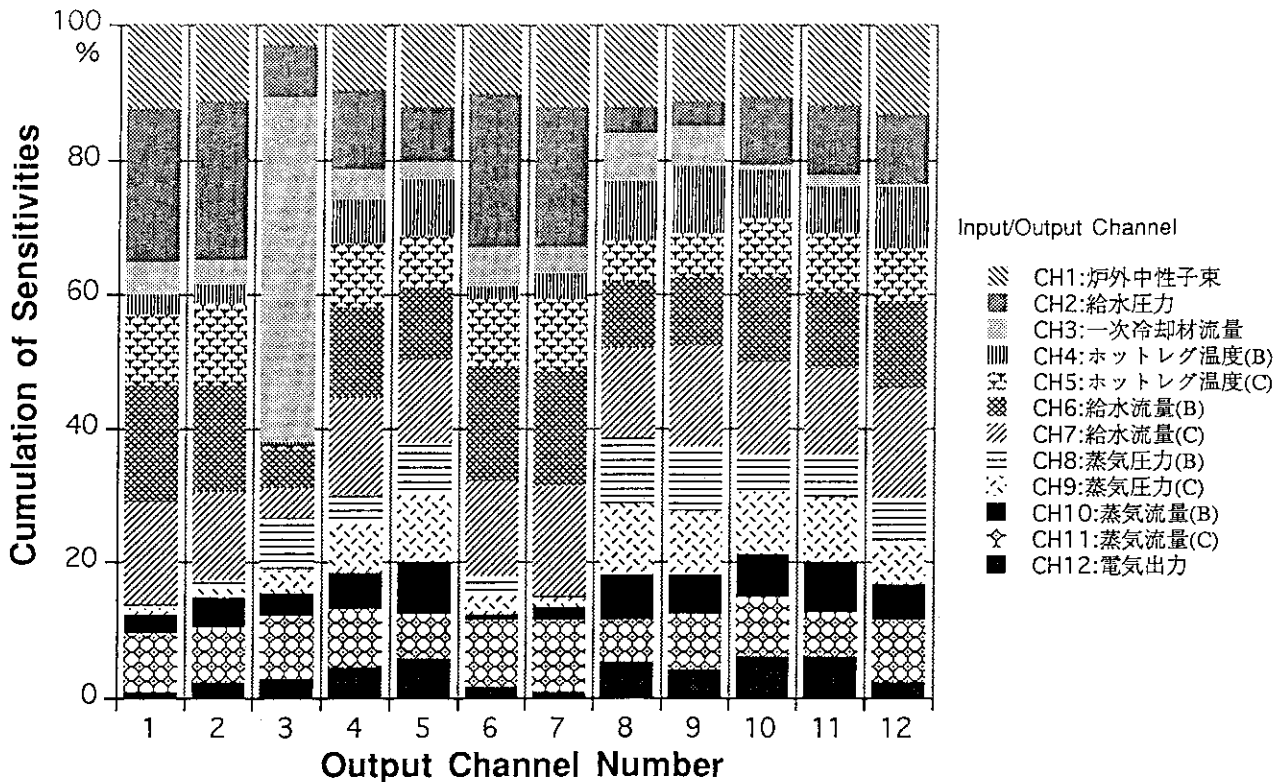


Fig. 5.1 ニューラルネットワーク推定値 (出力) に対する測定値 (入力) の寄与率

6 診断結果

このPWRコンパクトシミュレータは運転員訓練用に作られているため、実際の原子炉の運転状況に近いように設計されている。今回のシミュレーションでは、全ての場合について自動制御系が常時作動しており、監視信号がアラーム範囲を越えた場合には警報が発せられるようになっているため、ニューラルネットワークを用いた異常診断システムと従来の警報システムとの比較を容易に行うことができる。

出力100%定常運転時に数種類のマルファンクションを加えて、原子炉で異常が発生した場合のシミュレーションデータを作成し、ワークステーションにオフラインで転送した後、ニューラルネットワークによる異常診断を行った。ここで、全てのマルファンクションは、測定開始約9秒後に加えられる。今回のプラント診断に用いる異常事象は、主給水部分喪失、大気放出弁の漏洩、一次冷却材ループ小破断、体積制御タンク低水位誤検知の4つ場合である。Table 6.1に従来の警報システムとの比較を、以下にそれぞれ場合の診断結果を示す。

6.1 主給水部分喪失

100%定常出力運転中に、第一給水加熱器内の給水管が破損して、900 [ton/hr]の給水流量が加熱器シェル内へ流出する。給水が漏れたことで給水の流量、圧力が減少し、それに伴い蒸気発生器の水位も徐々に下がってくる。原子炉の自動制御系は給水流量の低下を感知し、外部からの給水量を増やすために給水制御弁開度を大きくし、給水流量の低下を押さえようとする。漏れが大きい場合には、外部から給水しているにも関わらず蒸気発生器の水位は徐々に減少していき、水位がシミュレータの警報システムで設定されたしきい値を超えるため警報が発生する。しかし、今回のシミュレーションでは漏れの量がそれほど大きくなかったために、警報は発せられなかった。

この異常事象に対するプラント及びニューラルネットワークモデルの挙動をFig. 6.1に示す。本監視システムは、漏れが発生してから1秒後に給水圧力信号が異常であると診断し、3秒後には2つのループにおける給水流量信号で異常を検知した。これは、Fig. 6.2に示されているように、給水の漏れにより給水圧力と給水流量の測定値は急激に低下するが、その他の信号にはまだ影響が出ていないためネットワークの推定値は変化しておらず、そのためこれらの信号の偏差がしきい値を超えたからである。

なお、450秒付近に現れている電気出力信号のピークは、AD変換時に発生したノイズであるが、この時点での電気出力信号の偏差は非常に大きくなっており、センサー異常に対しても十分検知可能でありことがわかった。

6.2 大気放出弁の漏洩

100%定常出力運転中、大気放出弁座の吹き抜けによる弁容量100%の蒸気漏洩が発生する。Fig. 6.3にこの事象に対するプラント及びニューラルネットワークモデルの挙動を示す。大気放出弁から蒸気が漏洩することで、蒸気流量、蒸気圧力が急激に低下する。同時に、蒸気平均温度も低下し、当然電気出力も低下する。この電気出力の低下を補うために、自動制御系は制御棒を引き抜く。制御棒が引き抜かれると中性子束が大きくなり、1次系の冷却水の温度が上昇し、二次系の蒸気温度も上がる。その結果、電気出力は増加する。しかし、制御棒の引き抜きにより中性子束が大きくなりすぎたため、制御棒の上昇がストップし、「ROD STOP」の警報が点灯する。この警報は蒸気が漏れだしてから30秒後に鳴り出した。制御棒の上昇が止まった後、電気出力も徐々に低下する。

Fig. 6.4から明らかなように、この異常事象の場合には、本監視システムは蒸気の漏れが発生した1秒後に2つのループでの蒸気流量の異常低下を検知し、3秒後には一次冷却材流量を除く全ての信号で異常を示している。蒸気流量と給水流量は測定値が急激に減少するため、偏差がしきい値を超える。蒸気圧力は、流量が減少するためモデル上では上昇すべきであるが、実際の測定値は蒸気漏洩のため減少しているため偏差が急激に大きくなる。一方、給水圧力は給水流量が減少するため、徐々に高くなる。また、中性子束は蒸気流量及び給水流量が減少するため、推定値も下がるが、上述のように制御系によって実際の測定値は上昇するため偏差が大きくなりしきい値を超える。

6.3 一次冷却材部分喪失（一次冷却材ポンプ1台軸固着）

100%負荷運転中に、Cループ冷却材ポンプのインペラーの損傷により、ポンプ軸が固着状態になり、結果的にCループの冷却材が部分喪失する異常事象である。Fig. 6.5にその結果を示す。Cループの冷却材流量は、ポンプ軸固着により約2秒で急激に減少し始める。一次冷却材が92%に減少した異常発生2秒後の時点で原子炉がトリップするため、9種類のアラームが、異常発生後2～5秒で鳴り出している。中性子束はスクラムにより、瞬時にゼロ付近に達する。Fig. 6.6に示されているように、本監視システムも2秒後に1次冷却材流量信号の異常を、さらに5秒後には全信号での異常を検知している。この際の1次冷却材流量信号の異常は、偏差がしきい値を超えたというよりは測定値が学習データの範囲を超えたことによって検知されたものである。なお、この異常事象は前の2つの場合に比べて非常に大きいため、従来の警報システムとの違いはほとんど見られなかった。

6.4 体積制御タンク低水位誤検知

100%出力時に体積制御タンク（VCT）の水位コントローラが故障し、VCT水位が0%であるという誤信号を発しつつける異常事象である。VCT水位低の警報が異常発生時から鳴りだすが、その時点でプラント自身に異常はないため、監視システムが異常を検知す

るまでしばらく時間がかかる。Fig. 6. 7 にプラント及びニューラルネットワークモデルの挙動を示す。水位コントローラが故障すると、実際のVCTレベルは正常であっても、コントロールパネルでの表示は0%を示し、直ちに一次冷却水貯蔵タンク及びほう酸水タンクより水の補給が開始される。一方でVCT出口弁は閉となり、充填ラインへの水供給は燃料取替用水タンク (RWST) に切り替わるため、ボロン濃度が750PPMから3000PPMに上昇する。従って、炉内減速材中のボロンが増加し、中性子束は減少して、結果的に一次系の平均温度が下がる。この温度下降を抑えて二次系出力を保持するため、制御棒の引抜きが行われる。そして、故障発生後約12分で制御棒が上限まで引き抜かれ、「ROD WITHDRAW LIMIT」アラームが鳴る。

Fig. 6. 8 から明らかなように、本監視システムでは、体積制御タンク水位コントローラが故障してから24秒後に、中性子束信号から原子炉プラントの異常を検知している。これはボロンが注入され、中性子束が減少したことによって、プラントの状態が正常時から変化したためである。さらに中性子束の減少によって原子炉内の温度も徐々に低下し、95秒を過ぎて2つのループのホットレグ温度が低いという異常を検知した。以上の結果より、制御系も含めたプラント全体の挙動の変化から、故障信号を直接監視することなしに異常事象を検知することも可能であることがわかった。

Table 6.1 異常検知までの所要時間

	異常事象	マルファンク ション番号	従来の警報システム	ニューラルネット監視システム
1	主給水流量部分喪失 (2E6 lbm/hr)	msc240.200	警報なし	1 sec: 給水圧力 異常 3 sec: 給水流量(B) 異常 3 sec: 給水流量(C) 異常
2	大気放出弁の漏洩(100%)	msc390.100	30 sec: ROD STOP	1 sec: 蒸気流量(B) 異常 1 sec: 蒸気流量(C) 異常 2~3 sec: 全信号異常 (一次冷却材流量除く)
3	一次冷却水の部分喪失 (一次冷却材ポンプ軸固着)	mps120	2~5 sec: REACTOR TRIP, etc	2 sec: 一次冷却材流量 異常 4 sec: 電気出力、給水流量 異常 5 sec: 全信号異常
4	体積制御タンク 低水位誤検知	mps500	0 sec: VCT LEVEL LOW 720 sec: ROD WITHDRAW LIMIT	24 sec: 炉外中性子束 異常 95 sec: ホットレグ温度(B) 異常 95 sec: ホットレグ温度(C) 異常

