



ニューラルネットワークを用いた
原子炉異常監視技術の研究

2001年3月

鍋島邦彦

日本原子力研究所

Japan Atomic Energy Research Institute

日本原子力研究所研究成果編集委員会

委員長 佐藤 征夫 (理事)

委 員

天野 英俊 (ホット試験室)	津田 孝 (炉心プラズマ研究部)
新井 英彦 (環境・資源利用研究部)	野村 靖 (燃料サイクル安全工学部)
伊予久達夫 (高温工学試験研究炉開発部)	馬場 恒孝 (環境安全研究部)
岩本 昭 (物質科学研究部)	藤木 和男 (材料試験炉部)
大道 英樹 (研究情報部)	細金 延幸 (核融合装置試験部)
小川 益郎 (核熱利用研究部)	前多 厚 (N U C E F 試験部)
小原 祥裕 (核融合工学部)	室村 忠純 (環境科学研究部)
加藤 正平 (保健物理部)	森 貴正 (エネルギーシステム研究部)
西堂 雅博 (放射線高度利用センター)	森田 洋右 (材料開発部)
桜井 文雄 (研究炉部)	柳原 敏 (バックエンド技術部)
佐々木貞吉 (放射光利用研究部)	芳野 隆治 (企画室)
笹本 宣雄 (中性子科学研究センター)	依田 修 (光量子科学研究センター)
棚瀬 正和 (環境・資源利用研究部)	渡辺 正 (計算科学技術推進センター)

Japan Atomic Energy Research Institute

Board of Editors

Yukio SATO (Chief Editor)

Hidetoshi AMANO	Fumio SAKURAI	Atsushi MAEDA
Hidehiko ARAI	Teikichi SASAKI	Tadazumi MUROMURA
Tatsuo IYOKU	Nobuo SASAMOTO	Takamasa MORI
Akira IWAMOTO	Masakazu TANASE	Yosuke MORITA
Hideki OMICHI	Takashi TSUDA	Satoshi YANAGIHARA
Masuro OGAWA	Yasushi NOMURA	Ryuji YOSHINO
Yoshihiro OHARA	Tsunetaka BANBA	Osamu YODA
Shohei KATO	Kazuo FUJIKI	Tadashi WATANABE
Masahiro SAIDOH	Nobuyuki HOSOGANE	

JAERIレポートは、日本原子力研究所が研究成果編集委員会の審査を経て不定期に公開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（〒319-1195 茨城県那珂郡東海村）あて、お申し込み下さい。なお、このほかに財団法人原子力弘済会資料センター（〒319-1195 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。

JAERI reports are reviewed by the Board of Editors and 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, 319-1195, Japan.

© Japan Atomic Energy Research Institute, 2001

編集兼発行 日本原子力研究所

ニューラルネットワークを用いた
原子炉異常監視技術の研究

日本原子力研究所東海研究所エネルギーシステム研究部

鍋島 邦彦

(2000年10月19日受理)

要旨

本研究は、ニューラルネットワークに過去の正常な運転データを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手法について検討したものである。この手法の概念は、正常運転データのみを学習したニューラルネットワークに異常な運転パターンが入力された場合、ニューラルネットワークによる各プラント変数の推定値が、実際の測定値と異なってくることを利用し、2つの偏差を監視することによって、原子力プラント内の微小な異常兆候を検知するものである。入出力が同じ信号をもつオートアソシアティブネットワークを使用すると、正常時の運転データのみから、全ての異常事象を検知することが可能となる。

まず、様々な異常事象を容易に模擬できるPWRプラントシミュレータを使用して、適応学習付フィードフォワード型ニューラルネットワークの異常検知性能の評価を行った。その結果、適応学習法を取り入れたフィードフォワード型ニューラルネットワークは、プラント動特性や緩やかな状態の変化にモデルを追従させることが可能で、しかも定常運転時だけでなく過渡運転時に発生したほとんどの異常事象についても、従来の監視システムよりもはるかに早い段階で検知できることが明らかになった。次に、このニューラルネットワークを用いた異常監視システムを、実際の原子力発電所(PWR)に適用し、1年間にわたるオフライン及びオンライン監視した結果、従来の監視システムや運転員が気づかないようないくつかの微小な異常事象を検知することができた。さらに、ニューラルネットワークを用いた感度解析を行い、ニューラルネットワークが適切にプラントをモデル化できていることが証明された。

最後に、フィードバック結合を持つリカレントネットワークを採用することにより、適応学習を行うことなく原子炉の動特性をモデル化できることが、PWRプラントシミュレータへの適用から明らかになった。したがって、実際の原子炉異常監視には、適応学習付リカレントネットワークを採用することが最適であるとの結論が得られた。

A Study of Reactor Monitoring Method with Neural Network

Kunihiko NABESHIMA

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

(Received October 19, 2000)

Abstract

The purpose of this study is to investigate the methodology of Nuclear Power Plant (NPP) monitoring with neural networks, which create the plant models by the learning of the past normal operation patterns. The concept of this method is to detect the symptom of small anomalies by monitoring the deviations between the process signals measured from an actual plant and corresponding output signals from the neural network model, which might not be equal if the abnormal operational patterns are presented to the input of the neural network. Auto-associative network, which has same output as inputs, can detect all kind of anomaly condition by using normal operation data only.

The monitoring tests of the feedforward neural network with adaptive learning were performed using the PWR plant simulator by which many kinds of anomaly conditions can be easily simulated. The adaptively trained feedforward network could follow the actual plant dynamics and the changes of plant condition, and then find most of the anomalies much earlier than the conventional alarm system during steady state and transient operations.

Then the off-line and on-line test results during one year operation at the actual NPP (PWR) showed that the neural network could detect several small anomalies which the operators or the conventional alarm system didn't noticed. Furthermore, the sensitivity analysis suggests that the plant models by neural networks are appropriate.

Finally, the simulation results show that the recurrent neural network with feedback connections could successfully model the slow behavior of the reactor dynamics without adaptive learning. Therefore, the recurrent neural network with adaptive learning will be the best choice for the actual reactor monitoring system.

Keywords: Neural Network, Reactor Monitoring, Recurrent Network, Anomaly Detection, Adaptive Learning, Sensitivity Analysis

目 次

第1章 序論	1
第2章 ニューラルネットワークによる原子力プラントのモデル化	3
2.1 原子炉異常監視技術の目的	3
2.2 従来の異常監視技術	3
2.3 ニューラルネットワークによるモデルベース型異常監視手法	4
2.4 ニューラルネットワーク研究の歴史	5
2.5 ニューロンの動作モデル	6
2.6 ネットワーク構造	7
2.6.1 オートアソシアティブネットワーク	7
2.6.2 適応学習付フィードフォワード型ニューラルネットワーク	8
2.6.3 リカレントネットワーク	8
2.7 学習アルゴリズム	9
2.7.1 誤差逆伝播（バックプロパゲーション）アルゴリズム	9
2.7.2 適応学習アルゴリズム	10
2.7.3 忘却項を持つ学習アルゴリズム	11
2.7.4 リカレントネットワークの学習アルゴリズム	12
2.8 入出力データの規格化	13
2.9 ネットワーク初期値の設定	14
2.10 まとめ	14
第3章 適応学習付フィードフォワード型ニューラルネットワークによる異常検知	
手法の検証1 —PWRプラントシミュレータへの適用—	18
3.1 PWRプラントシミュレータの概要	18
3.1.1 システム構成	18
3.1.2 シミュレータで取り扱われるプラントモデル	19
3.2 ニューラルネットワークによる原子炉のモデル化	20
3.2.1 プラント監視信号の選択	20
3.2.2 換算係数の導出	21
3.2.3 初期学習	22
3.2.4 異常判定のしきい値	22
3.3 100%定常出力運転時の異常検知結果	23
3.3.1 初期学習結果	23
3.3.2 主給水部分喪失	23

3. 3. 3	大気放出弁の漏洩	24
3. 3. 4	一次冷却材部分喪失（一次冷却材ポンプ1台軸固着）	25
3. 3. 5	体積制御タンク低水位誤検知	25
3. 4	過渡運転時の異常検知結果	26
3. 4. 1	初期学習	26
3. 4. 2	過渡運転時データの学習効果	27
3. 5	適応学習の効果	27
3. 6	まとめ	28
第4章	適応学習付フィードフォワード型ニューラルネットワークによる異常検知	
	手法の検証2 一実プラントへの適用—	59
4. 1	Borssele 炉の概要	59
4. 2	Borssele 炉のモデル化	59
4. 3	リアルタイムプラント監視システムの構築	60
4. 4	初期学習	61
4. 5	初期値の設定	62
4. 6	隠れ層のユニット数	62
4. 7	学習パラメータの設定	63
4. 8	しきい値の設定	63
4. 9	適応学習の効果	64
4. 10	ニューラルネットワークによる監視結果	64
4. 10. 1	出力上昇運転時(B19170A2)の監視結果	64
4. 10. 2	同位相リンシング運転時(B19178A)の監視結果	65
4. 10. 3	逆位相リンシング運転時(B19222A)の監視結果	65
4. 10. 4	炉停止運転時(B19268N1)の監視結果	65
4. 10. 5	起動運転時(B19270A)の監視結果	66
4. 10. 6	ストレッチアウト運転時(B19393S1)の監視結果	66
4. 10. 7	最終炉停止時(B19404A)の監視結果	67
4. 11	まとめ	67
第5章	感度解析によるネットワーク内部の究明	95
5. 1	感度解析	95
5. 2	PWRシミュレーションデータによる感度解析結果	96
5. 3	実炉データによる感度解析結果	97
5. 4	まとめ	98

第6章 リカレントニューラルネットワークによる異常検知手法の検証	
—PWRプラントシミュレータへの適用—	102
6.1 ニューラルネットワークによる原子炉のモデル化	102
6.2 適応学習付フィードフォワード型ネットワーク	103
6.3 リカレントネットワーク	103
6.4 初期学習	104
6.5 定常及び過渡出力運転時の解析結果	104
6.5.1 出力減少運転時の一次冷却材小破断	104
6.5.2 復水器循環水部分喪失	105
6.5.3 大気放出弁の漏洩	105
6.6 まとめ	106
第7章 結論	111
7.1 適応学習付フィードフォワード型ニューラルネットワークによる異常検知 (PWRプラントシミュレータへの適用)	111
7.2 適応学習付フィードフォワード型ニューラルネットワークによる異常検知 (実炉への適用)	112
7.3 感度解析	112
7.4 リカレントネットワークによる異常検知 (PWRプラントシミュレータへの適用)	113
7.5 高温ガス炉への応用	114
7.6 今後の課題	114
謝辞	116
参考文献	117

Contents

1 . Introduction	1
2 . Modeling of Nuclear Power Plant with Neural Network	3
2 . 1 Purpose of Reactor Monitoring Methods	3
2 . 2 Conventional Monitoring Methods	3
2 . 3 Model-Based Monitoring Methods with Neural Network	4
2 . 4 History of Neural Network Research	5
2 . 5 Dynamic Model of Neuron	6
2 . 6 Network Structure	7
2 . 6 . 1 Auto-Associative Network	7
2 . 6 . 2 Feed-Forward Neural Network with Adaptive Learning	8
2 . 6 . 3 Recurrent Network	8
2 . 7 Learning Algorithm	9
2 . 7 . 1 Back-Propagation Algorithm	9
2 . 7 . 2 Adaptive Learning Algorithm	10
2 . 7 . 3 Learning Algorithm with Forgetting Factor	11
2 . 7 . 4 Learning Algorithm for Recurrent Network	12
2 . 8 Input and Output Data Normalization	13
2 . 9 Initial Setting of Network Parameter	14
2 . 10 Summary	14
3 . Results of Anomaly Detection by Feed-Forward Neural Network with Adaptive Learning —Application to PWR Plant Simulator—	18
3 . 1 Outline of PWR Plant Simulator	18
3 . 1 . 1 System Construction	18
3 . 1 . 2 Plant Model in Simulator	19
3 . 2 Reactor Modeling by Neural Network	20
3 . 2 . 1 Signal Selection for Plant Monitoring	20
3 . 2 . 2 Calculation of Conversion Factor	21
3 . 2 . 3 Initial Learning	22
3 . 2 . 4 Fault Severity Level	22
3 . 3 Results of Anomaly Detection during 100% Steady State Operation	23
3 . 3 . 1 Results of Initial Learning	23
3 . 3 . 2 Partial Loss of Feedwater	23

3. 3. 3	Leakage of Atmospheric Steam Dump Valve	24
3. 3. 4	Partial Loss of Reactor Coolant System Flow	25
3. 3. 5	Volume Control Tank Level Control Fails Low	25
3. 4	Results of Anomaly Detection during Transient Operation	26
3. 4. 1	Results of Initial Learning	26
3. 4. 2	Effect of Transient Operational Data Learning	27
3. 5	Effect of Adaptive Learning	27
3. 6	Summary	28
4.	Results of Anomaly Detection by Feed-Forward Neural Network with Adaptive Learning —Application to Real Plant—	59
4. 1	Outline of Borssele Reactor	59
4. 2	Plant Modeling of Borssele Reactor	59
4. 3	Construction of Real-Time Plant Monitoring System	60
4. 4	Initial Learning	61
4. 5	Initial Parameter Setting	62
4. 6	Number of Units at Hidden Layer	62
4. 7	Learning Parameter Setting	63
4. 8	Fault Severity Level Setting	63
4. 9	Effect of Adaptive Learning	64
4. 10	Monitoring Results by Neural Network	64
4. 10. 1	Monitoring Result during Power Increase (B19170A2)	64
4. 10. 2	Monitoring Result during Same-Phase Rinsing (B19178A)	65
4. 10. 3	Monitoring Result during Reverse-Phase Rinsing (B19222A)	65
4. 10. 4	Monitoring Result during Shutdown Operation (B19268N1)	65
4. 10. 5	Monitoring Result during Start-Up Operation (B19270A)	66
4. 10. 6	Monitoring Result during Stretch-Out Operation (B19393S1)	66
4. 10. 7	Monitoring Result during Last Shutdown (B19404A)	67
4. 11	Summary	67
5.	Study of Inner Construction of Network by Sensitivity Analysis	95
5. 1	Sensitivity Analysis	95
5. 2	Results of Sensitivity Analysis using PWR Simulation Data	96
5. 3	Results of Sensitivity Analysis using Real Plant Data	97
5. 4	Summary	98

6 . Results of Anomaly Detection by Recurrent Neural Network	
—Application to PWR Plant Simulator—	102
6 . 1 Reactor Modeling by Neural Network	102
6 . 2 Feed-Forward Neural Network with Adaptive Learning	103
6 . 3 Recurrent Network	103
6 . 4 Initial Learning	104
6 . 5 Results of Analysis During Steady-State and Transient Operation	104
6 . 5 . 1 Small Reactor Coolant System Leak During Power Decrease	104
6 . 5 . 2 Partial Loss of Circulation Water	105
6 . 5 . 3 Leakage of Atmospheric Steam Dump Valve	105
6 . 6 Summary	106
7 . Conclusion	111
7 . 1 Anomaly Detection by Feed-Forward Neural Network with Adaptive Learning (Application to PWR Plant Simulator)	111
7 . 2 Anomaly Detection by Feed-Forward Neural Network with Adaptive Learning (Application to Real Plant)	112
7 . 3 Sensitivity Analysis	112
7 . 4 Anomaly Detection by Recurrent Network (Application to PWR Plant Simulator)	113
7 . 5 Application to High Temperature Gas Cooling Reactor	114
7 . 6 Future Work	114
Acknowledgments	116
References	117

表リスト

表3-1	Surry-1 原子炉の主要プラントパラメータ
表3-2	シミュレータのマルファンクションリスト
表3-3	PWR シミュレータプロセス信号表
表3-4	パネルからのアナログ出力信号の換算係数
表3-5	定常運転学習データ
表3-6	定常運転データ学習後の異常判定しきい値
表3-7	100%定常運転時の異常事象検知時間（定常運転データ学習）
表3-8	過渡運転学習データ
表3-9	過渡運転データ学習後の異常判定しきい値
表3-10	中間層の数
表3-11	100%定常運転時の異常事象検知時間（過渡運転データ学習）
表3-12	出力減少運転時の異常事象検知時間
表4-1	Borssele 炉の主要プラントパラメータ
表4-2	プラント信号リスト（第19期燃料サイクル初期）
表4-3	プラント信号リスト（第19期燃料サイクル中期）
表4-4	第19期PWR運転データ一覧
表4-5	3つのネットワークによる異常検知結果
表4-6	学習パラメータによる学習収束度
表4-7	初期学習後のネットワークのしきい値
表6-1	ネットワーク学習データ
表6-2	初期学習後のリカレントネットワークのしきい値
表6-3	異常事象の検知時間

図リスト

- 図 2 - 1 神経細胞のモデル
- 図 2 - 2 ニューラルネットワークの構造
- 図 2 - 3 ネットワーク内部のユニット（ニューロン）の結合
- 図 2 - 4 学習アルゴリズム
- 図 2 - 5 適応学習データと学習回数
- 図 2 - 6 リカレントネットワークモデル
- 図 3 - 1 シミュレータ構成図
- 図 3 - 2 PWR プラントモデル図（ミミックパネル）
- 図 3 - 3 オートアソシアティブネットワークモデル
- 図 3 - 4 (a) 初期学習結果 (1)
- 図 3 - 4 (b) 初期学習結果 (2)
- 図 3 - 5 (a) 主給水部分喪失時の応答 (1)
- 図 3 - 5 (b) 主給水部分喪失時の応答 (2)
- 図 3 - 6 (a) 主給水部分喪失時の応答 (0-20 秒)
- 図 3 - 6 (b) 主給水部分喪失時の応答 (0-20 秒)
- 図 3 - 7 (a) 大気放出弁の漏洩時の応答 (1)
- 図 3 - 7 (b) 大気放出弁の漏洩時の応答 (2)
- 図 3 - 8 (a) 大気放出弁の漏洩時の応答 (0-20 秒)
- 図 3 - 8 (b) 大気放出弁の漏洩時の応答 (0-20 秒)
- 図 3 - 9 (a) 一次冷却材部分喪失時の応答 (1)
- 図 3 - 9 (b) 一次冷却材部分喪失時の応答 (2)
- 図 3 - 10 (a) 一次冷却材部分喪失時の応答 (0-20 秒)
- 図 3 - 10 (b) 一次冷却水部分喪失時の応答 (0-20 秒)
- 図 3 - 11 (a) 体積制御タンク低水位誤検知時の応答 (1)
- 図 3 - 11 (b) 体積制御タンク低水位誤検知時の応答 (2)
- 図 3 - 12 (a) 体積制御タンク低水位誤検知時の応答 (0-40 秒)
- 図 3 - 12 (b) 体積制御タンク低水位誤検知時の応答 (0-40 秒)
- 図 3 - 13 過渡運転時の異常検知結果（体積制御タンク低水位誤検知）
- 図 3 - 14 過渡運転時の適応学習効果（体積制御タンク低水位誤検知）
- 図 4 - 1 Borssele 炉のプラント概略図と監視信号
- 図 4 - 2 オートアソシアティブニューラルネットワークモデル
- 図 4 - 3 監視システム構成図
- 図 4 - 4 オンライン監視画面
- 図 4 - 5 (a) 初期学習結果