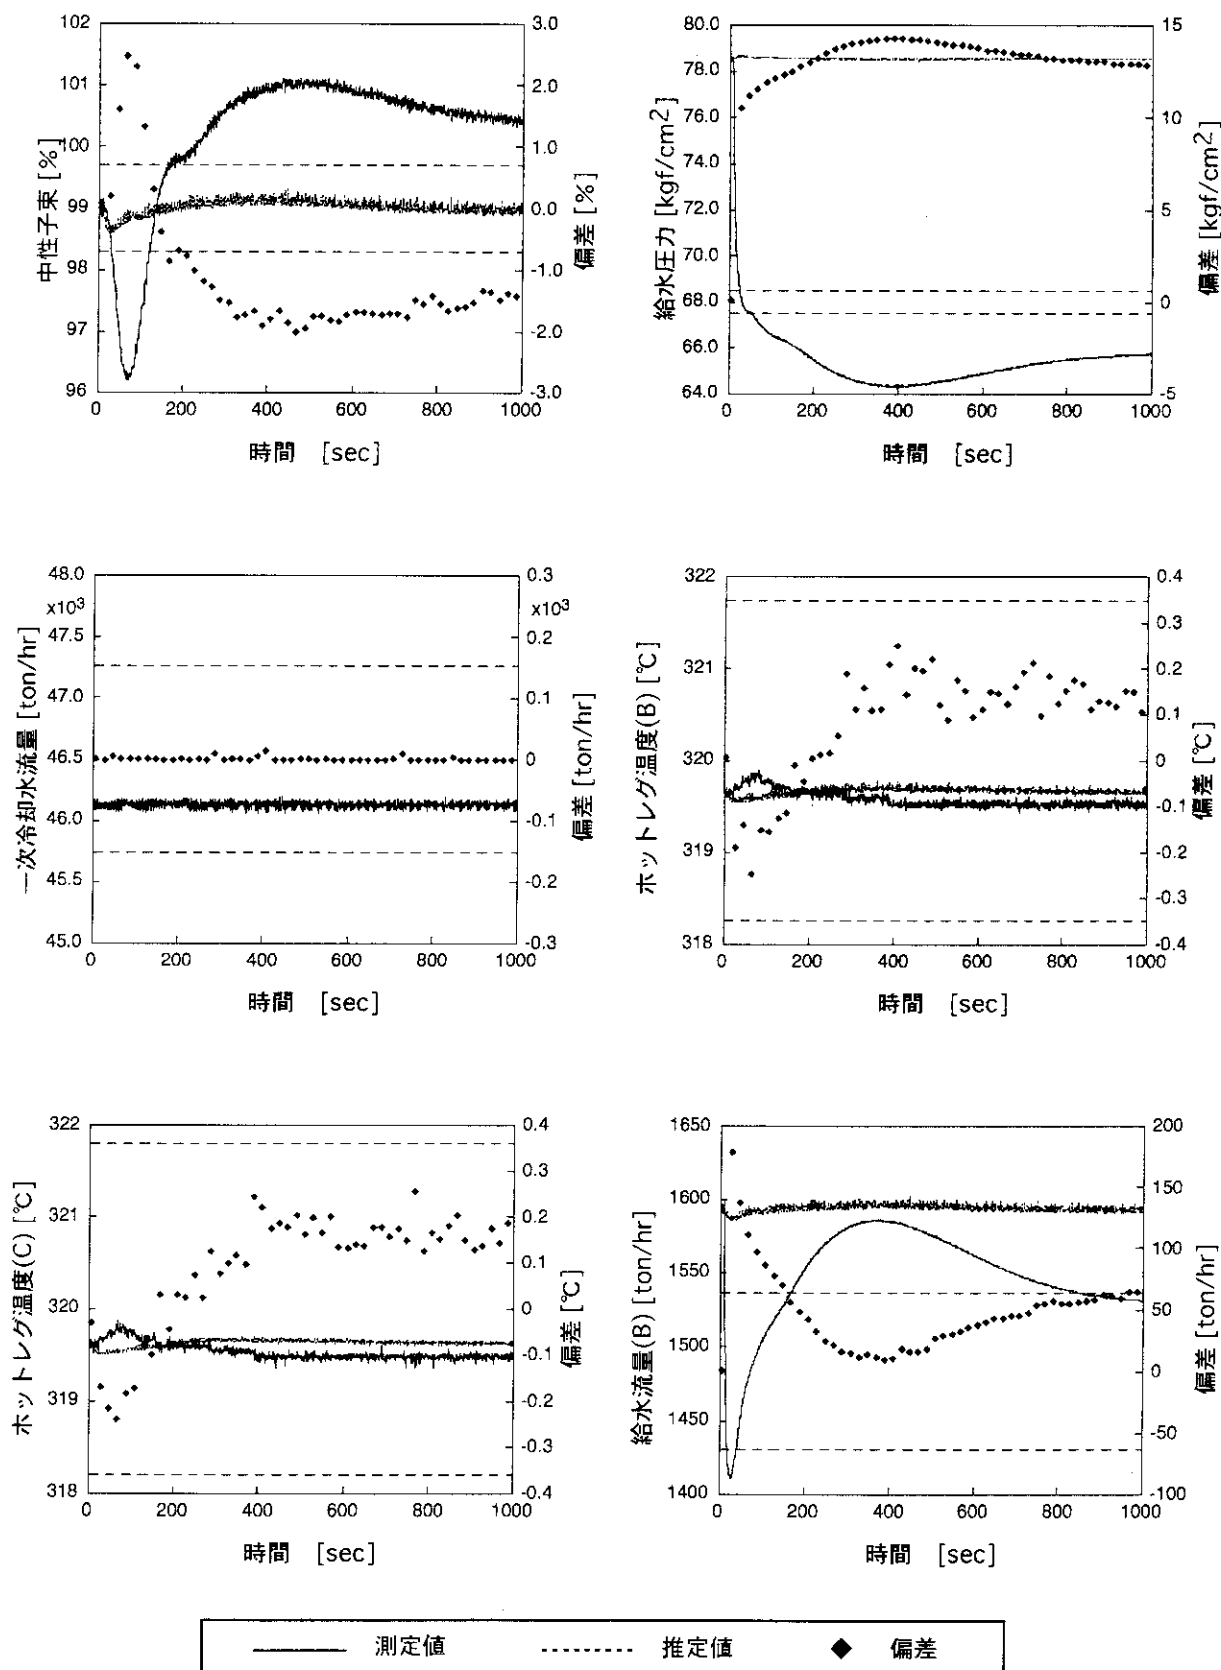


Fig. 6.1(a) 主給水部分喪失時の応答 (1)

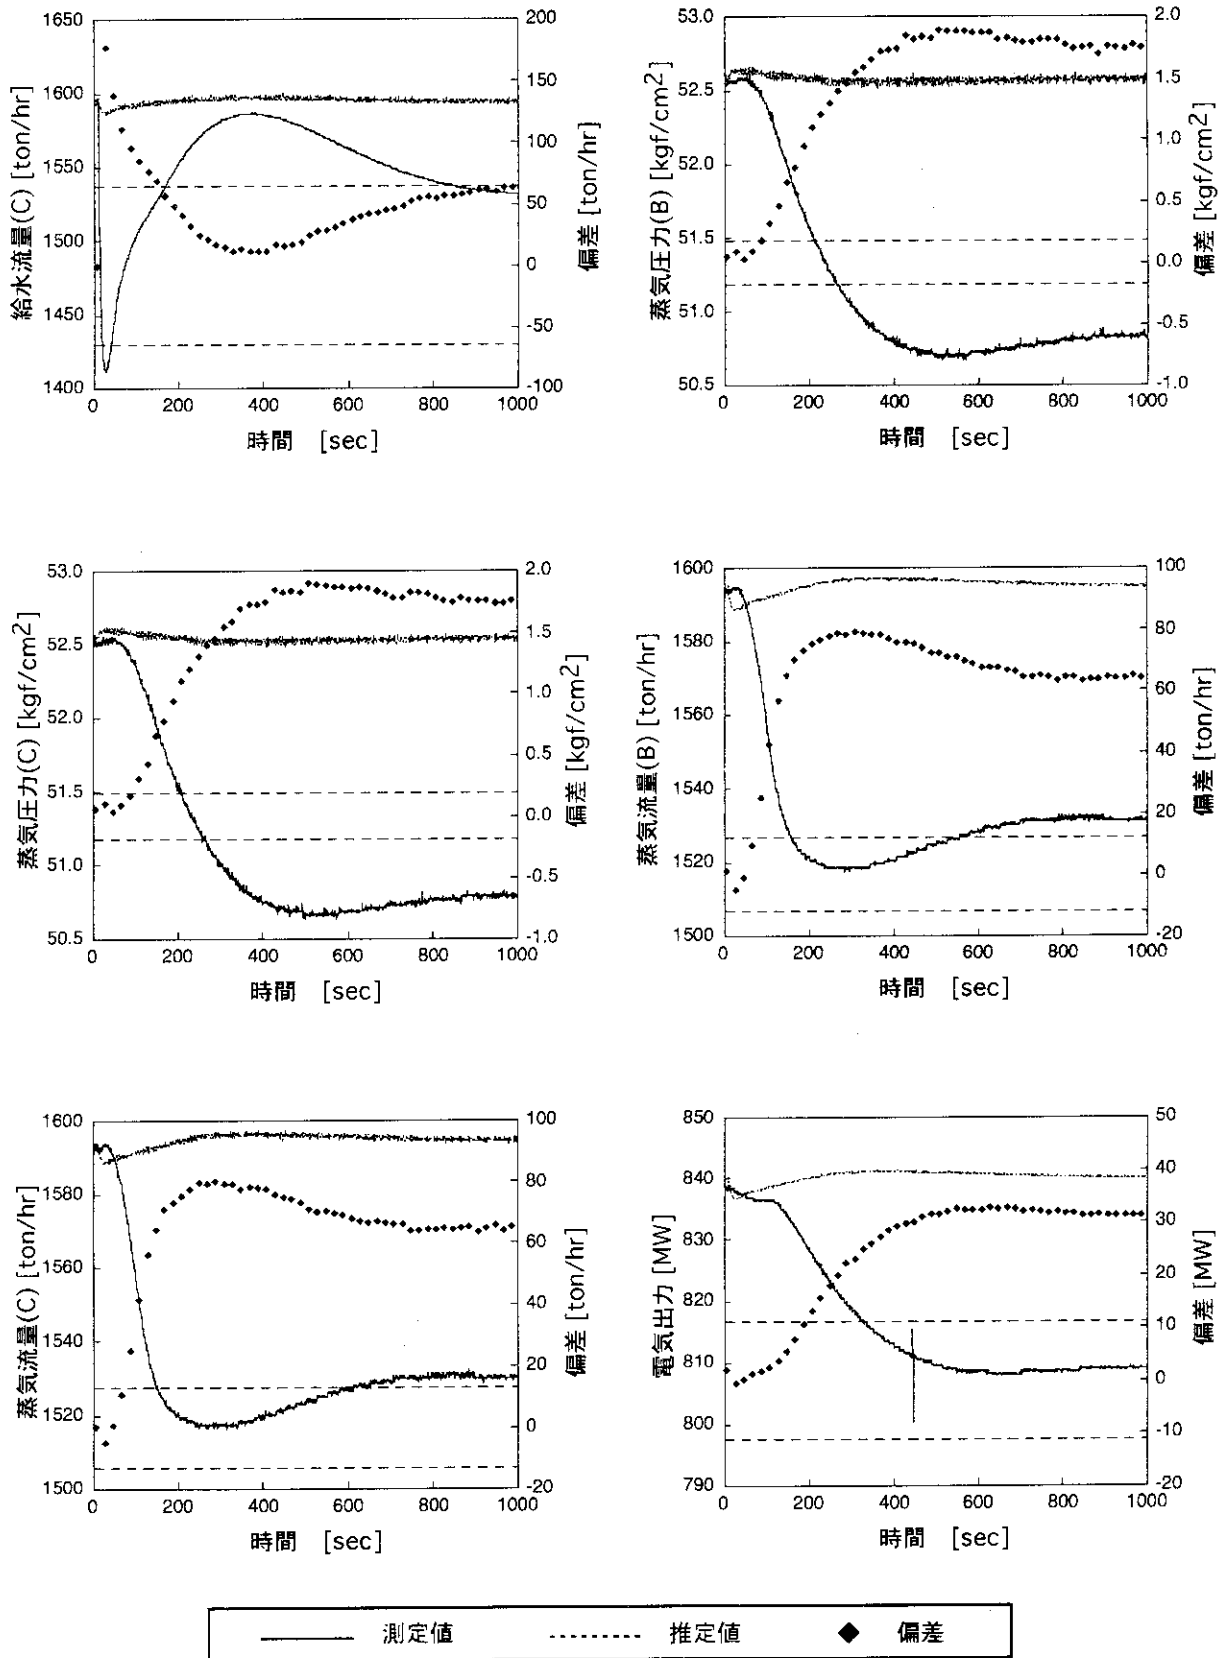


Fig. 6.1(b) 主給水部分喪失時の応答 (2)

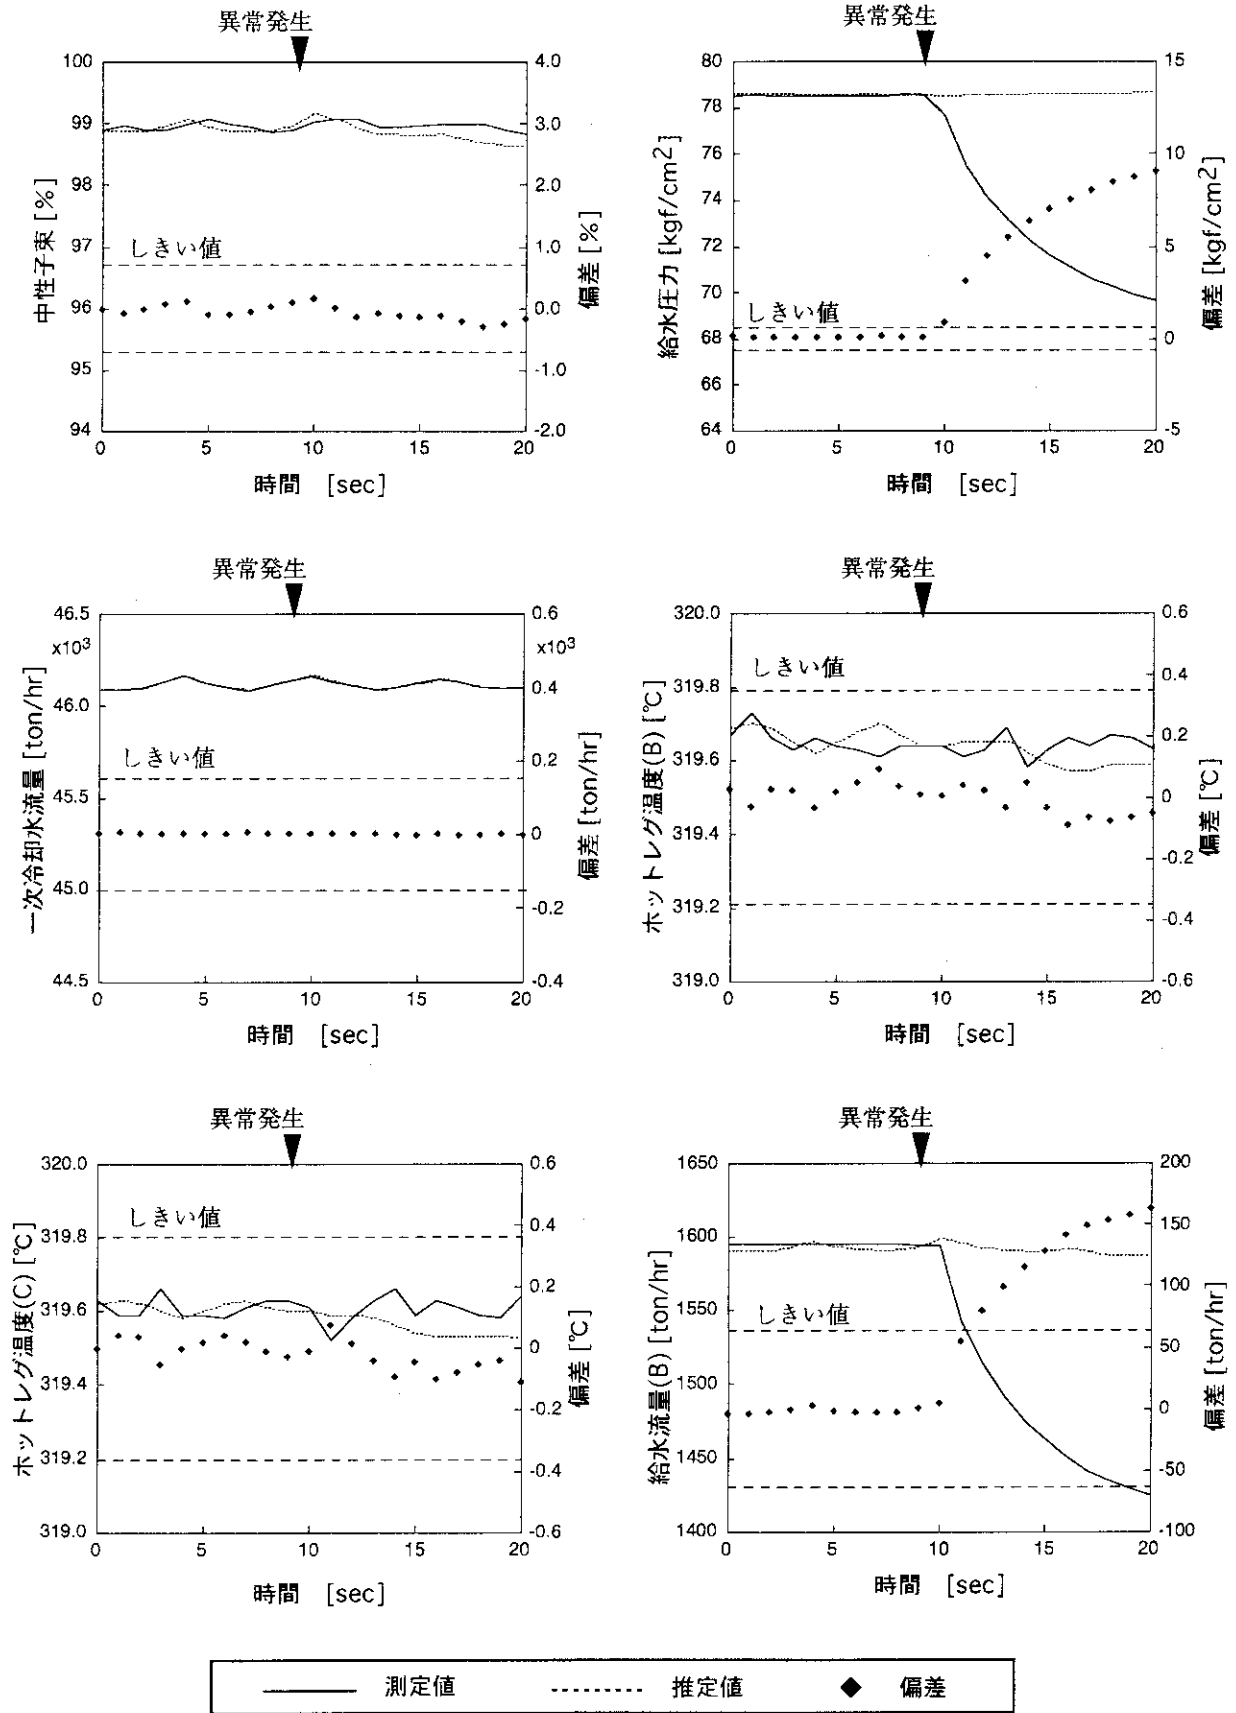


Fig. 6.2(a) 主給水部分喪失時の応答 (0-20秒)