- 図 4-5 (b) 初期学習結果 (続き)
- 図 4-6 中間層のユニット数による初期学習の収束誤差
- 図 4-7 ネットワークの学習誤差の推移
- 図 4-8 (a) 出力上昇運転時(B19170A2)の監視結果
- 図 4-8 (b) 出力上昇運転時(B19170A2)の監視結果 (続き)
- 図 4-9 (a) 同位相リンスング運転時(B19178A)の監視結果
- 図 4-9 (b) 同位相リンスング運転時(B19178A)の監視結果 (続き)
- 図 4-10 (a) 逆位相リンスング運転時(B19222A)の監視結果
- 図 4-10 (b) 逆位相リンスング運転時(B19222A)の監視結果 (続き)
- 図 4-11 (a) 炉停止運転時(B19268N1)の監視結果
- 図 4-11 (b) 炉停止運転時(B19268N1)の監視結果 (続き)
- 図 4-12 (a) 起動運転時(B19270A)の監視結果
- 図 4-12 (b) 起動運転時(B19270A)の監視結果 (続き)
- 図 4-13 (a) ストレッチアウト運転時(B19393S1)の監視結果
- 図 4-13 (b) ストレッチアウト運転時(B19393S1)の監視結果 (続き)
- 図 4-14 (a) 最終炉停止時(B19404A)の監視結果
- 図 4-14 (b) 最終炉停止時(B19404A)の監視結果 (続き)
- 図 4-15 最終炉停止時(リンスング部拡大)の監視結果
- 図 5-1 ネットワーク出力信号に対する入力信号の寄与率
(シミュレータ : 100%定常運転データ)
- 図 5-2 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 全学習データ)
- 図 5-3 蒸気流量初期学習データ (実炉)
- 図 5-4 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 100%定常運転データ)
- 図 5-5 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 80%定常運転データ)
- 図 5-6 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 全学習データ; 忘却付)
- 図 6-1 PWR プラントシミュレータの概略図
- 図 6-2 リカレントネットワークモデル図
- 図 6-3 一次冷却材小破断時の異常検知結果
- 図 6-4 復水器循環水部分喪失時の異常検知結果
- 図 6-5 大気放出弁の漏洩時の異常検知結果

This is a blank page.

第1章 序論

原子力プラントの運転状態をオンラインで監視して、異常の兆候を的確に検知し、その原因を同定する診断技術の研究は、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、現在原子炉に設置されているプラント監視システムのほとんどは、監視する各種信号があらかじめ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。この許容範囲は、低出力から高出力運転時までをカバーするため、かなり広く設定されており、ゆっくり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。逆に、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許容範囲を越えてアラームが鳴る場合も起こりうる。したがって、従来の警報システムが作動する以前の非常に微少な異常兆候を早期に検知し、運転員に告知することは、原子炉の安全性、経済性の点から非常に重要である。

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さまざまな研究が行われてきた。診断関連の技術は、1980年初頭までは信号ゆらぎ成分の統計解析法、いわゆる炉雑音解析法がその中心であったが、1980年代中期になるとエキスパートシステム、人工知能などの応用の試みが始まり、さらにニューラルネットワーク、ファジイ理論、カオス理論、ウェーブレット解析といった新しい技術の導入が急速に進んで来た¹⁾。また、原子力分野における異常診断に際しては、特に高い能力と信頼性が要求されることから、複数の技術の相補的利用を重視した多重手法統合方式の研究が精力的に進められつつある。

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な手法であるが、原子炉出力変動時には使用できない上、異常であるかどうかを判定する監視しきい値の設定が難しいという欠点がある。エキスパートシステムを利用したルールベース型診断は、ルール記述の曖昧さと膨大なルール数の作成という欠点から、プラント全体への適用は困難である。一方、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モデルベース型診断は、監視システムを構築する上で非常に有効な方法である。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が、原子炉は非常に複雑でかつ非線形なシステムであるため、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精密な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精度を達成することは難しく、ある一部分のモデル化に止まっている。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。

そこで本研究では、ニューラルネットワークに過去の正常な運転データを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。

主要なプラント変数の運転データを入力信号とし、それらの信号をそのまま出力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採用する。正常な学習データのみ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は、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）が測定値（入力信号）と一致する。しかし、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には、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、原子炉プラント内の微少な異常兆候を検知することが可能になる。また、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、学習が終了した後の推定にはほとんど時間を要さない。そこでオフラインで初期学習を行った後、オンラインで異常診断を行えば、実時間での利用も十分可能である。

本論文では、加圧水型原子力プラント（以下、PWRプラントと呼ぶ）で様々な異常が発生した場合に、2種類の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た。さらに、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切に行われているかどうかを検証した。

第2章 ニューラルネットワークによる原子力プラントのモデル化

2.1 原子炉異常監視技術の目的

原子炉出力の大型化や、燃料の燃焼効率を上げるための燃料装荷パターンの最適化、燃料の最高温度を下げ安全性を向上させる燃料径の小型化など、近年進められている原子炉の改良は、逆に炉内動特性の局所的な不安定性を増大させる危険性を指摘されつつある。また、国外においては、経済性を追求した運転条件のために、沸騰水型原子力プラント（以下、BWRプラントと呼ぶ）の出力上昇運転時の不安定性振動現象も確認されている。このような異常事象の際に、アラームが鳴って原子炉がスクラムするまで、運転員が全く異常に気づかないケースが問題となる。

原子炉は巨大なプラントであり、いろいろなコンポーネントだけでなく各種制御系も複雑に絡み合っているため、原子炉に異常事象が発生しても異常が小さい場合には、各種制御系が動作することによって、異常により引き起こされた現象が相殺され、さらに大きな事故につながるまで気づかない危険性も出てくる。このためには、原子炉の運転中にもっとも重要だと思われるプラントパラメータを選択し、常時自動的に監視することが、運転員の負担軽減に大きく役立つと考えられる。

以上のように、プラント変数を常時監視している警報システムや運転員も気が付かないような非常に小さな異常兆候を早期に検知し、運転員に知らせることによって、事故に対処するための時間的余裕を与えることが、本監視システムの目的である。したがって、プラント外部に接続された本監視システムは、運転員の負担軽減目的としたサポートを行うために開発された。

2.2 従来の異常監視技術

原子力プラントの運転制御に用いる中性子束信号や圧力・流量信号は、流体の流れや気泡のランダムな発生とそれを制御する制御系の動作により、定常状態でも、法則性のあるゆらぎ信号として観測される。異常の発生によりこのゆらぎ信号のパターンは微妙に変化するが、これを統計的に識別し異常診断に利用することが、いわゆる炉雑音解析法である。この診断技術は1980年代初頭までは代表的なものであり、その応用例として、原子炉から観測される中性子束や温度・流量のゆらぎ信号の周波数スペクトル密度や、各種の統計量（平均、分散、歪み度、平坦度など）を利用した診断技術が挙げられる²⁾。これらの統計量は、プラントの異常により敏感に変化することと、異常原因に依存して異なるパターンの変化をすることから、異常兆候を早期にとらえて原因を推定する手段として利用されている。この診断技術は、定常運転時のオンライン異常検知に非常に有効な手法であるが、

原子炉出力変動時での適用が難しいという欠点がある。さらに、異常の誤警報確率及び見逃し確率から上下限の監視しきい値を定める際には十分な注意が必要となる。

ルールベース型診断は、通常「If LHS Then RHS」の形式で表現した診断ルールを知識ベースに多数記録し、推論機構がこれらのルールと作業メモリーに記録されたデータと照合し、診断を実行する。この診断では、RHS に定義した異常原因により発生すると想定されるシステム状態を有限個の条件に組み合わせて LHS に定義する。原子力プラントに適用する場合、プラントの運転手順書などに記載されている異常時処理手順等の記載項目、あるいはエキスパートシステムの有する診断知識をルール形式で断片的に集積すれば、診断が可能になるということで、多くの研究がなされてきた。しかし、どのように LHS を定義すればルールが完全であるかということを一般的に決めることはできない。したがって、ルールの結論には、曖昧さは避けられない。また、プラントの異常診断のように物理現象を対象とする場合、連続量を論理値へ変換する際の曖昧さを考慮する必要がある。しかも、原子炉のような巨大で複雑なシステムをルールだけで記述することは不可能に近い。このように、データ・ルールの曖昧さ、ルールベースの完全性への保証に対しては、有効な方法が見出せていないため、実問題への適応に至らないケースが多い。

2. 3 ニューラルネットワークによるモデルベース型異常監視手法

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モデルベース診断手法は、監視システムを構築する上で非常に有効な方法である。ノルウェーのハルデンプロジェクトで開発された、蒸気発生器の熱交換モデルをベースとした異常診断システムが、このパイオニア的研究として挙げられる³⁾。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ため、低出力から定格出力までの広範囲にわたりかつシステム全体の精密な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精度を達成することは難しく、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。そこで本研究では、原子炉のモデル化にニューラルネットワークを利用する⁴⁾。この他にも、原子炉の異常同定⁵⁾や沸騰検知^{6),7)}にニューラルネットワークを用いた例もいくつか見られる。

今回用いた手法は、ニューラルネットワークを対象システムのモデル化に用いたモデルベース状態監視と考えるとよい。対象システムと並列に入力を与え、システムと同様な応答をするようにあらかじめニューラルネットワークを学習させておく。その後、ニューラルネットワークの予測とシステムの実際の応答とを比較し、両者の間に大きな相違が生じればシステムに何らかの変化（異常）が生じたと判断する。入出力が明確に区別されたシステムでは、実際の機器と同様の入力を与えて出力を比較する方法が用いられるが、ここで

は、主要パラメータ一式を全て入力し、同じパラメータの自己連想や将来予測をさせて比較する方法を試みる。この入出力が同じオートアソシアティブネットワークを用いる手法は、想定外事象を含めた、正常運転時以外の全てのプラント状態を検知できるという利点がある。特に、原子力プラントでは実炉からの異常事象がほとんど得られないことから、この手法は有効である。