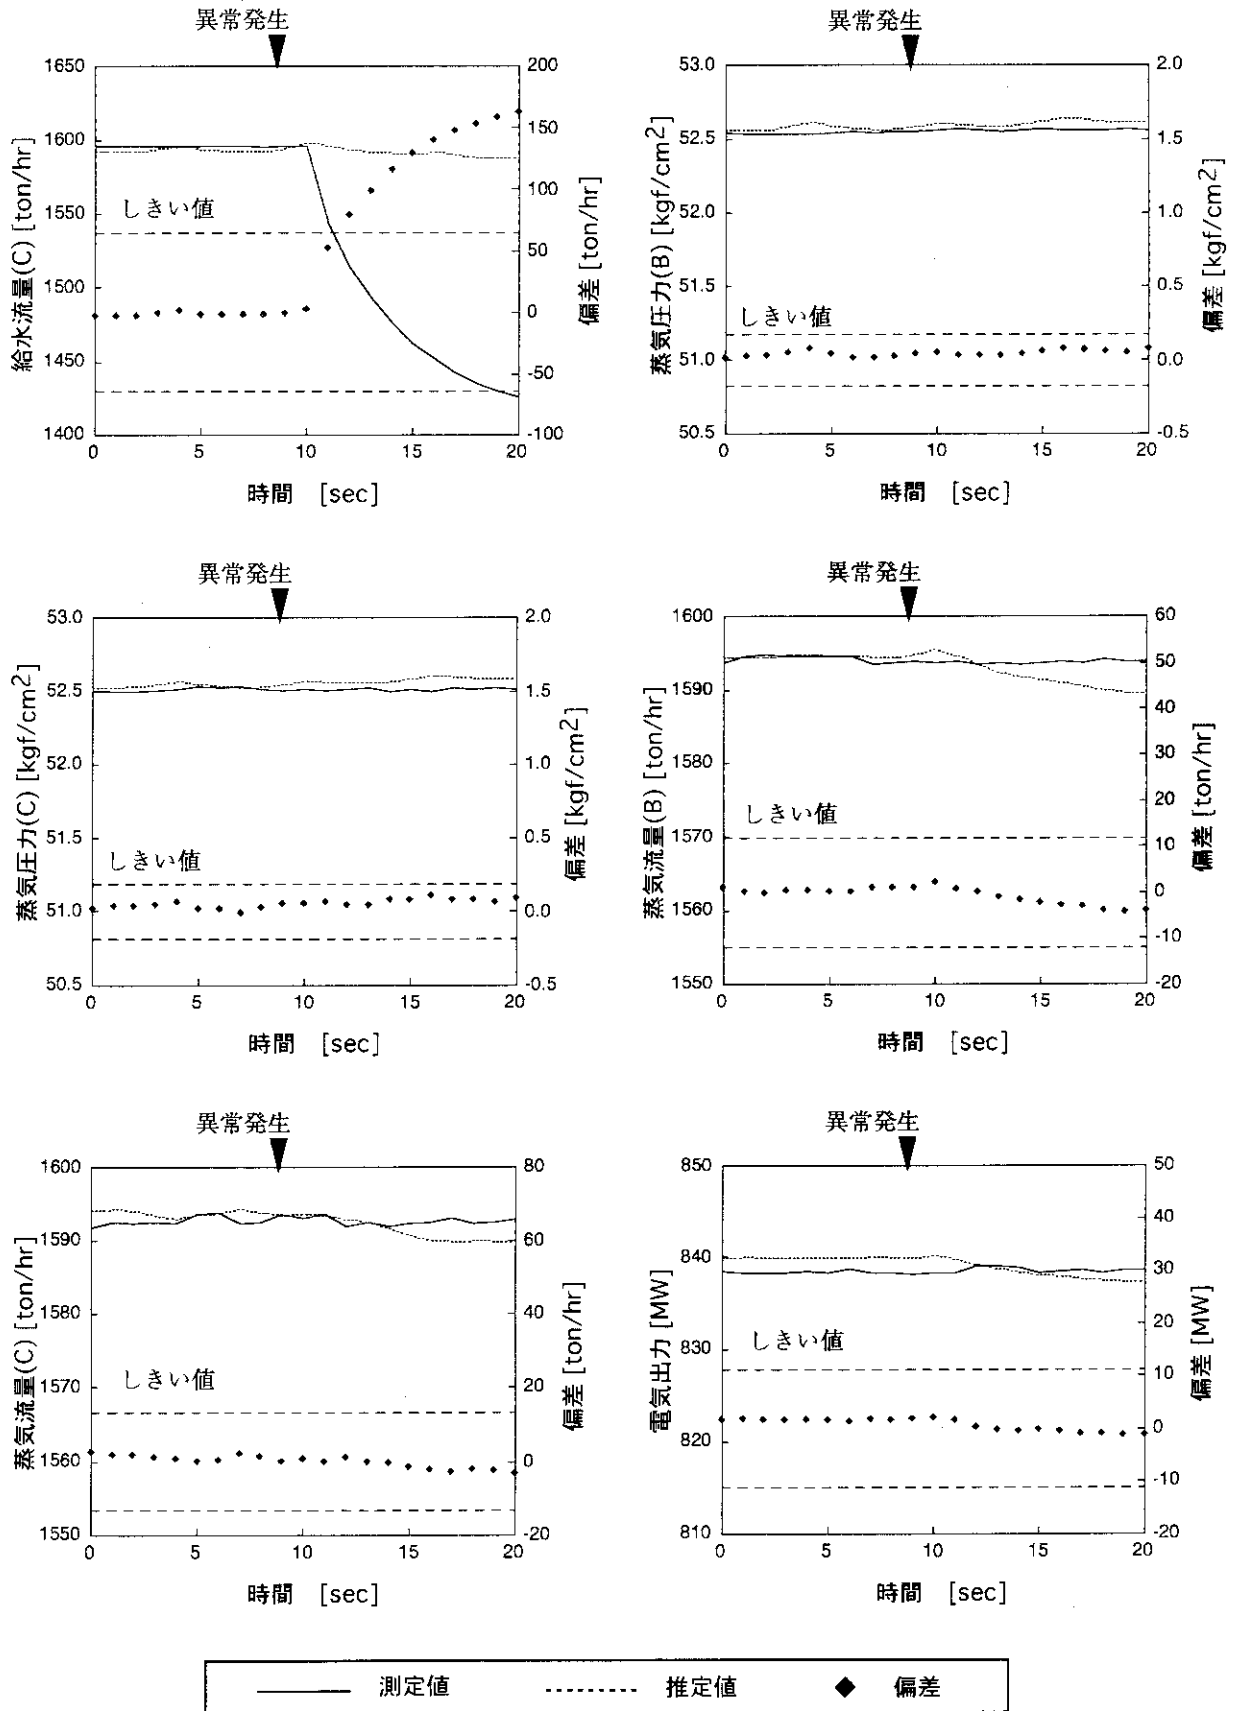


Fig. 6.2(b) 主給水部分喪失時の応答 (0-20秒)

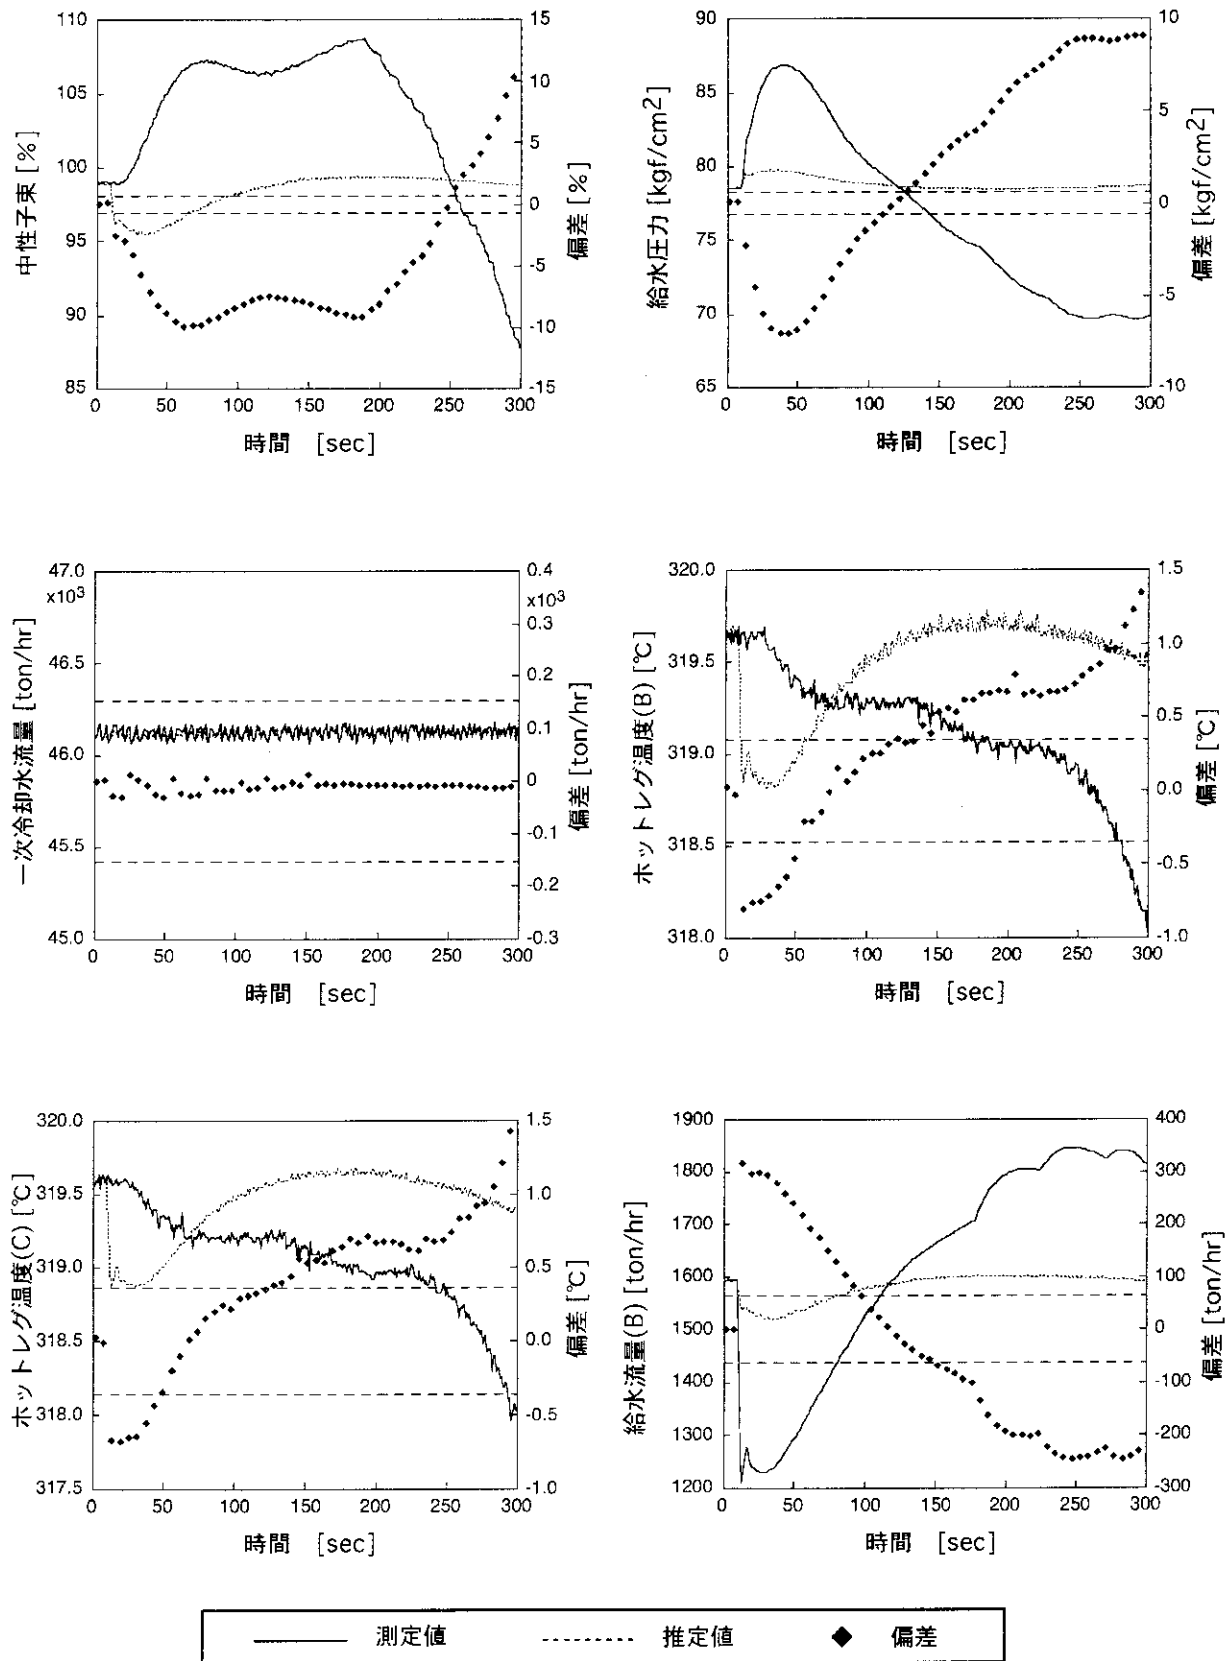


Fig. 6.3(a) 大気放出弁の漏洩時の応答 (1)