ニューラルネットワークをシステム・モデリングに応用することの利点は、システムの数理モデルが不明であっても入出力さえ測定できればモデル化が可能で、これは数理モデルが知られていてもモデル・パラメータが不明であったり、未知のモデル化誤差がある場合にも同様である。また、実際の運用を開始した後も学習を継続すること（適応学習）によって、対象システムの緩やかな特性変化にモデルを追従させることができる。

2. 4 ニューラルネットワーク研究の歴史

ニューラルネットワークの研究は、生物の情報処理の大部分を占める学習機能を、数理的な面から捉えようとするものである。その理論的な研究は、1960年代初期にRosenblattによって提案されたパーセプトロン(Perceptron)に始まり、その後、いろいろな形で学習アルゴリズムの収束定理が証明された。しかし、こうした学習機械の理論の本格的な応用は、1986年にRumelhartらによって提唱されたConnectionist Modelにより、スタートしたと言える⁸⁾。彼らが行った大規模な計算実験は、単純な計算能力しか持たない素子を大量に、かつ均質に結合させたネットワーク構造が、各素子間で局所的に情報をやり取りすることによって行われる「学習」を通して外界の情報を獲得し、それを凡化し、現実問題に有効に働くことを認識させた。特に、多層神経回路網(Multi Layer Perceptron)における誤差逆伝播学習法(Error Back-Propagation Learning)は、こうした学習機械の潜在能力の高さを一般に知らしめるとともに、その簡便性から様々な分野での応用を促した。

しかし一方で、学習の結果として得られるネットワークの内部構造は、ブラックボックス的な不明瞭さを感じさせ、工学的には忌避する向きもあったため、80年代終わりからはニューラルネットワークによる非線形関数近似という問題の理論的な研究が主流になった⁹⁾。まず、中間層の素子数が十分に多ければ、三層ネットワークは任意の関数を十分な精度で近似できることが様々な観点から証明された。さらに素子数と精度の定量的な関係が議論され、目的関数のクラスを限ると三層ネットワークの平均二乗誤差の上限は、入力次元に陽には依存せず、中間素子数の逆数で減少することが示された。

また、こうした多層神経回路網の近似能力の解析を背景に、現実問題にニューラルネットワークを適用する場合、自由に更新できるパラメータの数をどれくらいにするかということと、どれくらいの例題を集めてネットワークに提示すれば良いかということも、重要な問題として議論されてきた。たとえば、中間層の素子数を増やして回路を大きくすれば、

ニューラルネットワークの表現力は豊かになり、与えられた例題に対しては正解を出しやすくなる。しかし、学習に要する時間は長くなり、また例題以外の新しい入力に対しては、非常に大きな間違いを犯してしまう可能性が高くなる。逆に素子数が不十分であれば、例題すら満足に表現できないことになる。このように、ニューラルネットワークの大きさは、ネットワークの汎化能力、学習時間と密接に関わってくるため、適切なネットワークの大きさを何らかの方法で求めることは、ニューラルネットワークの能力を十分に発揮させる上で重要なことである。これを解決する一つの方法として、ニューラルネットワークの中間層の素子数を可変にするアルゴリズムが多く研究者によって提案されているが、こうしたアプローチは与えられた問題ごとに恣意的に行わなくてはならない場合が多い。

2. 5 ニューロンの動作モデル

元来、生物の脳の神経細胞は、図 2-1 (a) のような比較的単純な結合状態を有している。したがって、一般的な神経細胞のモデルは多入力 1 出力の素子とみなすことができ、他の細胞の出力が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を超えた場合に細胞が興奮して電流を流し、そうでない場合には何も出力しない。

人工ニューラルネットワークは、このような神経細胞の働きを図 2-1 (b) のように単純化した工学的モデルで表したものである。まず、図中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。階層型ニューラルネットワークの 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に重みをかけたものの総和として表わされる。

$$I_j^k = \sum_i W_{i,j}^{k-1,k} \cdot O_i^{k-1} \quad (2-1)$$

さらに、この入力 I_j^k は、入出力関数 $f(I)$ によって出力に変換される。この入出力関数 f に非線形関数を用いることにより、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、本来、生物の神経系は 2 値モデルであり、ユニット内のしきい値を θ とすると、非線形関数は単位段階関数

$$f(x) = \begin{cases} 1 & (x \geq \theta) \\ 0 & (x < \theta) \end{cases} \quad (2-2)$$

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原子力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等を考慮して、入出力関数には下式のようなシ

ゲモイド関数を採用する。

$$f(x) = \frac{1}{1 + e^{-(x-\theta)}} \quad (2-3)$$

したがって出力信号は、

$$O_j^k = f(I_j^k) = \frac{1}{1 + e^{-(I_j^k - \theta_j^k)}} \quad (2-4)$$

のように表される。

2. 6 ネットワーク構造

ニューラルネットワークの構造は、図2-2のように大きく分けて階層型と相互結合型の2種類に分類することができる。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ことがほとんどである。最もよく用いられている階層型の例は、学習則に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ものである。

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区別されていない。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、画像や文字認識等の分野で適用されている。

2. 6. 1 オートアソシアティブネットワーク

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は、入力層と出力層の信号が全く同じオートアソシアティブ（自己連想型）ネットワークである¹⁰⁾。したがって、出力層の各ユニットの値は、対応する入力層の各ユニットの信号とまったく同じ値、あるいは同じ信号の1タイムステップ後の予測値となる。オートアソシアティブネットワークは、

基本的に多（ n ）入力1出力のネットワークを n 個並列に並べたものと同じ性能を有しているが、1つのネットワークですむため、高速性を要求されるリアルタイム計算に適している。ただし、このオートアソシアティブネットワークは、入力と出力が全く同じであるため、同一信号どうしの結合が強くなりすぎて、結果的にモデル化がうまくいかない危険性も指摘されている。この点については、第5章の感度解析の項目で述べているように、自身の信号寄与度は20%弱にすぎず、他の信号による適切なモデル化が行われていることが示されている。

2. 6. 2 適応学習付フィードフォワード型ニューラルネットワーク

フィードフォワード型ニューラルネットワークは、入力層、出力層及び1つ以上の隠れ層からなる階層構造で、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、フィードバック結合はない。一般的に隠れ層が多くなるほど複雑なモデル化が可能になると考えられているが、層の数が増すごとに学習の収束が悪くなり、計算時間が飛躍的に増大する。今回の適用例では3層および4層構造のネットワークで学習を試みたが、2つのネットワークの学習結果および監視性能に大きな差異は見られなかった。そこで、異常検知のリアルタイム性を確保するため、ここではより単純な3層構造ネットワークを採用した。

通常、フィードフォワード型ニューラルネットワークは、その単純な構造のため、時系列データの取り扱いや、複雑な動特性を有するシステムのモデル化には、あまり向いていないと言われている。したがって複雑なプラントのモデル化に利用する場合、その動特性をモデル化することが困難なため、後述の適応学習を用いて、対象となるプラント特性の変化に追従させる方法を考えた。これは、初期学習においてプラントの基本的なモデルを構築し、適応学習においてプラント動特性や緩やかな状態の変化にモデルを追従させるものである。

2. 6. 3 リカレントネットワーク

適応学習付フィードフォワード型ニューラルネットワークでは、随時新しいデータを学習していくため、非常にゆっくりと変化していく異常事象のパターンを学習し、その結果として、異常を見逃す危険性がある。そこで、フィードバック結合を持つリカレント型ニューラルネットワークを使用して、原子炉プラントの動特性をモデル化することにより、適応学習なしで、異常検知に適用できるかどうかを検証する。当然、実際の原子力プラントに適用する場合には、同一燃料サイクル内でシステム動特性も変化していくため、適応学習は不可欠であるが、その頻度を減らすことにより、緩やかな異常パターンを学習する危険性をかなり減少させることができると考えてよい。

リカレントネットワークの学習は誤差逆伝播学習を拡張した手法で行われるが、自由度が大きいので、適切な構造を効率的に探索することが要求される。もし、システム動特性の数理モデルが部分的にでもわかっているならば、その知識に基づいてモデル化する方が、全体をブラックボックスとして直接モデル化するより効果的である。

リカレントネットワークには、フィードバック結合の形態によって、いくつかの種類に分類される。代表的なものとしては、出力層の出力から中間層の入力へのフィードバック結合を持つ Jordan 型、中間層の出力から中間層の入力へのフィードバック結合を持つ Elman 型、等が挙げられる。ここでは、Jordan 型を採用した。

2.7 学習アルゴリズム

生物の神経系における学習は、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行われていると考えられる。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。

2.7.1 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、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する⁸⁾。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ためにこの名前が付けられている。

誤差逆伝播アルゴリズムでは、図2-3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 $W_{i,j}^{k-1,k}$ は、学習回数 t 回目において以下のようにして修正される。

$$W_{i,j}^{k-1,k}(t) = W_{i,j}^{k-1,k}(t-1) + \Delta W_{i,j}^{k-1,k}(t) \quad (2-5)$$

$$\Delta W_{i,j}^{k-1,k}(t) = \eta \cdot \delta_j^k \cdot O_i^{k-1} + \alpha \cdot \Delta W_{i,j}^{k-1,k}(t-1) \quad (2-6)$$

ここで、 η は標準誤差逆伝播法における学習率で、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 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、

$$\delta_j^M = (Y_j - O_j^M) \cdot f'(I_j^M) = O_j^M \cdot (1 - O_j^M) \cdot (Y_j - O_j^M) \quad (2-7)$$

その他の中間層においては、

$$\delta_j^k = f'(I_j^k) \cdot \sum_p W_{j,p}^{k,k+1} \cdot \delta_p^{k+1} = O_j^k \cdot (1 - O_j^k) \cdot \sum_p W_{j,p}^{k,k+1} \cdot \delta_p^{k+1} \quad (k = M - 1, \dots, 2) \quad (2-8)$$