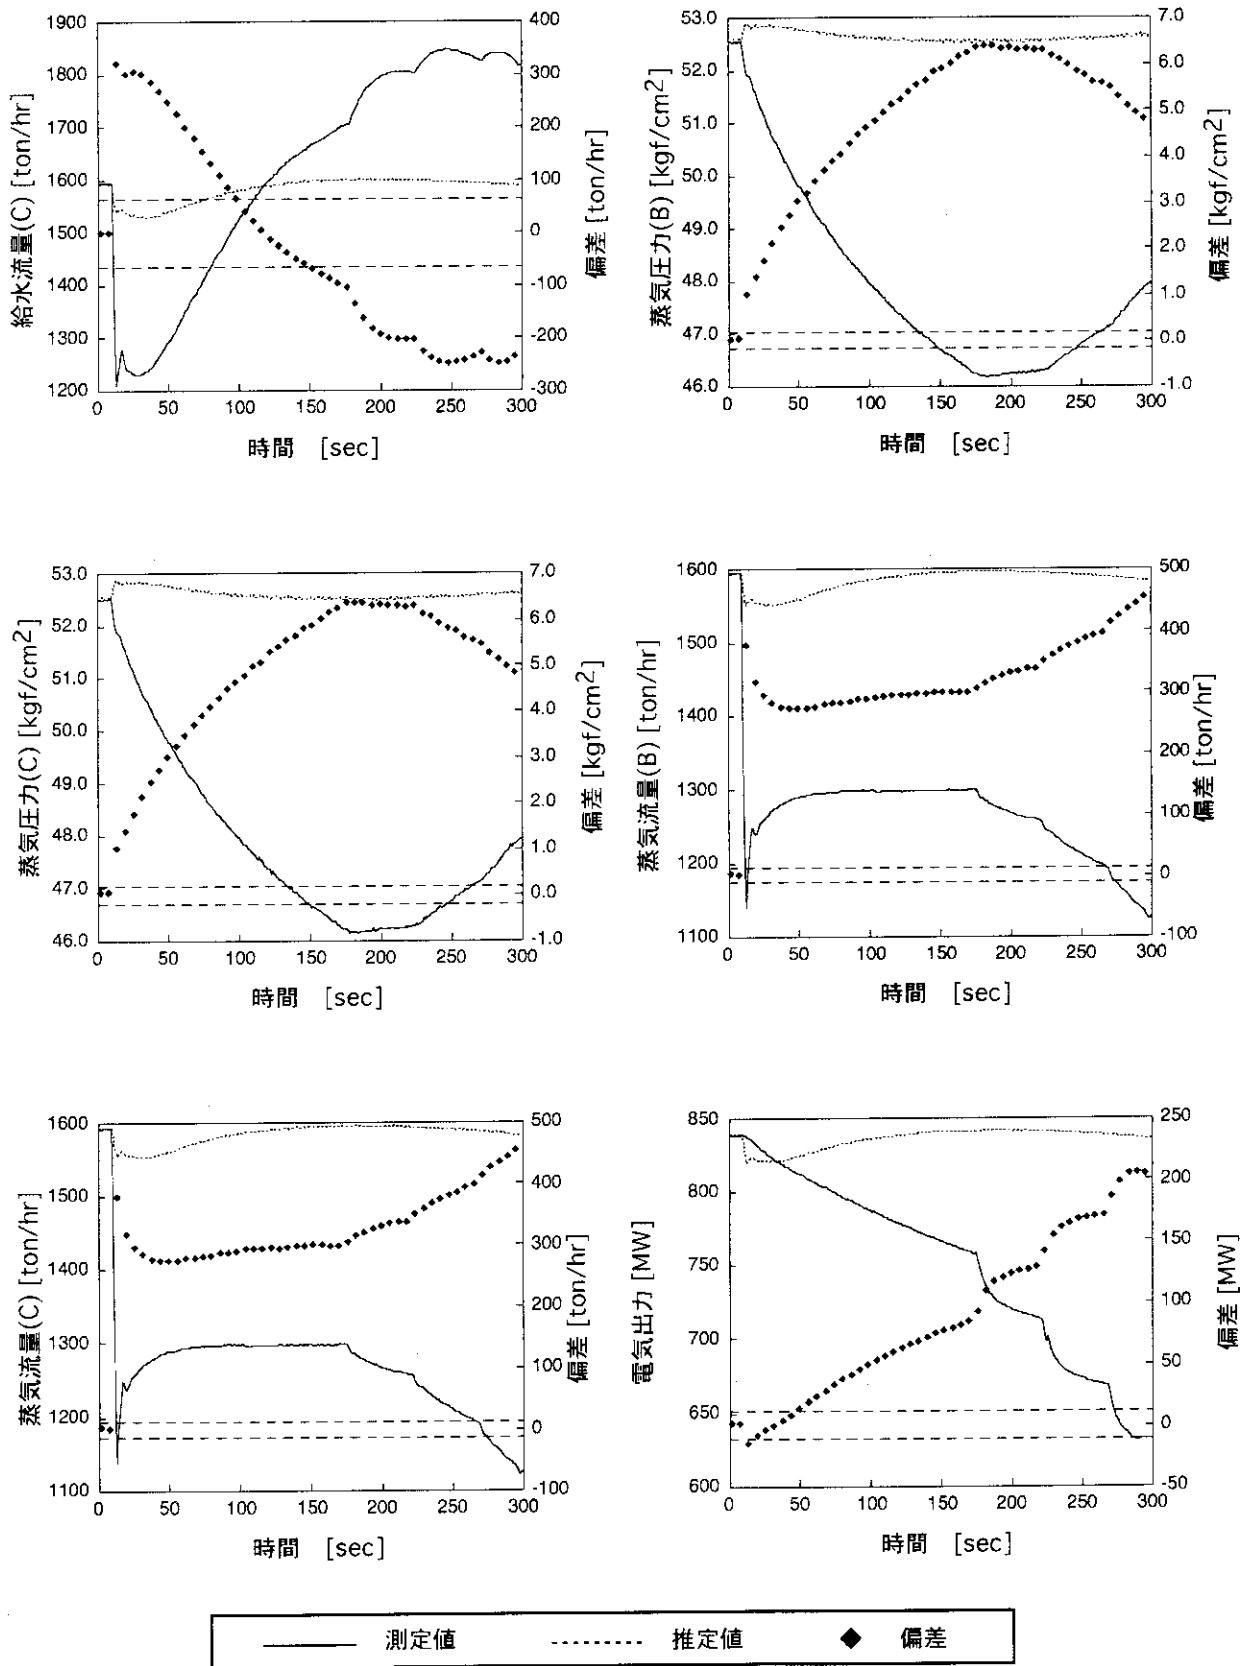


Fig. 6.3(b) 大気放出弁の漏洩時の応答 (2)

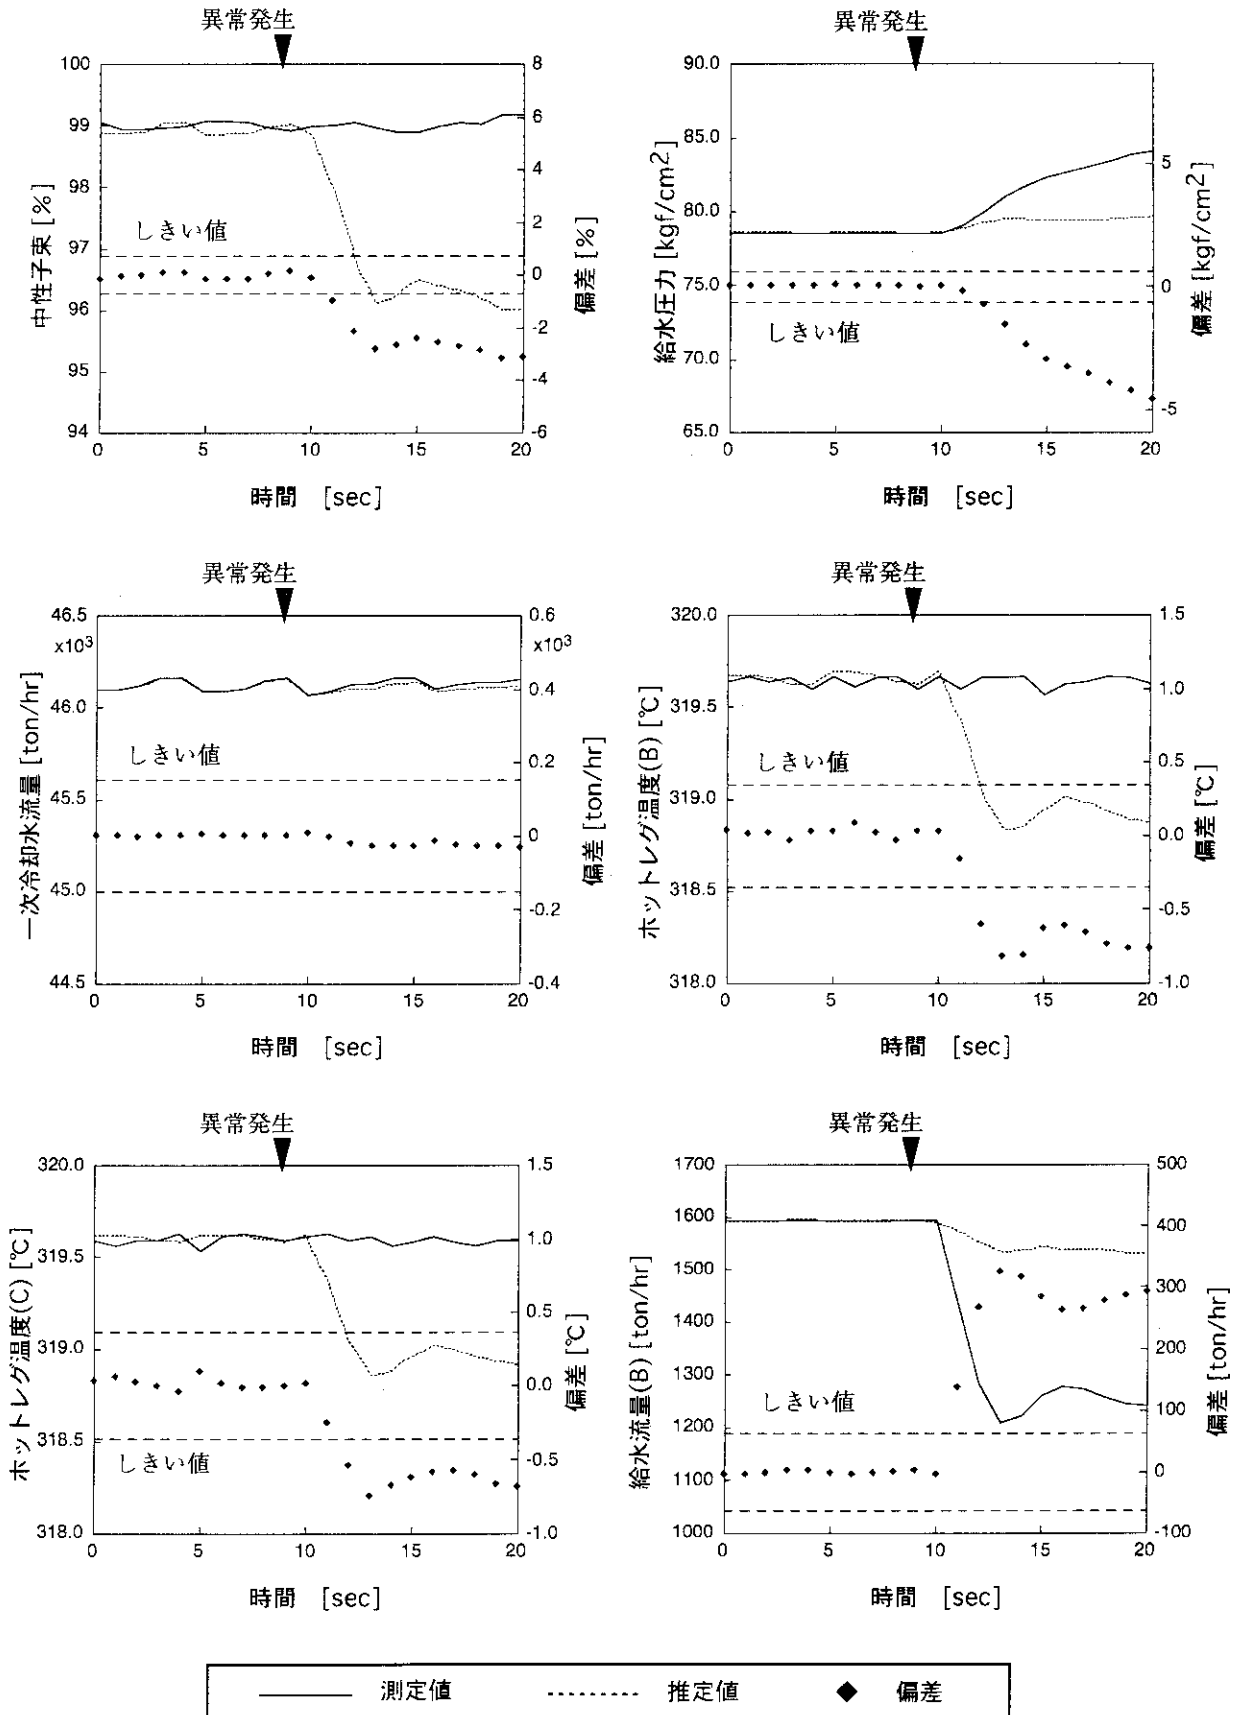


Fig. 6.4(a) 大気放出弁の漏洩時の応答 (0-20秒)