となる。ここで、 δ_p^{k+1} は $k+1$ 層における誤差信号、 $W_{j,p}^{k,k+1}$ は k 層 j 番目と $k+1$ 層 p 番目のユニット間の結合の重みである。(2-7)式の Y_j は教師信号、 f' は入出力関数の微分であり、(2-4)式のようなシグモイド関数を用いているため最終的に(2-7)式のように簡単な形で表すことができる。また、(2-6)式の右辺第2項はモーメンタム項と呼ばれ、学習の振動を減らして学習速度を速め、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 はモーメンタム項の係数である。

一般的に、学習率及びモーメンタム項の係数は、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値の方が収束が速くなる、と言われている。そこで、学習率 η 及びモーメンタム項の係数 α を学習回数に応じて変更できるようにした。今回の計算では、学習回数が増えるとともに、 η 及び α の値が段階的に小さくなるように設定されている。

2. 7. 2 適応学習アルゴリズム

ニューラルネットワークは、過去の運転データの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できる。しかしながら、原子炉は燃料の燃焼や運転条件の変化に伴ってプラント特性が徐々に変化していくため、燃料初期と末期では、同じネットワークモデルを使用することができない。そこで図2-4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つの学習課程に分けて考えた。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。初期学習の際には、ランダムにデータを学習するモードと決め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はなく、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利用される。

初期学習後は、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ため、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。

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、プラントを正常とみなし、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）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。また、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2-5参照）。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。また学習の順序もランダムではなく、

$$X(t-i) ; ((i=0, j-1), j=1, N) \quad (2-9)$$

と固定されている。図2-5に示されている様に、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。なお、この際の学習率 (η) 及びモーメント項の係数 (α) は、初期学習時に比べて小さい値（実際例： $\eta=0.005, \alpha=0.005$ ）に設定され、ネットワークの重みとしきい値が徐々に更新されていく。

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適応学習を行わず、どの信号が異常であるかのメッセージを画面に出力して、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）の範囲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、ネットワークを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。このような二段階の判定によって、異常事象の検知にロバスト性を持たせている。

2. 7. 3 忘却項を持つ学習アルゴリズム

ユニット間の結合の重みに忘却を導入する学習アルゴリズムは、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¹¹⁾。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少しずつ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、(2-6)式に結合の重みの絶対値和の項（右辺第3項）を追加する。

$$\Delta W_{i,j}^{k-1,k}(t) = \eta \cdot \delta_j^k \cdot O_i^{k-1} + \alpha \cdot \Delta W_{i,j}^{k-1,k}(t-1) - \varepsilon \cdot \text{sign}(\Delta W_{i,j}^{k-1,k}(t-1)) \quad (2-10)$$

ここで、 ε は繰り返し毎の忘却量、 $\text{sign}(x)$ は下式のように定義される。

$$\text{sign}(x) = \begin{cases} 1, & ; x > 0 \\ 0, & ; x = 0 \\ -1, & ; x < 0 \end{cases} \quad (2-11)$$

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が形成されるため、各入出力変数の相関を調べる場合には有効である。しかしながら、学習の繰り返し毎に強制的に全ての重みを減衰させていくため、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、今回、この忘却項は感度解析の場合にのみ使用する。

2. 7. 4 リカレントネットワークの学習アルゴリズム

リカレントネットワークの学習は誤差逆伝播学習を拡張した手法で行われるが、自由度が大きいので、適切な構造を効率的に探索することが要求される。もし、システム動特性の数理モデルが部分的にでもわかっているならば、その知識に基づいてモデル化する方が、全体をブラックボックスとして直接モデル化するより効果的である。

今回使用するニューラルネットワークは3層構造をもつ階層型で、入力層 $X(t)$ と出力層 $Y(t)=X(t+1)$ のユニットが一対一に対応し、出力層から中間層へのフィードバック結合を持つ Jordan 型のリカレントネットワークである¹²⁾。図2-6にそのモデル図を示す。

時刻 t で、中間層の各ユニットに入力される重み付き総和 $u_i(t)$ は出力層からフィードバックされる時間遅れ $Y(t-\tau)$ としきい値 W_{ii} を考慮すると、

$$u_i(t) = \sum W_i \cdot X(t) + \sum W_f \cdot Y(t-\tau) - W_{ii} \quad (2-12)$$

と表される。この入力 $u_i(t)$ はシグモイド関数により出力 $u_o(t)$ に変換される。

$$u_o(t) = \frac{1}{1 + \exp(-u_i(t))} \quad (2-13)$$

ここで W_i は入力層-中間層間の重み、 W_f は出力層から中間層へのフィードバック結合部の重みである。また、出力層へ入力する重み付き総和 $u_v(t)$ は、

$$u_v(t) = \sum W_o \cdot u_o(t) - W_{to} \quad (2-14)$$

となる。ここで W_o は中間層-出力層間の結合の重み、 W_{to} は出力層のしきい値である。この入力 $u_v(t)$ はシグモイド関数により出力 $Y(t)$ に変換される。

$$Y(t) = \frac{1}{1 + \exp(-u_v(t))} \quad (2-15)$$

出力ユニットの τ 時刻前の信号も入力ユニットの一部として見なすと、学習には3層ニューラルネットワークの誤差逆伝播アルゴリズムを適用することができる¹³⁾。したがって、出力の誤差が最小になるように出力層の重みが修正式(2-16)、(2-17)に従って修正される。

$$W_o(t+1) = W_o(t) + \Delta W_o(t) + \alpha \times \Delta W_o(t-1) \quad (2-16)$$

$$\Delta W_o = \eta \delta Y(t) \quad (2-17)$$

ここで、 η は学習率、 α はモーメント項の係数で、学習の高速化をはかる変数である。 δ は誤差信号で、出力層の誤差信号を計算し中間層-出力層間の結合の重みを修正した後、中間層の誤差信号を計算し、入力層-中間層間およびフィードバック結合の重みを修正する。今回リカレントネットワークを適用した軽水炉の動特性は比較的速いため、フィードバック時の時間遅れ τ は、1タイムステップに相当する1秒に設定した。

2.8 入出力データの規格化

ニューラルネットワークを実際 X_i^{\max} 問題に適 X_i^{\min} 用する場合、入出力信号はその種類によって、値の大きさや学習例題中での変化の割合が大きく異なっている。したがって、各信号の影響を平等にするために、学習に用いる入出力データを規格化する必要がある。本計算では学習例題中の入力信号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。

$$X_i^{norm} = \frac{X_i^{original} - X_i^{\min}}{X_i^{\max} - X_i^{\min}} - 0.5 \quad (2-18)$$

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

$$Y_i^{norm} = \frac{Y_i^{original} - Y_i^{\min}}{Y_i^{\max} - Y_i^{\min}} \times 0.8 + 0.1 \quad (2-19)$$

ここで、 $X_i^{original}$ 及び $Y_i^{original}$ は物理単位の入力と出力、 X_i^{norm} 及び Y_i^{norm} は規格化された入力と出力である。一般的に学習データの規格化は、 $-1 \sim +1$ の間で行われていることが多く、かつゼロを中心に正と負に分布させる方が学習の収束が速いと言われている。また、ある入力信号の変動幅が、他の入力に比べて著しく大きい場合には、入力の対数値を規格化する方が良い。

なお、学習例題の中でほとんど変化がなく一定な値をとる信号は、ニューラルネットワークで学習することが難しく、逆に他の入出力信号の学習を妨げるおそれがあるため、なるべく除いた方が好ましい。

2. 9 ネットワーク初期値の設定

通常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、入出力信号の規格値に合わせて、それぞれ $-0.5 \sim 0.5$ 、 $-1.0 \sim 1.0$ 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。

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ある必要最小限な値を超えている場合には、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。

2. 10 まとめ

本章では、適応学習付フィードフォワード型とリカレントの2つをタイプのニューラルネットワークについて詳述した。次章以降に、これらのネットワークのPWRプラントシミュレータ(Surry-1モデル)及び実プラント(Borssele炉)への適用例を示している。プラントの動特性を考慮したモデル化という観点からは、リカレントネットワークのほうが優れているが、実際の原子力プラントに適用する場合にはプラント特性の緩やかな変化に追従するための適応学習も不可欠である。したがって、将来、実プラントへ導入する際には、適応学習付リカレントネットワークを採用する方が望ましい。

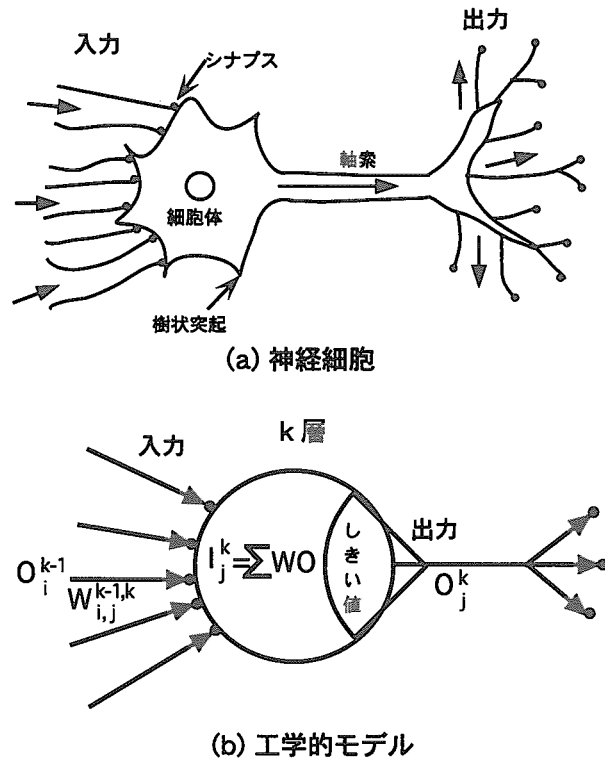


図2-1 神経細胞のモデル


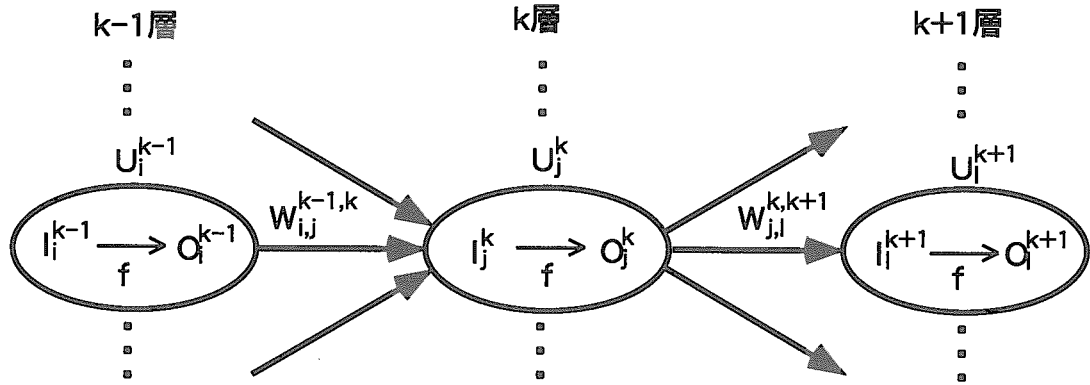


図2-2 ニューラルネットワークの構造



- U_j^k : k 層 j 番目のユニット(ニューロン)
- I_j^k : 入力の総和
- O_j^k : 出力
- $W_{i,j}^{k-1,k}$: $k-1$ 層 i 番目から k 層 j 番目のユニットへの結合の重み
- f : 入出力関数

図 2-3 ネットワーク内部のユニット (ニューロン) の結合

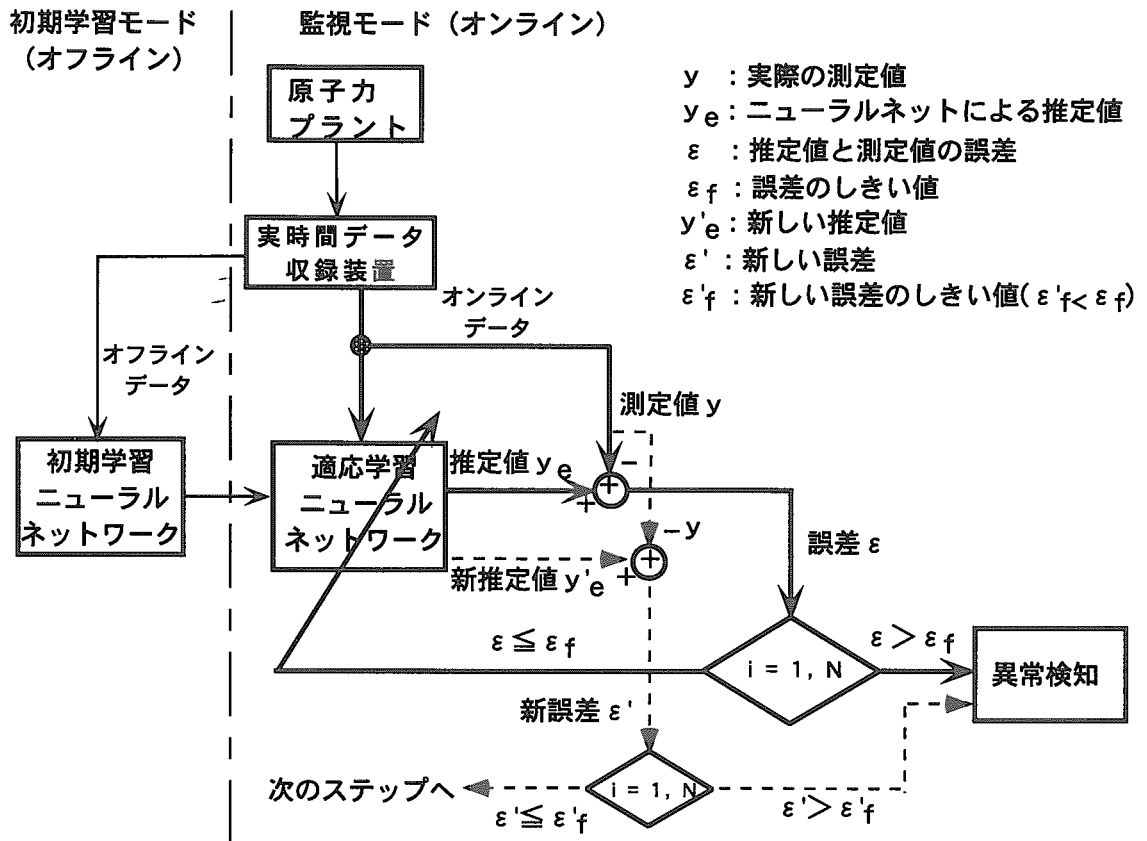


図 2-4 学習アルゴリズム




図 2-5 適応学習データと学習回数

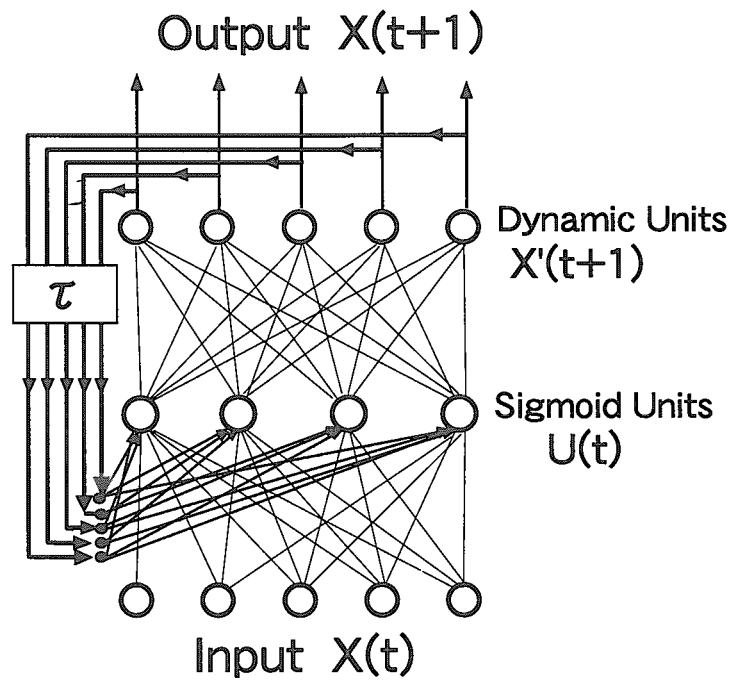


図 2-6 リカレントネットワークモデル

第3章 適応学習付フィードフォワード型ニューラルネットワーク

による異常検知手法の検証 1

—PWR プラントシミュレータへの適用—

本章では、いろいろな異常事象を容易に模擬できるPWRプラントシミュレータを使用して、適応学習付フィードフォワード型ニューラルネットワークの異常検知性能の検証を行う。ここで使用する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監視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。

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層フィードフォワード型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、原子力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で、微小な異常兆候を発見するものである^{14),15)}。

3. 1 PWRプラントシミュレータの概要

3. 1. 1 システム構成

本研究で使用したシミュレータは、アメリカのPWRプラント Surry-1（電気出力822MWe）を模擬したものであり、シミュレータ構成は、図3-1に示すようにモザイク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（図3-2）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。シミュレーション結果は、プリンター、ペンレコーダ、ディスプレイ上に表示できるが、シミュレータ自身はLAN(Local Area Network)に接続されていないため、これまで外部コンピュータへのデータ送信が不可能であった。今回、異常監視システムの検証のためにシミュレータの改造を行った結果、ミックパネル部及びペンレコーダに出力される計87チャンネルのプラントアナログ信号を取り出すことが可能になった。図3-1に示されるように、シミュレータから取り出されたアナログ信号は、PC上でデジタル値に変換され、LAN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及びオフライン監視に利用することができる。本章では、PWRプラントシミュレータによるオフライン解析結果を使用した場合の、ニューラルネットワークによるプラントのモデル化と異常検知性能の検証について記述する。

3. 1. 2 シミュレータで取り扱われるプラントモデル

Surry-1 は、電気出力 822 MW の PWR 型原子炉で、その冷却系は 3 ループから構成されている。Surry-1 原子力プラントの主要パラメータを表 3-1 に示す。

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抽出系、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、真空ブレーカー、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、サンプル水位、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
- ・ 抽出ライン圧力制御系

(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(アラーム)も発信される。

また、表3-2に示すように、本シミュレータでは、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ファンクションが49種類用意されている^{16),17)}。本研究では、微小な異常兆候の検知を目的としているため、その中でも比較的緩やかな異常事象数種類についてのシミュレーションを行い、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た。

3. 2 ニューラルネットワークによる原子炉のモデル化

3. 2. 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のモデル化及び監視を行う。この際、監視に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。シミュレータから毎秒送られてくる信号は、表3-3に示されているように、ミミックパネルからの79チャンネルの信号及びペシレコーダに出力される8チャンネルの信号である。シミュレータで模擬されているSurry-1原子力プラントの冷却系は、A、B、Cの3ループから成っている。しかし、図3-2のように、モザイク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、しかもシミュレータに用意されているマルファンクションも、ほとんどがBまたはCループに印可される。したがって、基本的にAループのプラント変数は常にBまたはCループの変数と同じ値になるため、監視信号として選択するプラント変数はB、Cループに限定した。また、低出力から100%出力までの正常な運転中、値が全く変化しないプラント変数については、従来の監視手法でも十分に異常を検知できるので、今回の監視信号からはなるべく除外した。

以上のことから、監視信号に用いるプラント変数として、まず炉心からは炉外中性子束

が、一次系からは一次冷却材流量と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。なお、図3-3に示されるように、中間層が8ユニットの場合のフィードフォワード型オートアソシアティブネットワークの出力信号は、同時刻の入力信号と全く値である。