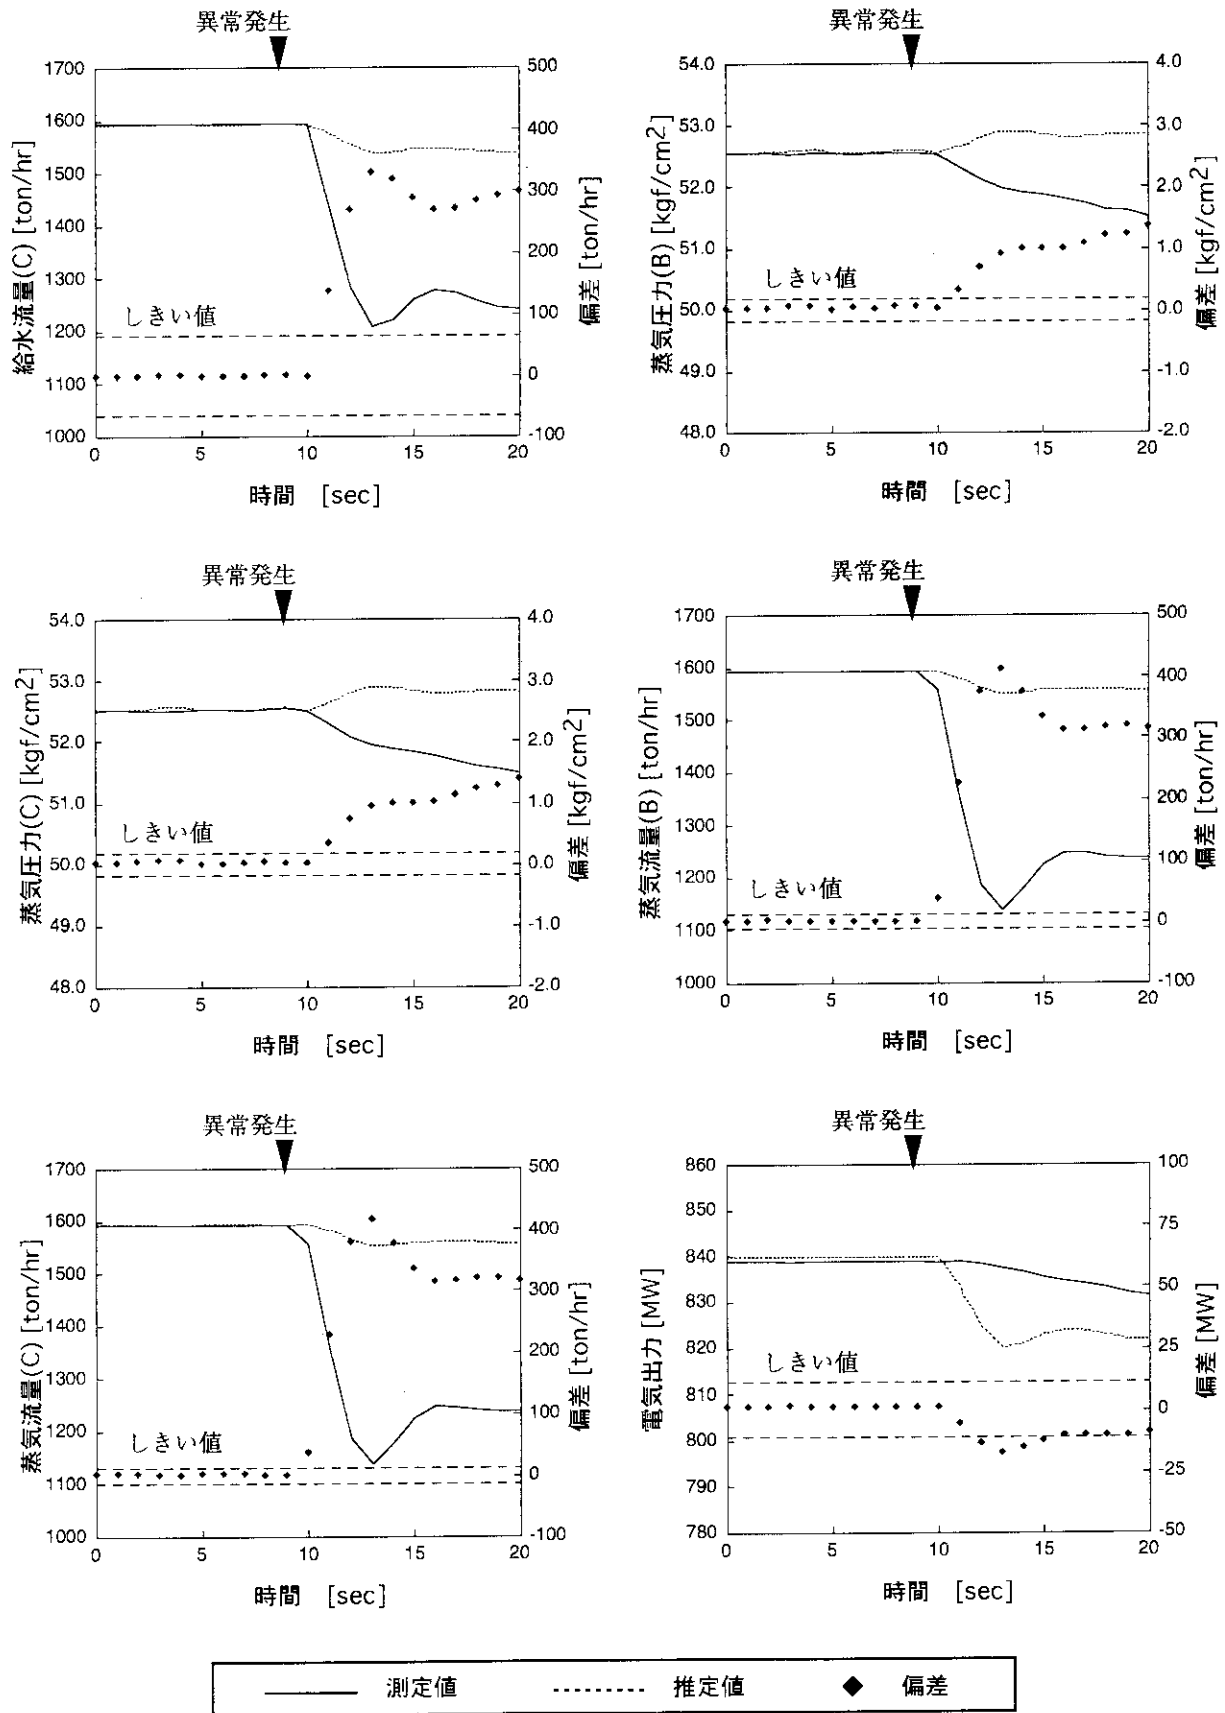


Fig. 6.4(b) 大気放出弁の漏洩時の応答 (0-20秒)

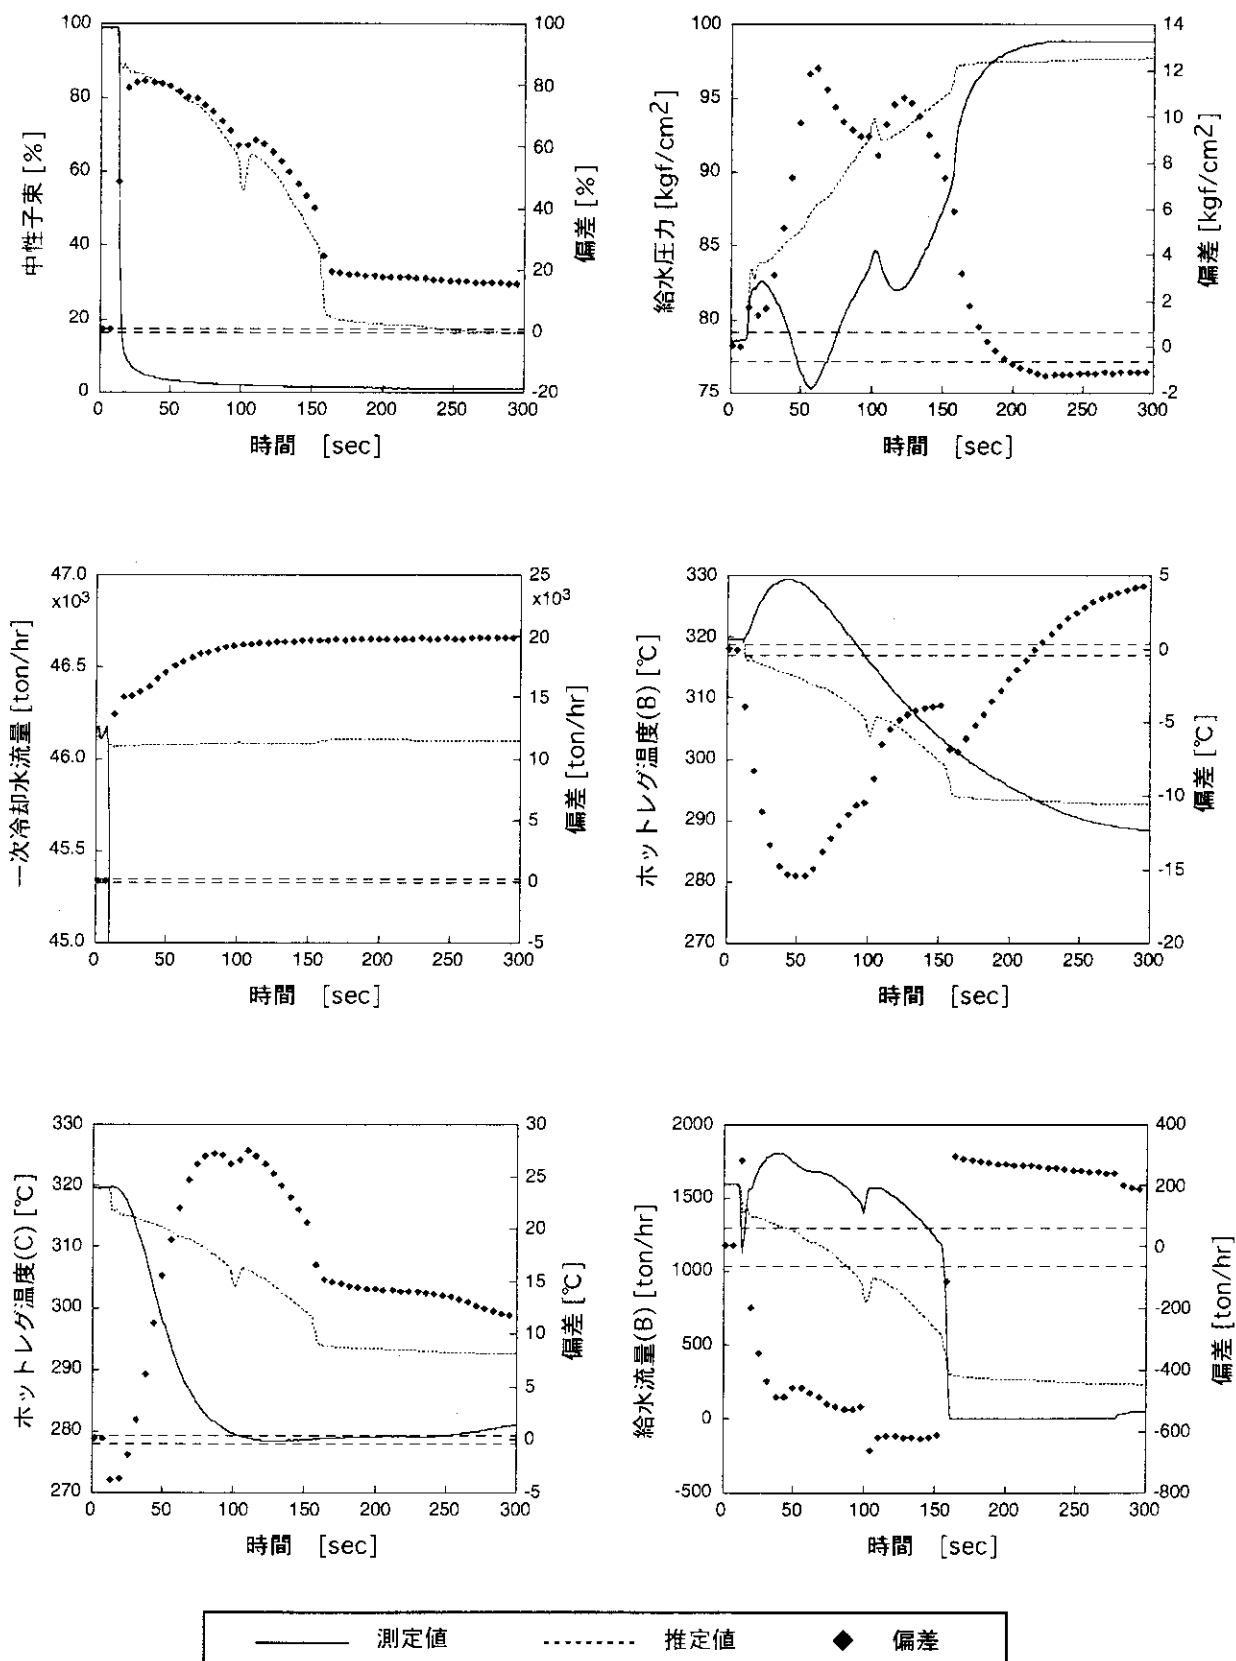


Fig. 6.5(a) 一次冷却材部分喪失時の応答 (1)

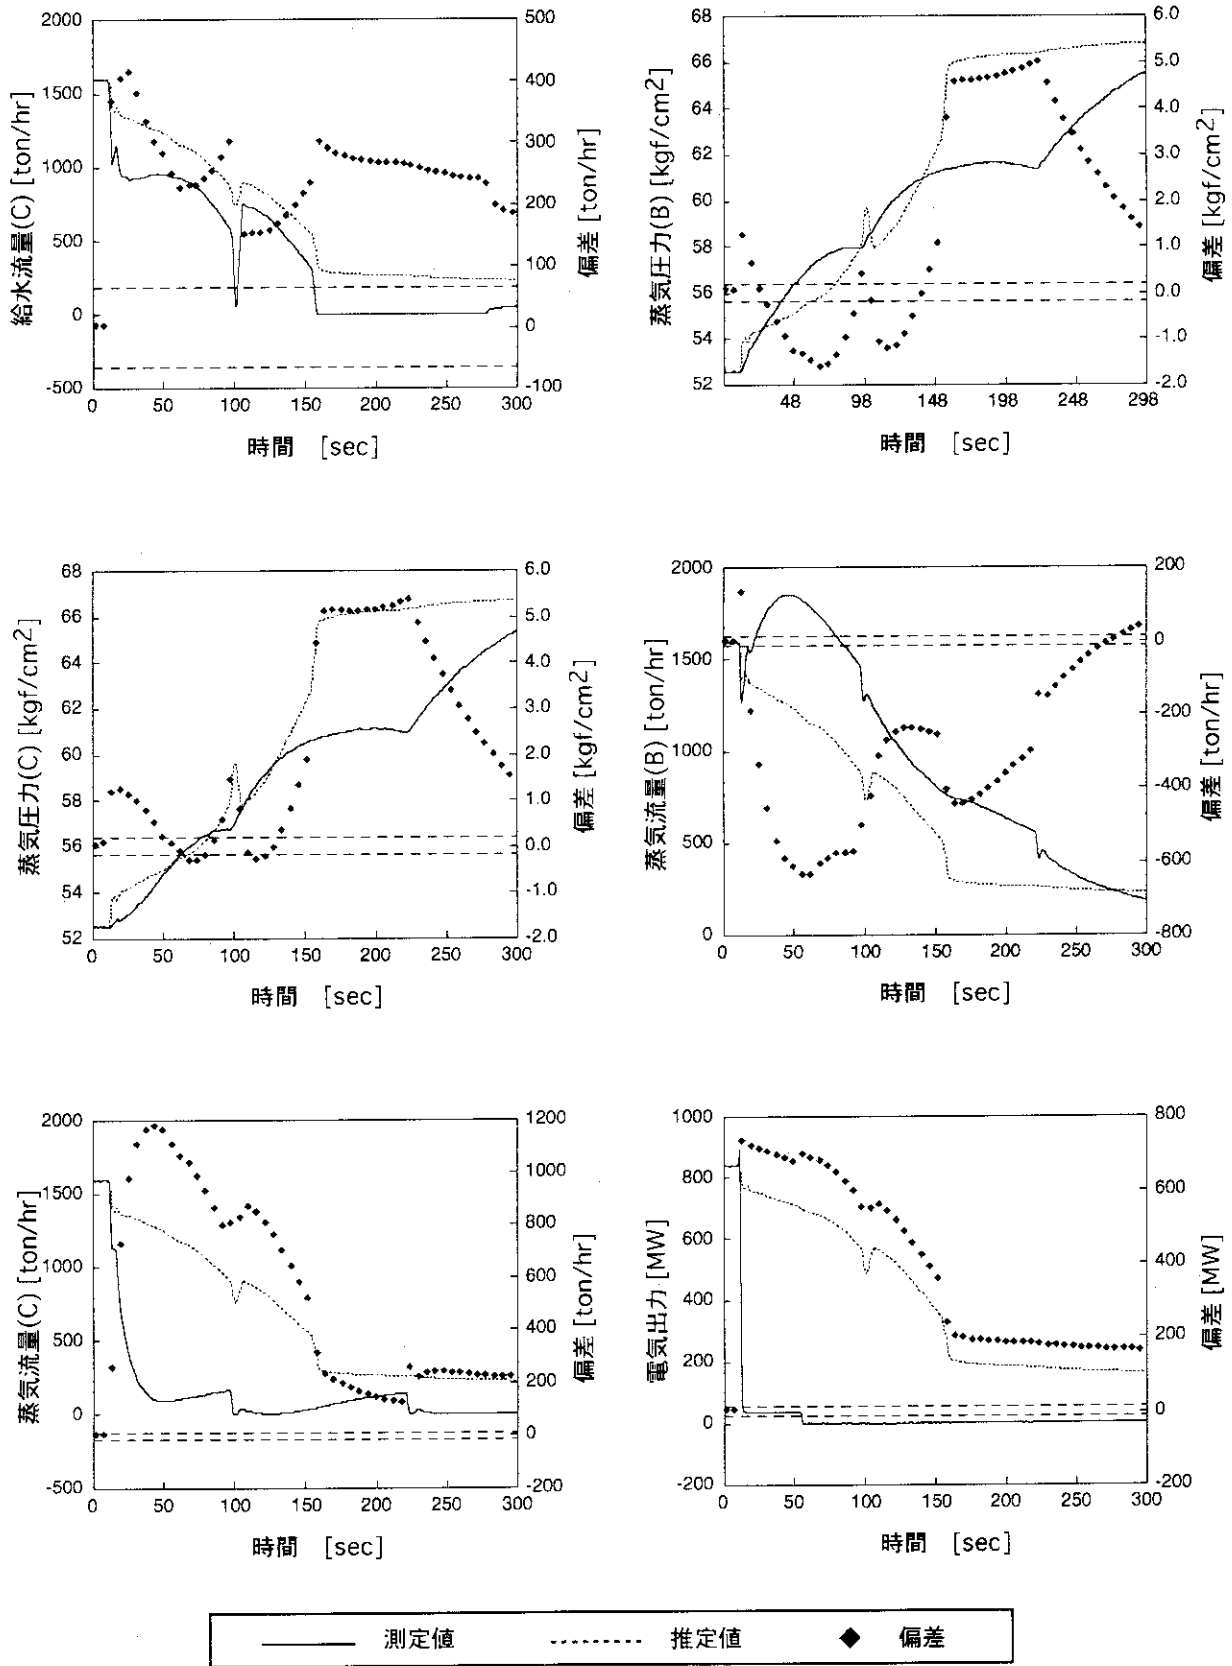


Fig. 6.5(b) 一次冷却材部分喪失時の応答 (2)