ここで行うニューラルネットワークによるモデル化とは、正常運転データを学習して入力信号と出力信号の相関モデルを作成することに他ならない。したがって、オートアソシアティブネットワークのように、入力と出力の信号が全く同じである場合には、同一信号同士の相関、つまり自己相関が大きくなると、モデル化がうまくできていないことを意味する。したがって、ニューラルネットワークを異常診断に利用する前に、第6章で述べる感度解析を行い、ネットワークモデルの妥当性を検証しておく必要がある。

3.2.2 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、表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。

監視信号として使用可能な14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、加圧器圧力、加圧器水位の6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。表3-4に得られた換算係数を示す。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。

3. 2. 3 初期学習

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。一般的に初期学習のデータには、定常運転時と起動、停止時の正常な運転データをなるべく一様に使用することが望ましいと考えられる。今回用いたシミュレータには、初期状態として、燃料初期・中期・末期における100%、50%、20%定常出力運転時のデータが用意されており、今回の初期学習では、燃料初期の100%、50%、20%定常出力運転を用いた。しかし、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備わっていないため、初期学習に必要な過渡運転データとして、タービン操作弁によるタービン出力の変動幅及び一次系のボロン濃度を調整することにより、正常な出力減少運転データを作成した。

このように、初期学習において広範囲な学習データを必要とする大きな理由は、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は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は十分な性能を示すが、外挿は非常に不得意であることがわかっている。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も十分な注意を払う必要がある。

今回フィードフォワードネットワークの場合には、各データをランダムな順序で学習し、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。

3. 2. 4 異常判定のしきい値

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ため、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な課題の一つである。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%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。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は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、過渡運転時の変化が少ない割に定常出力時のゆらぎが大きいものが存在する

ためである。

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際の原子炉に適用した際に、経験的に得られた値であり、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発した（第5章参照）。しかし、係数を1.25倍にしても、以下の微小な異常兆候を100%検知できることから、異常を見逃す確率確率はゼロであると考えてよい。

3.3 100%定常出力運転時の異常検知結果

3.3.1 初期学習結果

初期学習には、本来シミュレータで用意されている3つの定常運転時のデータのみを使用した。表3-5に示されるように、燃料サイクル初期における20%、50%、100%出力の定常運転時データをそれぞれ100パターンずつ作成し、合計300パターンを初期学習データとしてニューラルネットワークに使用する。各パターンをランダムに1000回ずつ学習するのに要した時間は、Sparc20で約2分であった。

図3-4は、12個のプラント信号についての初期学習結果を示している。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ため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、定常状態のみを学習した場合の各信号の異常判定しきい値を表3-6に示す。この中で、一次冷却材流量信号は一定値でほとんど変化がないため、標準偏差の2倍の値の方が最大誤差よりも大きくなっている。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、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ことから鑑みて、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事に由来すると考えられる。

初期学習後、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、フィードフォワード型ネットワークによる異常検知を行った。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た異常事象は、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つのケースである。表3-7に従来の警報システムとの比較を、以下にそれぞれの場合の診断結果を示す。

3.3.2 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図3-5に示す。本監視システムは、漏れが発生してからわずか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、図3-6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。この時点での電気出力信号のみの偏差が非常に大きくなっていることから、センサー異常に対しても十分検知可能であることが明らかになった。

3.3.3 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。図3-7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、蒸気の平均温度も低下し、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て、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。

図3-8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ネットワーク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、やはりしきい値を超える。

3. 3. 4 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。図3-9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。図3-10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。

3. 3. 5 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生しつづ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。図3-11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（RWS T）に切り替わる。したがって、充填ラインには高濃度のボロンが流れ込み、一次冷却系を循環して炉内冷却材中のボロン濃度が徐々に増加していくため、中性子束も減少し、結果的に一次系の平均温度も下がる。そこで、この温度下降を抑え二次系出力を保持するために制御棒の引き抜きがなされ、中性子束はいったん増加するが、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。

図3-12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、中性子束信号によって原子炉プラントの異常を検知している。これはボロンが炉心に注入されて、中性子束が減少したことにより、プラント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、故障信号を直接監視することなしに、制御系も含めたプラント全体の挙動

の変化から異常事象を検知することも可能であることが明らかになった。

3. 4 過渡運転時の異常検知結果

前節では、定常運転時データのみを学習して100%定格出力運転時の異常事象検知を行ったが、ここでは、過渡運転時データも学習したネットワークを使用して、定常運転時及び過渡運転時の異常検知性能を評価する。

3. 4. 1 初期学習

過渡運転学習データには、シミュレータで本来用意されている定常運転時のデータ、100%及び50%出力状態からの出力減少運転データを使用する(表3-8参照)。まず、燃料サイクル初期における20%、50%、100%出力時の定常運転のデータをそれぞれ20パターンずつ作成した。次に、タービン操作弁によるタービン出力の変更と一次系のボロン濃度を変えることによって、100%定常運転時からタービン出力減少率が2%/minの割合で50%まで出力を下げた場合の運転データを800点、また50%定常運転時から2%/minの割合で25%まで出力を減少した運転データを350点作成した。以上の合計1210パターンが、初期学習データとしてニューラルネットワークに使用される。各パターンを600回ずつランダムに学習した結果得られた、各信号の異常判定しきい値を表3-9に示す。学習に各定常状態の間の運転データが加わっているため、定常状態のみを学習したネットワークに比べて、学習が速く収束し、かつ学習誤差も小さくなっていることがわかる。なお、一次冷却材流量信号は一定値でほとんど変化がないため、今回も標準偏差の2倍の値の方が最大誤差よりも大きくなっている。

学習時には、誤差逆伝播法を採用し、学習速度 η 及び α の値の最適化を行った結果、 η を1.8~1.6に α を1.7~1.3に段階的に小さくした場合に、もっとも誤差の二乗和が小さくなることがわかった¹⁸⁾。

また、中間層のユニット数を変化させた場合の学習誤差を比較した結果を表3-10に示す。この結果より、中間層のユニット数が14個以上では学習誤差に目立った差異は見られない。今回の解析はオフラインで行うために、計算時間の制約がないことから、この後の異常検知には、中間層に22個のユニットを持つ3層のネットワーク(12-22-12)を採用する。

以上、中間層のユニット数や学習開始時のネットワークの重み等の初期値を変化させることによって、学習収束後のネットワーク状態は大きく異なってくる。しかしながら、各ネットワークの学習誤差、異常検知性能に目立った差異は見られなかった。これは、学習誤差の最小値の近傍に、無数の極小値を持った平面があり、学習がその平面上に収束している限りは、プラントのモデル化に必要な精度が得られていると考えてよい。このように、

厳密な数式解が存在しないような場合には、条件を満足できる解が多数存在し、必ずしも最小値に到達する必要がないことを意味している。

3. 4. 2 過渡運転時データの学習効果

ここでは、主給水部分喪失、タービン制御弁フェイルオープン、大気放出弁の漏洩（100%）、体積制御タンク低水位誤検知の4つのケースについて、それぞれ定常運転時及び出力減少時における異常事象の検知を行った。なお、出力減少時における異常事象は原子炉出力が100%から80%になる10分後に生起される。表3-11及び表3-12は、定常運転時及び出力減少時において、それぞれの異常事象の発生から異常検知するまでに要する時間と検知された信号を示したものである。

表3-11から明らかなように、過渡運転データも学習させたネットワークは、定常運転データのみを学習させた場合とほとんど同じ検知性能を示している。表中4番目の異常は、体積制御タンクの制御系が故障し、水位がゼロであるという誤信号を発生させる事象であるため、異常発生と同時に警報が鳴るが、それ以外の異常事象については、常に従来の警報システムより早い段階で異常を検知している。図3-13に、体積制御タンク低水位誤検知の場合の中性子束及び給水圧力信号の時間的な挙動を示す。

表中2番目の「タービン制御弁フェイルオープン」は、ガバナのサーボ機構の故障によりタービン制御弁4個中1個が全開になる異常事象である。他のタービン制御弁はタービン負荷がガバナ制御モードでないために、不変であり、したがってタービン制御弁平均開度が約3.8%増加する。蒸気流量はタービン制御弁の急激な開動作で瞬時に増加し、蒸気発生器圧力は逆に減少の傾向をたどる。タービン発電機出力は、タービン制御弁のフェイルオープンで2秒間に1.7%増加するが、蒸気圧力の効果に伴いタービンへの流入蒸気量が減少するため、次第に低下して収束する。一次冷却材温度は、コールドレグが蒸気発生器での発生蒸気量の増大により、伝熱量が多くなり徐々に低下する。一方、タービン発電機出力の上昇に伴いバンクD制御棒が0.4%引き抜かれ、中性子束はステップ状に約2%増加する。原子炉出力もわずかに増加する。定常運転時のケースでは、4秒後にまず蒸気流量信号で、続いて5秒後に中性子束信号で異常が発見される。また、過渡運転時では、わずか2秒後にホットレグ温度と電気出力信号で異常が検知された。これは、出力減少時においてこのマルファンクションが逆に出力を上昇させるために、発見が早くなるものと考えられる。なお、この異常事象は微小な上に自動制御系が働いてシステムを安定な状態に導くため、従来の警報システムによるアラームは鳴らない。

3. 5 適応学習の効果

適応学習とは、原子炉のように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学習モードである。ここでは、シミュレーションデータを利用して、適応学習の有効性を検証する。前節のように初期学習データと同じ出力減少幅の過渡運転時に異常を発生させた場合には、原子炉の動特性は変化しないため、適応学習を使用しないネットワークでも、容易に異常の検知が可能である。しかし、初期学習データと異なる割合で出力を減少させた場合、適応学習なしではシステムの動特性の変化にネットワークを追従させることができなくなる。100%定常運転時からタービン出力減少率が3%/minの割合で出力を下げている時、体積制御タンク低水位誤検知の異常事象が発生する場合の蒸気圧力信号の検知結果を図3-14に示す。適応学習を行わない場合には、異常が発生する以前の200秒付近で既に測定値とネットワークによる推定値の誤差が大きくなり、異常判定のしきい値を越えている。これに対し、適応学習を行ったネットワークでは、モデルの変化に正確な追従しているだけでなく、異常事象の発生も的確に検知できている。このことから、フィードフォワード型ニューラルネットワークを原子力プラントの異常検知に利用する場合には、適応学習が不可欠であることが明らかになった。