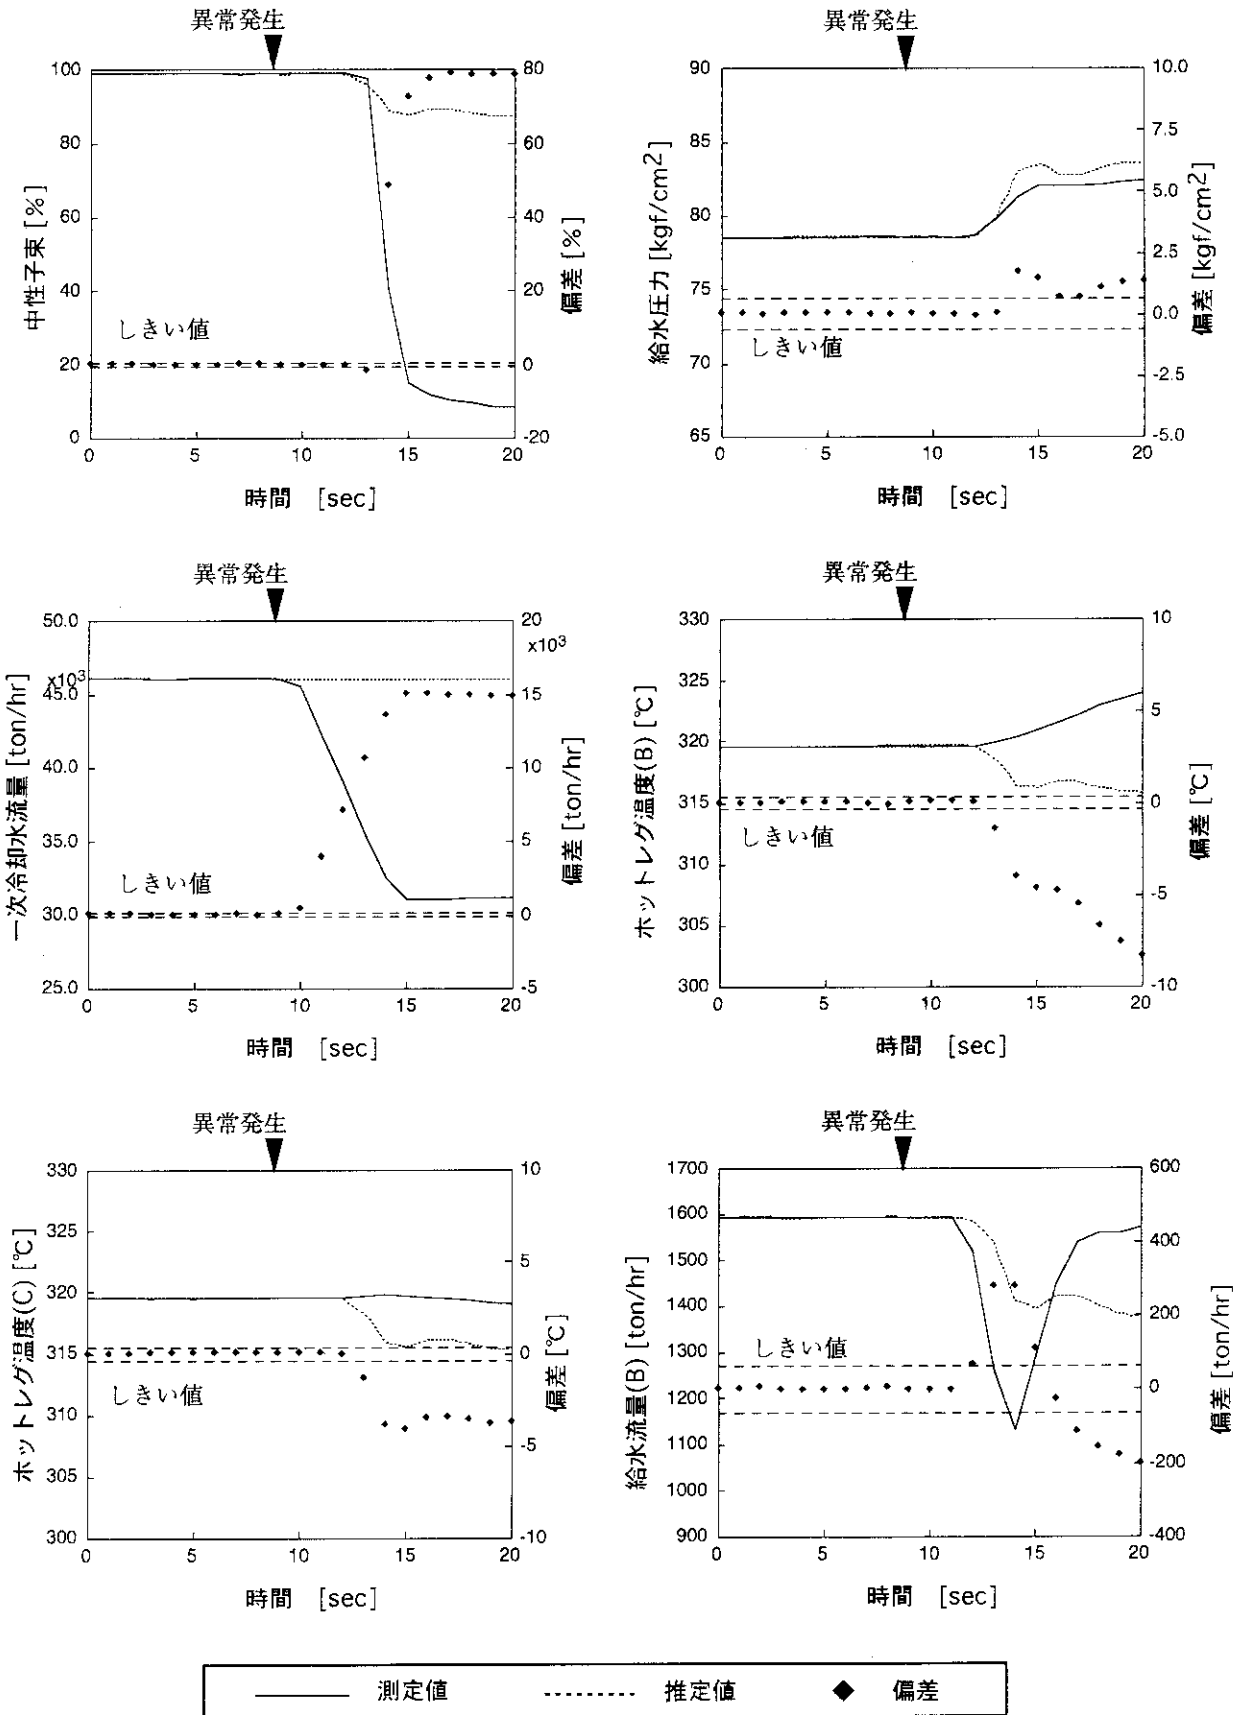


Fig. 6.6(a) 一次冷却材部分喪失時の応答 (0-20秒)

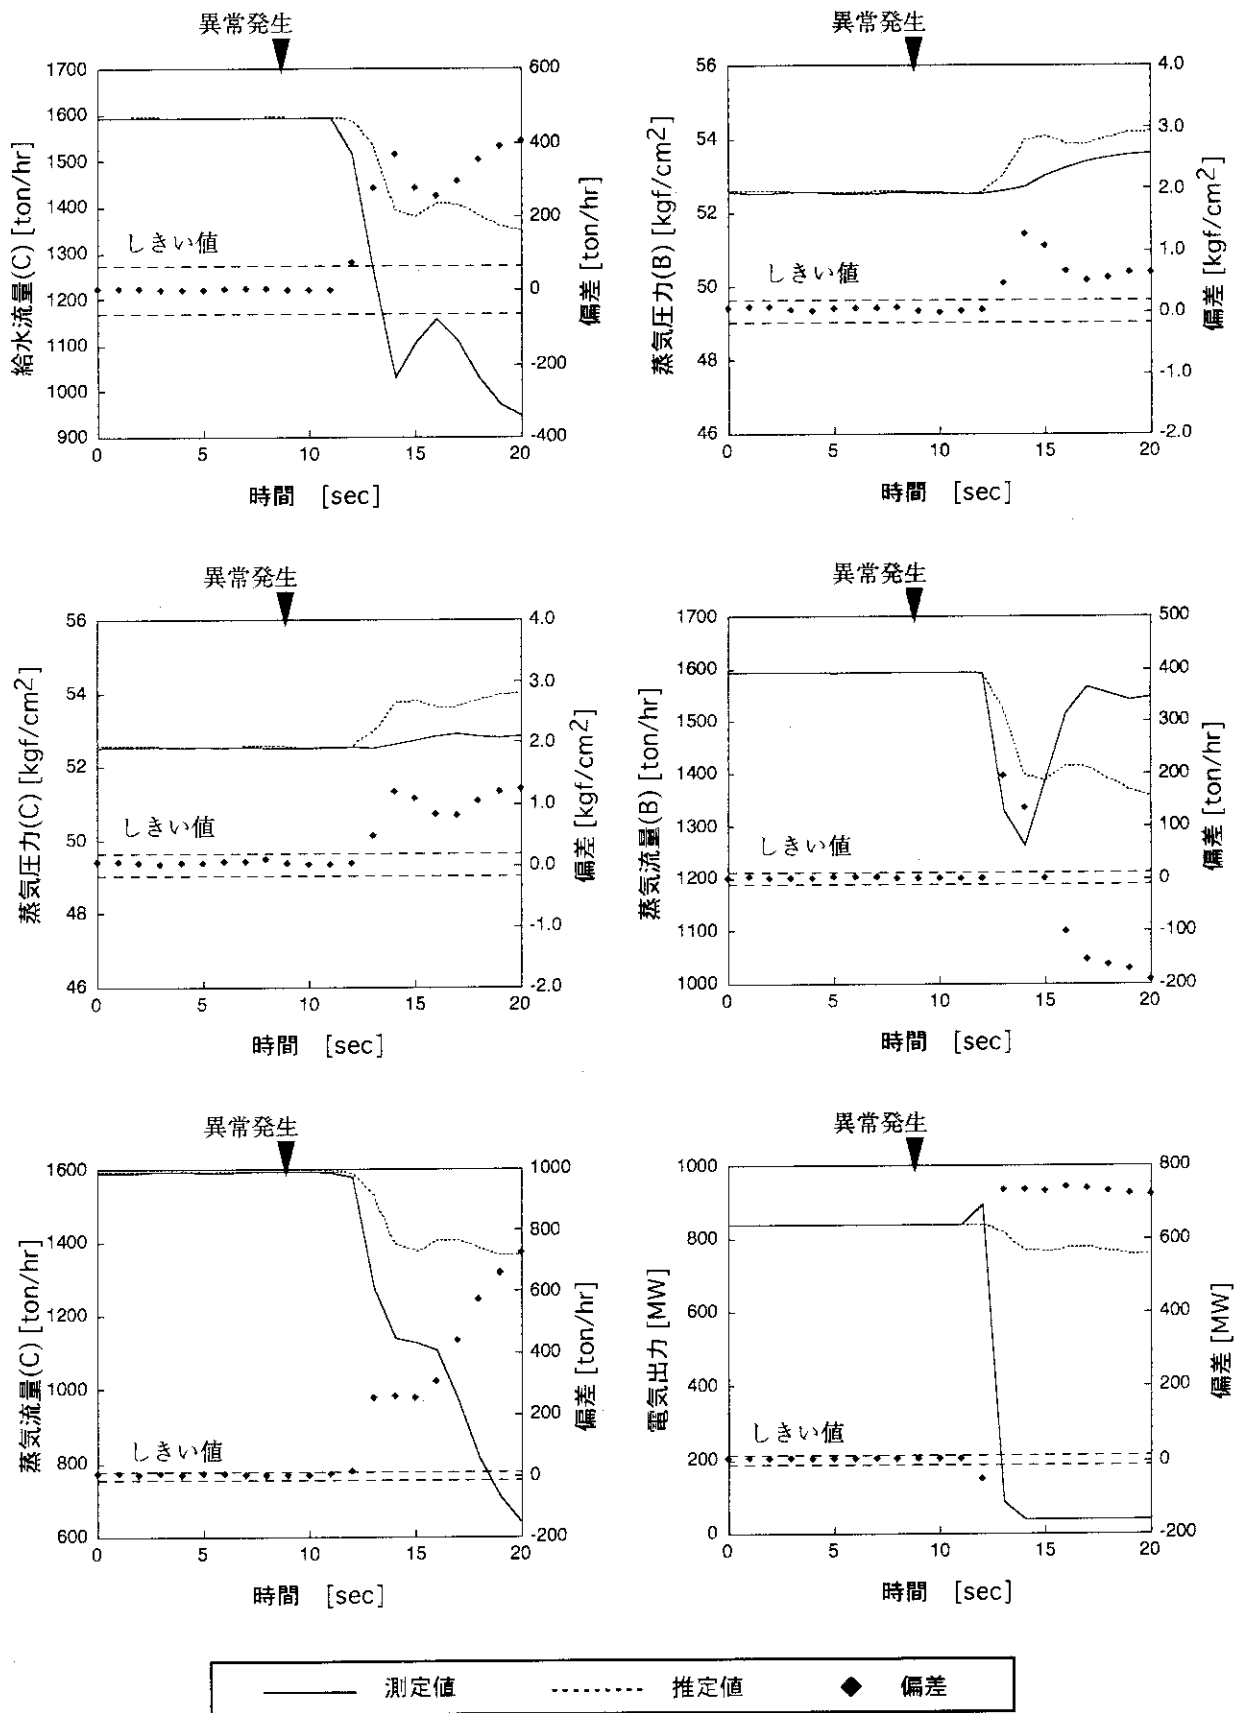


Fig. 6.6(b) 一次冷却水部分喪失時の応答 (0-20秒)

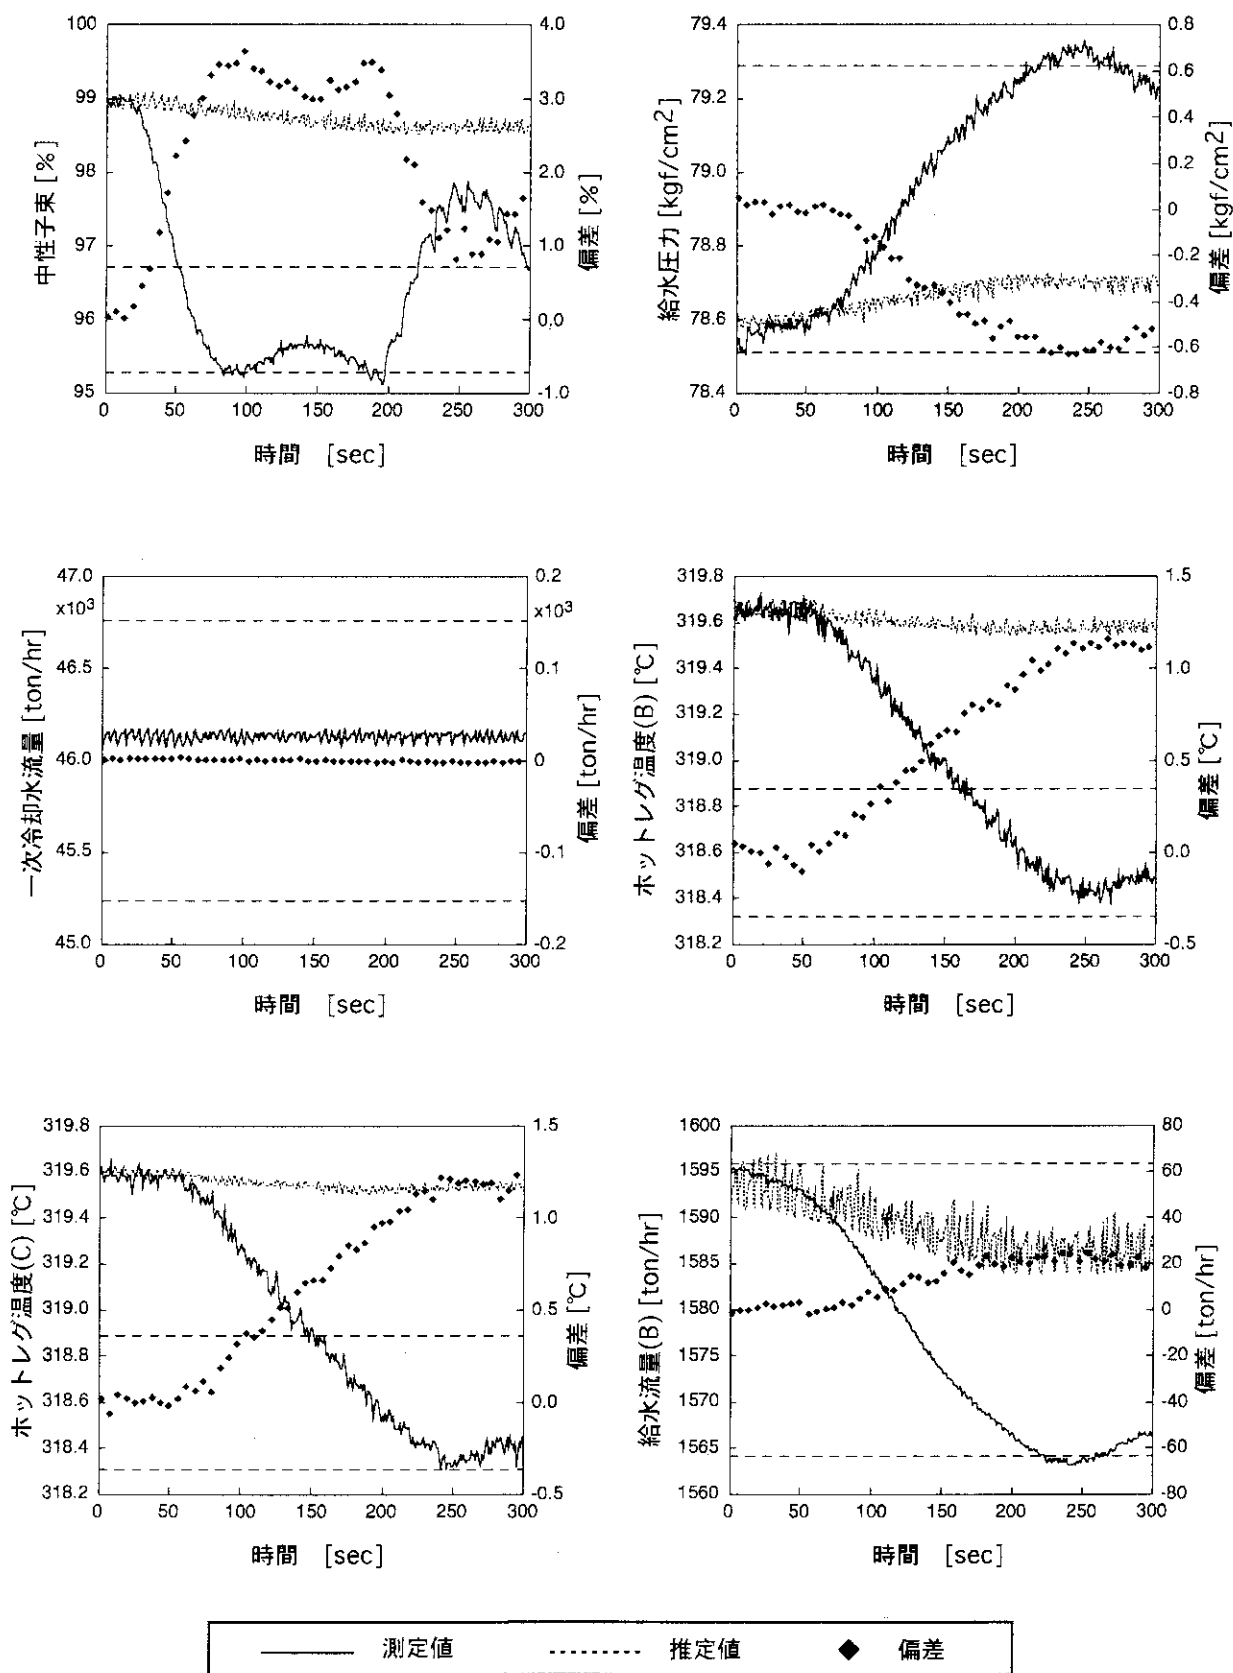


Fig. 6.7(a) 体積制御タンク低水位誤検知時の応答 (1)

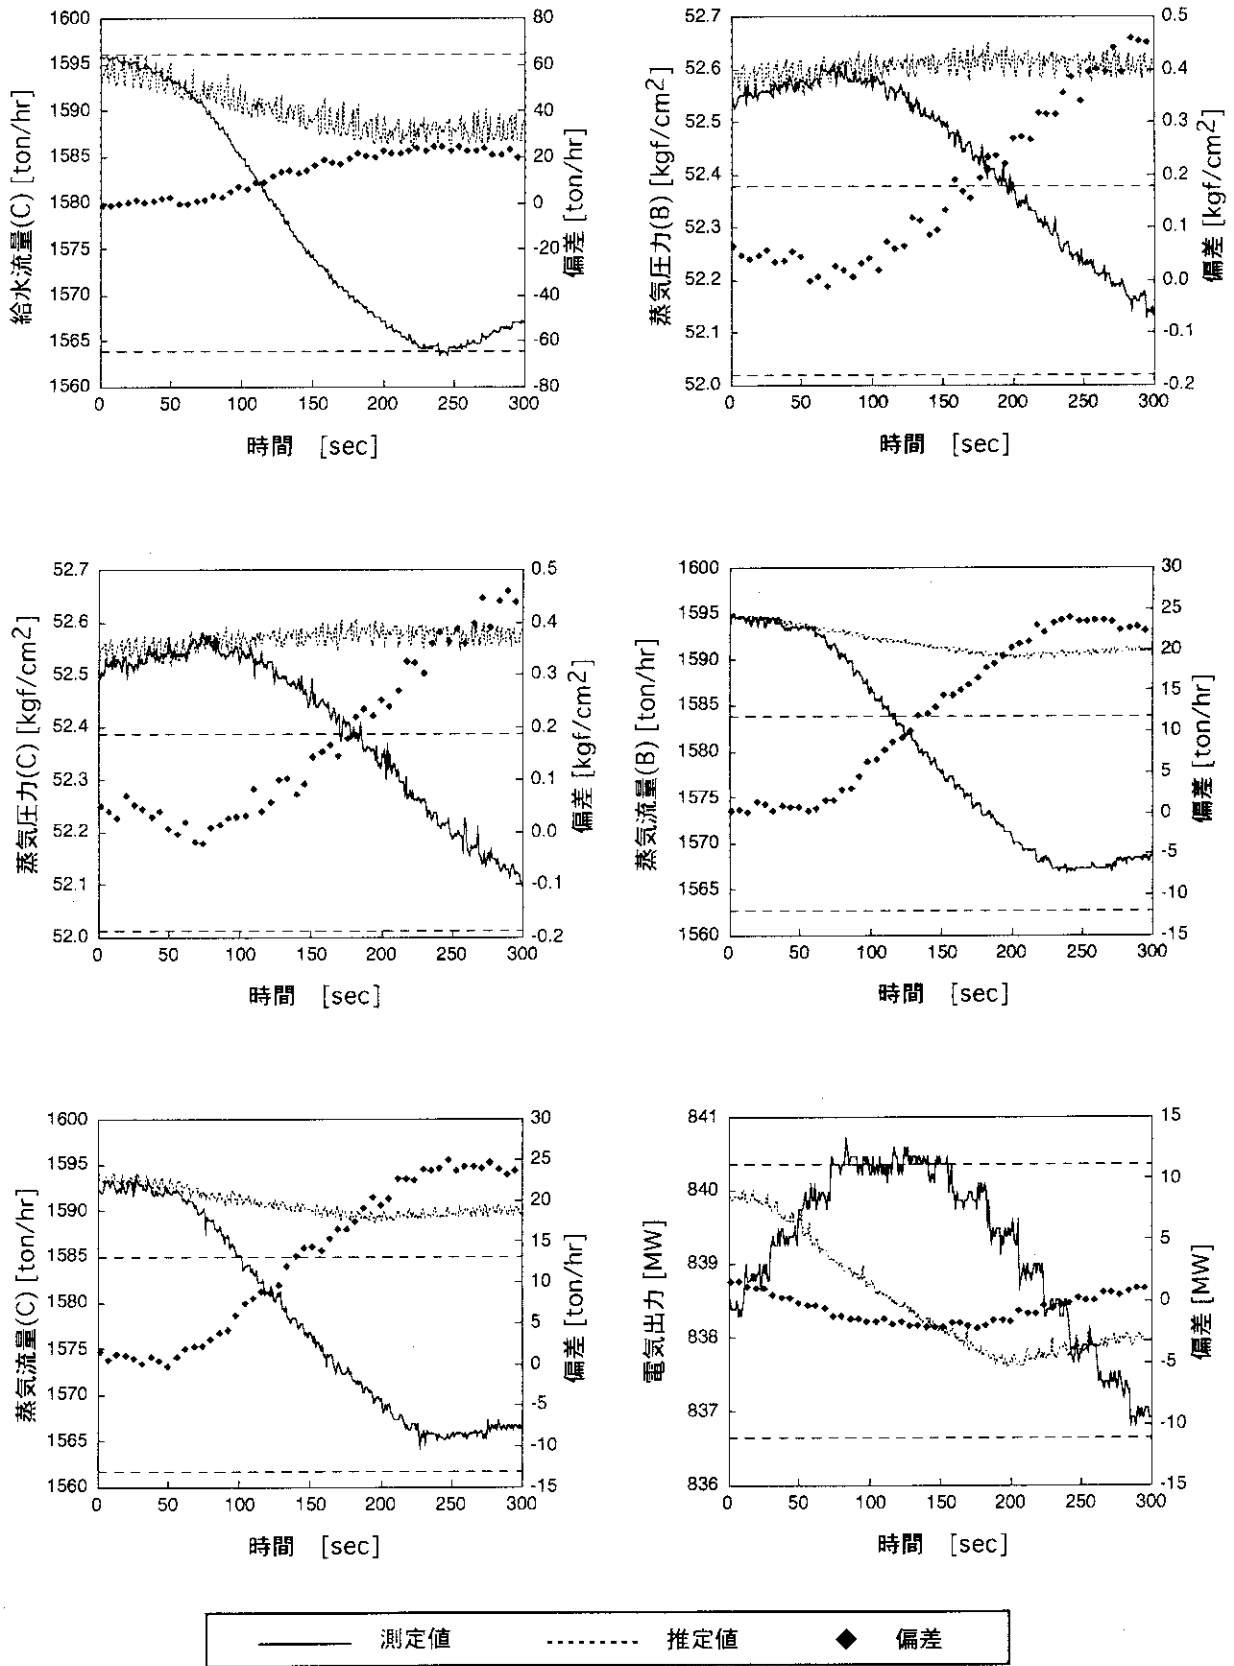


Fig. 6.7(b) 体積制御タンク低水位誤検知時の応答 (2)

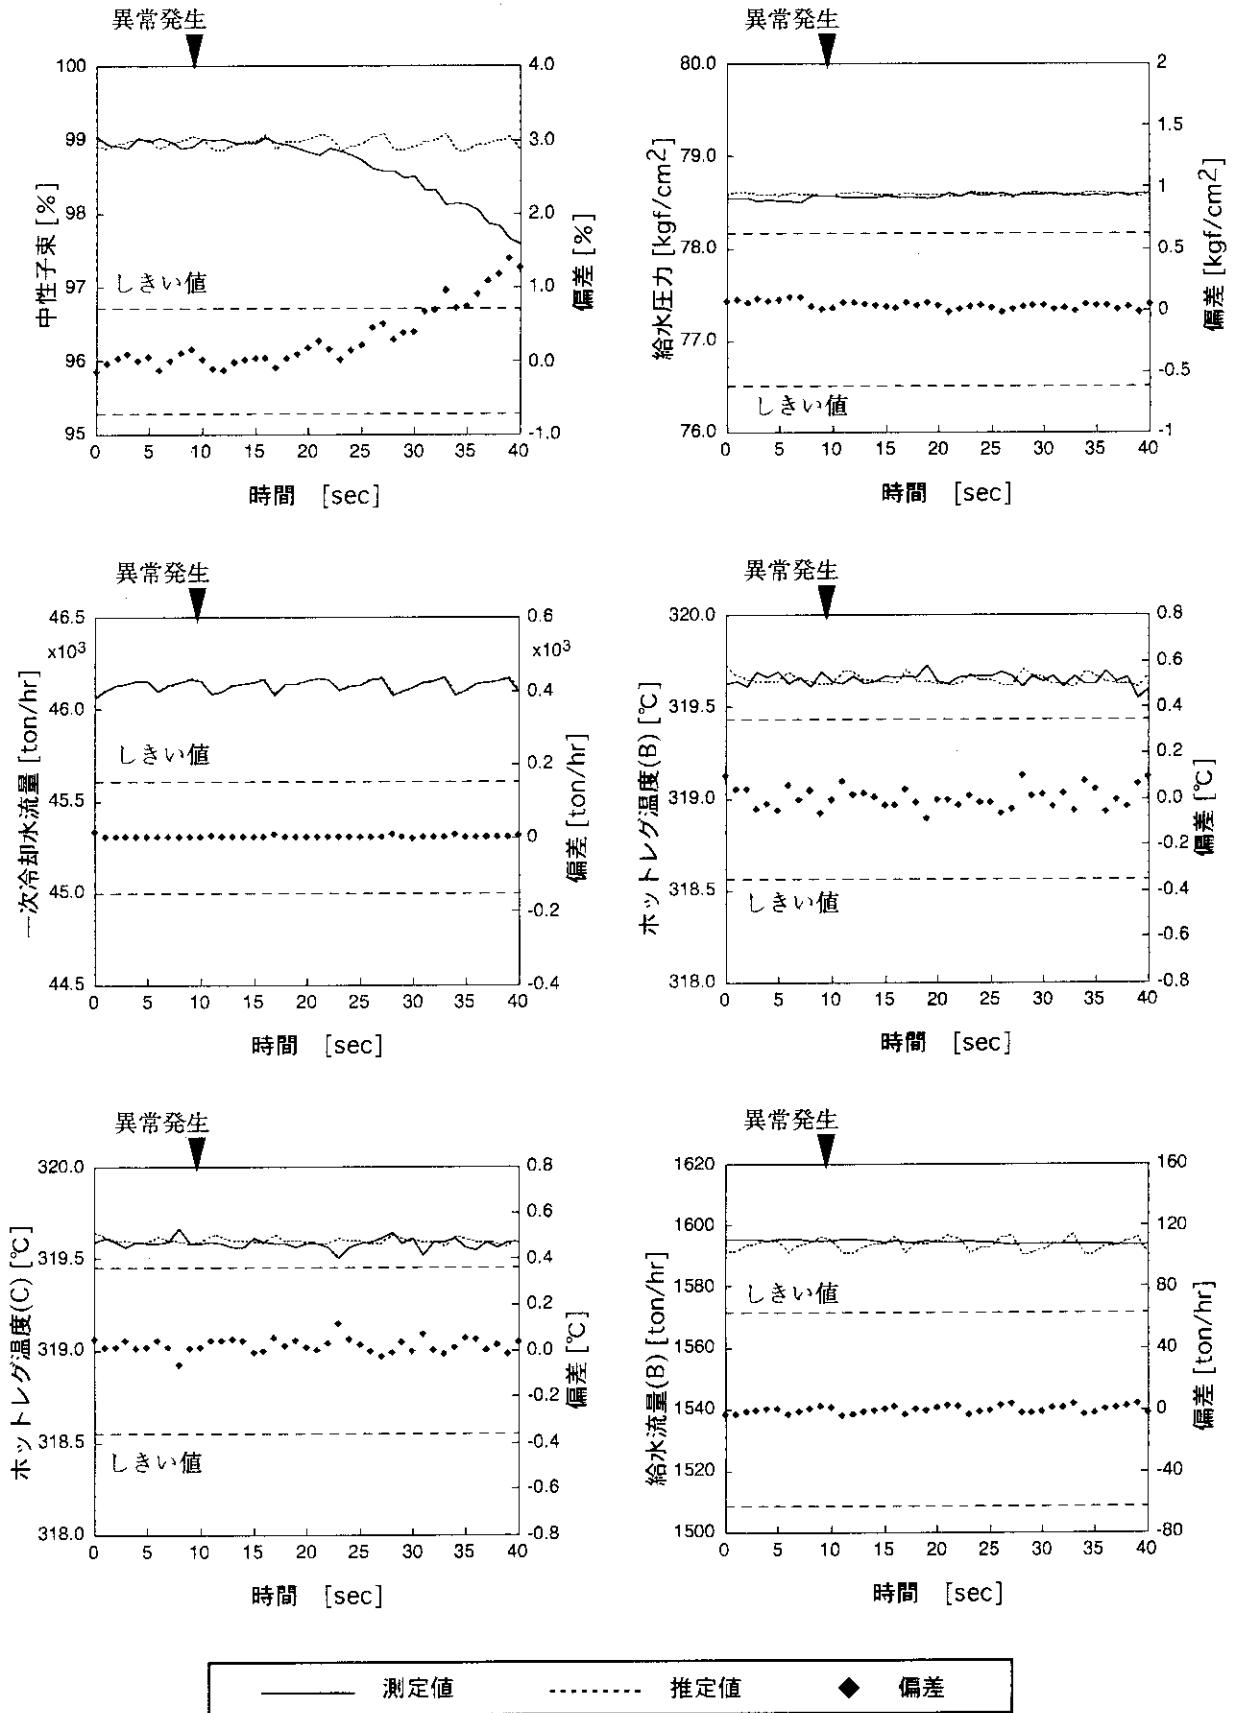


Fig. 6.8(a) 体積制御タンク低水位誤検知時の応答 (0-40秒)

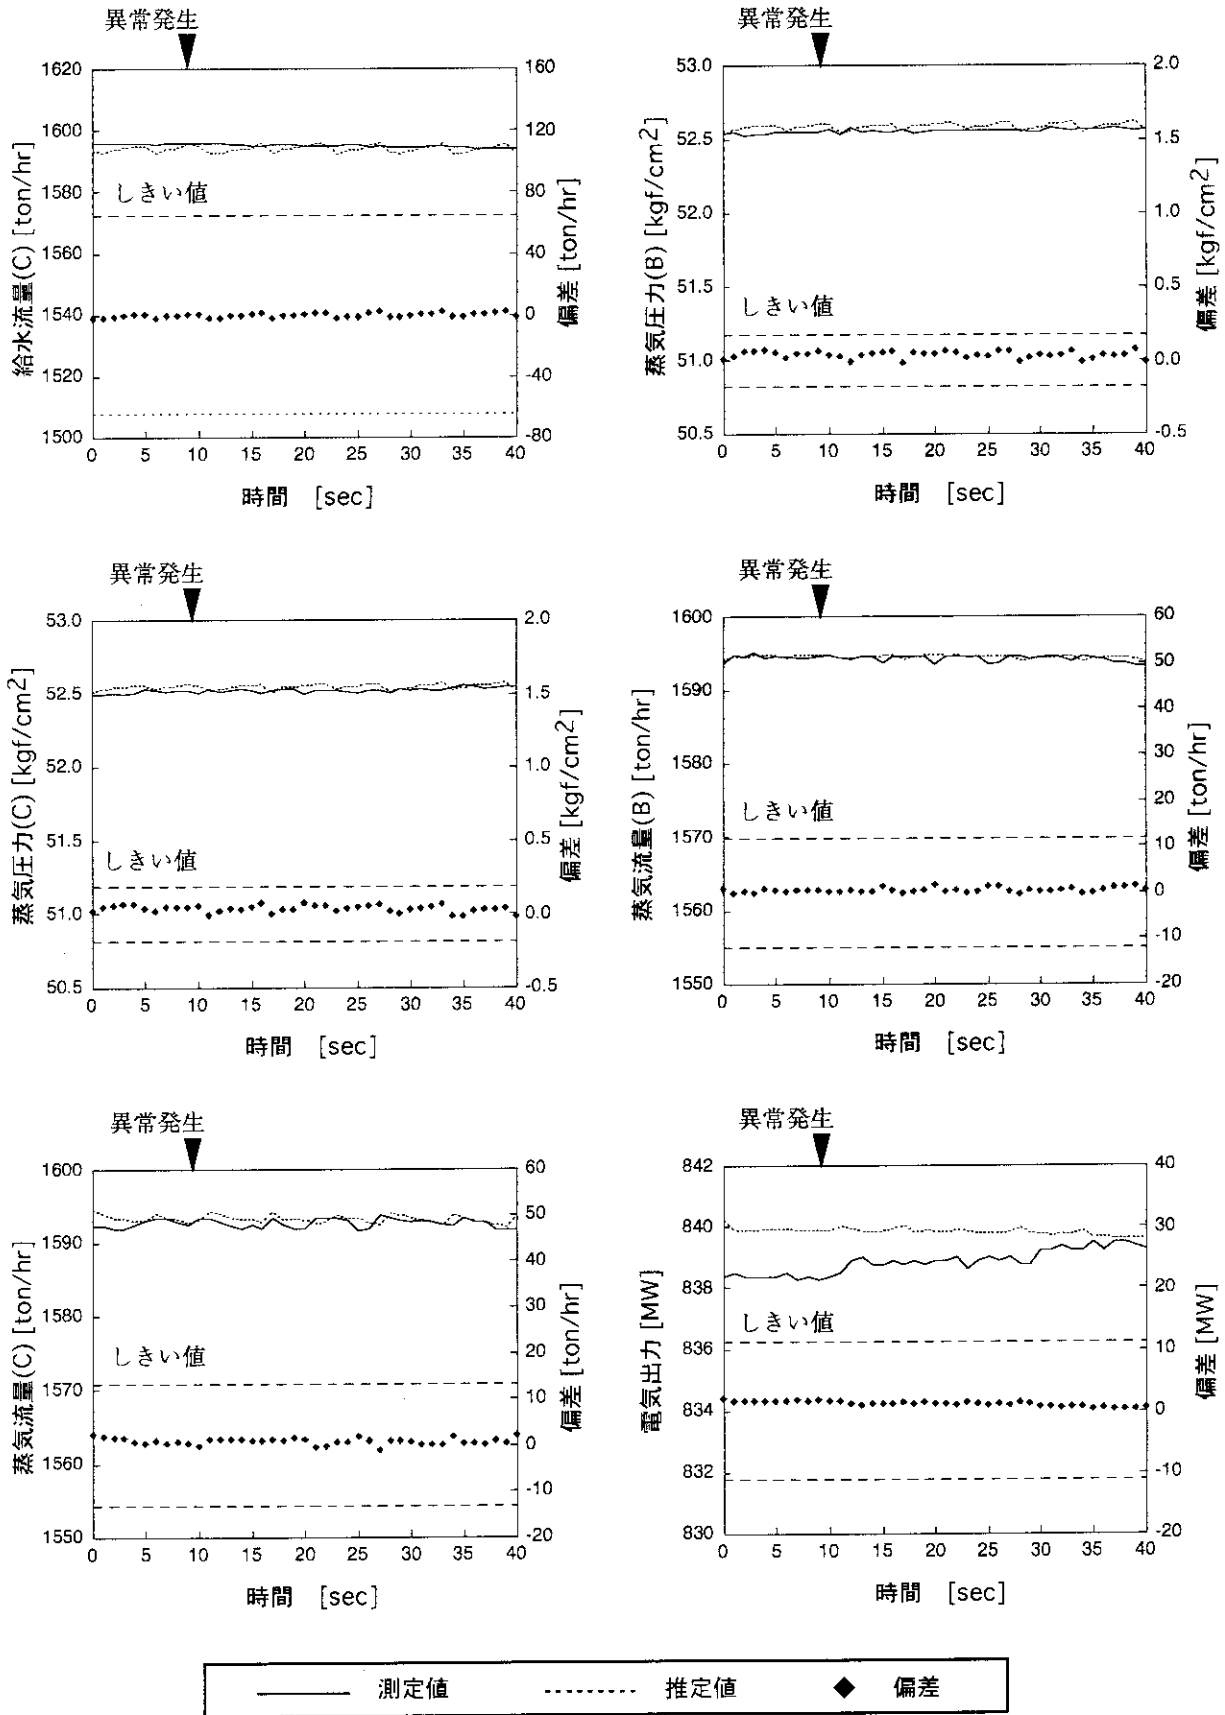


Fig. 6.8(b) 体積制御タンク低水位誤検知時の応答 (0-40秒)

7 結 論

運転訓練用PWRプラントシミュレータを使用して、100%定常出力運転時から4種類の異常事象を発生させ、ニューラルネットワークを用いた異常検知手法の検証を行った。その結果、ニューラルネットワーク監視システムは、4つのプラント異常事象に対して、既存の警報システムがアラームを出す以前に異常を検知することがわかった。さらに、ニューラルネットワークを用いた感度解析を行うことによって、ネットワーク内部構造の一部が明らかになるとともに、ニューラルネットワークが適切に原子炉プラントをモデル化できることが証明された。

以上の結果から、ニューラルネットワークを利用した監視システムが、原子炉の早期異常検知に非常に有効であることが明らかになった。しかし、今回の解析では初期学習に定常運転時のデータのみを使用したため、監視信号の変動に対して本監視システムが敏感に反応しすぎる傾向があり、正常な過渡運転時にも異常と診断する可能性がある。従って、このシステムを実際の原子炉に適用する場合には、原子炉の起動・停止等の通常の過渡運転データも学習に加える必要があるため、今後は本シミュレータによる過渡運転データの作成が重要な課題となる。ただし、実際の原子炉の運転データを使用した例からは、過渡運転データを加えた場合にも良好な結果が得られている上、低出力過渡運転時の異常事象も検知できている³⁾ため、シミュレータに対する本監視システムの性能もほとんど変わらないと考えてよい。なお、ノイズも含めた検出器の異常に対しては、ニューラルネットワークだけでなくエキスパートシステムのような知識情報を利用して、プロセス異常と区別する必要がある。

次の段階では、このPWRプラントシミュレータから得られるシミュレーションデータを利用して、いろいろな異常事象が発生する際の各プラント信号の挙動とニューラルネットワークによる推定値の偏差をデータベース化し、現在原研で開発が進められているニューラルネットワークとエキスパートシステムを組み合わせたハイブリット原子力プラント監視システムの知識ベース部分を作成する。このエキスパートシステム部の拡充により、異常事象の早期検知だけでなく、異常の種類・場所・原因等を特定する総合的な異常診断システムの開発に役立つ。そして最終的には、改良された本監視システムを実際の原子力プラントに適用し、検証を行う予定である。

参考文献

- 1) Turkcan E., et al, "Operational Experiences on the Borssele Nuclear Power Plant using Computer based Surveillance and Diagnostic System On-line", ECN-RX--91-057 (1991).
- 2) Uhrig R.E. : Potential Application of Neural Networks to the Operation of Nuclear Power Plants, Nuclear Safety, Vol.32 No.1 (1991).
- 3) Nabeshima K., Turkcan E. and Ciftcioglu O: "On-line Nuclear Power Plant Monitoring with Neural Network", Proc. of Third International Conference on Nuclear Engineering, April 23-27, 1995, Kyoto, Vol.3, p1551 (1995).
- 4)村上喜光、内藤彰、横林正雄：JAERI-M 83-048, " PWRプラント・シミュレータによる事故解析・その1 (一次系の解析) " (1983)
- 5)内藤彰、村上喜光、横林正雄：JAERI-M 83-081," PWRプラント・シミュレータによる事故解析・その2 (二次系の解析) " (1983)
- 6)鍋島邦彦、他：JAERI-Research 95-076, " ニューラルネットワークによる原子炉プラント監視手法と実炉への応用" (1995)
- 7) Rumelhart D.E., Hinton G.E. and Williams R.J., : "Learning Internal Representations Error Propagation, In Parallel Distributed Processing", Vol.1, MIT Press (1986).
- 8) Nabeshima K., Suzuki K. and Turkcan E.: "Neural Network with an Expert System for Real-time Nuclear Power Plant Monitoring", Proc. of a Symposium on Nuclear Reactor Surveillance and Diagnostics VII, Vol. 1. (1995)