3.6 まとめ

本章では、PWRシミュレータを用いて、定常運転時及び過渡運転時のシミュレーションデータを作成し、フィードフォワード型ネットワークによる異常検知を行った。定常運転データのみを学習したネットワークは、定常運転時に発生した異常事象を従来の監視システムよりもはるかに早い段階で検知することに成功した。また、過渡運転データも含めて学習したネットワークも、定常時及び過渡運転時に起こった異常事象を、同じように短い時間で検知することができた。

さらに、適応学習を採用することによって、本来動特性のモデル化が困難なフィードフォワード型ネットワークでもプラント特性の変化にネットワークモデルを追従させることが可能であることが証明され、しかも的確に異常を検知できることが明らかになった。

表3-1 Surry-1原子炉の主要プラントパラメータ

Electric Power Rating	822 MW
Total Core Heat Output	2441 MWt
Number of Fuel Assemblies	157
Active Core Height	3.66 m
Core Diameter	3.04 m
Coolant Inlet Temperature	283.9 °C
Coolant Outlet Temperature	318.7 °C
Core Coolant Flow Rate	45677 ton/hr
Total Volume of Reactor Coolant	253 m ³
Steam Temperature	268.9 °C
Feedwater Temperature	221.1 °C
Secondary Side Water Volume	47.81 m ³
Secondary Side Steam Volume	108.45 m ³

表3-2 シミュレータのマルファンクションリスト

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

表3-3 PWR シミュレータプロセス信号表

NO.	Signal	NO.	Signal
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. HEATER CONT. IND.	66	VOLTAGE REGULATOR BALANCE IND.
23	PRESSURIZER 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	

表3-4 パネルからのアナログ出力信号の換算係数

No	ch	Signal Y	Symbol	傾き A	切片 B
1	6	POWER RANGE-C IND. [-]	RXNCORE	1.1733E-1	8.2860E-3
2	70	FEEDWATER PRESS. [psi]	FWP210	7.8516E+1	8.0135E+2
3	71	PRIMARY WATER FLOW [lb/hr]	RCW111	6.0027E+6	5.9918E+7
4	72	HOT-LEG TEMP.(B) [°F]	RCT301(2)	2.2176E+1	4.2469E+2
5	73	HOT-LEG TEMP.(C) [°F]	RCT301(3)	2.2575E+1	4.2451E+2
6	74	FEEDWATER FLOW (B) [lb/hr]	FWW500(2)	2.5081E+5	2.5137E+6
7	75	FEEDWATER FLOW (C) [lb/hr]	FWW500(3)	2.4966E+5	2.5033E+6
8	76	STEAM PRESS.(B) [psi]	SGP030(2)	6.0118E+1	6.0047E+2
9	77	STEAM PRESS.(B) [psi]	SGP030(3)	6.0949E+1	6.1116E+2
10	48	STEAM FLOW-B IND. [lb/hr]	SGW040(2)	4.3604E+5	4.8559E+3
11	49	STEAM FLOW-C IND. [lb/hr]	SGW040(3)	4.4061E+5	6.8321E+3
12	60	UNIT LOAD IND. [-]	GEJ120VN	1.0022E-1	1.3466E-3
13	23	PRESSURIZER PRESS. [psi]	RCP701S	2.9922E+2	1.3713E+1
14	26	PRESSURIZER LEVEL [-]	XR459	9.7192E0	5.4499E-2

表3-5 定常運転学習データ

Total Learning Pattern	300
1) 100% Steady State Operation	100
2) 50% Steady State Operation	100
3) 20% Steady State Operation	100
Learning Cycle	1000
Learning Time	2 min (Sparc20)

表3-6 定常運転データ学習後の異常判定しきい値

Ch.	Signal (Y)	Symbol	Max Error (ϵ_{\max})	S.D. $\times 2$ (ϵ_{sd})	Fault Severity Level (ϵ_f)
1	ex-core neutron flux [%]	RXNCORE	0.567	0.12153	0.7089
2	feedwater pressure [kgf/cm ²]	FWP210	0.4984	0.12569	0.6230
3	primary coolant flow [$\times 10^3$ ton/hr]	RCW111	0.0084	0.06283	0.0785
4	hot-leg temperature (B) [°C]	RCT301(2)	0.2782	0.08128	0.3477
5	hot-leg temperature (C) [°C]	RCT301(3)	0.2887	0.08961	0.3609
6	feedwater flow (B) [ton/hr]	FWW500(2)	50.558	2.57090	63.198
7	feedwater flow (C) [ton/hr]	FWW500(3)	51.773	2.80840	64.717
8	steam pressure (B) [kgf/cm ²]	SGP030(2)	0.1213	0.06721	0.1803
9	steam pressure (C) [kgf/cm ²]	SGP030(3)	0.1166	0.06821	0.1879
10	steam flow (B) [ton/hr]	SGW040(2)	9.581	0.59499	11.898
11	steam flow (C) [ton/hr]	SGW040(3)	10.470	0.69586	13.088
12	generated electric power [MWe]	GEJ120VN	8.880	2.22580	11.101

表3-7 100%定常運転時の異常事象検知時間 (定常運転データ学習)

異常事象	従来の 警報システム		ニューラルネットワーク
主給水流量 部分喪失	警報なし		1s: Feedwater Press. 3s: Feedwater Flow
大気放出弁の漏 洩(100%)	30s: Rod Stop		1s: Steam Press. 2~3s: All Signal
一次冷却材ポン プ1台軸固着	2~5s: Reactor Trip etc.		2s: Primary Water Flow 4s: Feedwater Flow Electric Power
体積制御タンク 低水位誤検知	0s: VCT-L Lo 720s: Rod Withdraw Limit		24s: Neutron Flux 41s: Hot-leg Temp.

表 3 - 8 過渡運転学習データ

Total Learning Pattern		1210
1)	100% Steady State Operation	20
2)	50% Steady State Operation	20
3)	20% Steady State Operation	20
4)	2%/min Power Decrease Operation (100%-50%)	800
5)	2%/min Power Decrease Operation (50%-25%)	350
Learning Cycle		600
Learning Time		25 min (Sparc20)

表 3 - 9 過渡運転データ学習後の異常判定しきい値

Ch.	Signal (Y)	Symbol	Max Error (ϵ_{max})	S.D. $\times 2$ (ϵ_{sd})	Fault Severity Level (ϵ_f)
1	ex-core neutron flux [%]	RXNCORE	0.6618	0.12153	0.8273
2	feedwater pressure [kgf/cm ²]	FWP210	0.1810	0.12569	0.2262
3	primary coolant flow [$\times 10^3$ ton/hr]	RCW111	0.03936	0.06283	0.0785
4	hot-leg temperature (B) [$^{\circ}$ C]	RCT301(2)	0.2067	0.08128	0.2584
5	hot-leg temperature (C) [$^{\circ}$ C]	RCT301(3)	0.2226	0.08961	0.2782
6	feedwater flow (B) [ton/hr]	FWW500(2)	5.8284	2.57090	7.2855
7	feedwater flow (C) [ton/hr]	FWW500(3)	5.9506	2.80840	7.4383
8	steam pressure (B) [kgf/cm ²]	SGP030(2)	0.0716	0.06721	0.0895
9	steam pressure (C) [kgf/cm ²]	SGP030(3)	0.0767	0.06821	0.0959
10	steam flow (B) [ton/hr]	SGW040(2)	6.7225	0.59499	8.4031
11	steam flow (C) [ton/hr]	SGW040(3)	6.9152	0.69586	8.6441
12	generated electric power [MWe]	GEJ120VN	5.5467	2.22580	6.9334

表 3 - 10 中間層の数

中間層の数	誤差の二乗和
1 2 - 1 0 - 1 2	0.1479
1 2 - 1 4 - 1 2	0.0296
1 2 - 1 8 - 1 2	0.0396
1 2 - 2 2 - 1 2	0.0259
1 2 - 2 6 - 1 2	0.0257
1 2 - 3 0 - 1 2	0.0223

表3-1-1 100%定常運転時の異常事象検知時間（過渡運転データ学習）

異常事象	従来の 警報システム	定常運転データ学習 ネットワーク	過渡運転データ学習 ネットワーク
主給水流量 部分喪失	警報なし	1s: Feedwater Press. 3s: Feedwater Flow	2s: Neutron Flux Feedwater Press.
タービン制御弁 フェイルオープン	警報なし	3s: Steam Flow 10s: Neutron Flux	4s: Steam Flow 5s: Neutron Flux
大気放出弁の 漏洩(100%)	30s: Rod Stop	1s: Steam Flow 2s: All Signal	1s: Steam Press Steam Flow
体積制御タンク 低水位誤検知	0s: VCT-L Lo 720s: Rod Withdraw Limit	24s: Neutron Flux 95s: Hot-leg Temp.	129s: Steam Press 155s: Steam Press (連続)

表3-1-2 出力減少運転時の異常事象検知時間

異常事象	従来の 警報システム	過渡運転データ学習 ネットワーク
主給水流量 部分喪失	警報なし	2s: Feedwater Press. Feedwater Flow
タービン制御弁 フェイルオープン	警報なし	2s: Hot-leg Temp. Electric Power
大気放出弁の 漏洩(100%)	228s: Tav/Tref Dev.	3s: Steam Press Steam Flow
体積制御タンク 低水位誤検知	0s: VCT-L Lo. 354s: Rod Withdraw Limit	38s: Feedwater Press. 41s: Neutron Flux Steam Flow

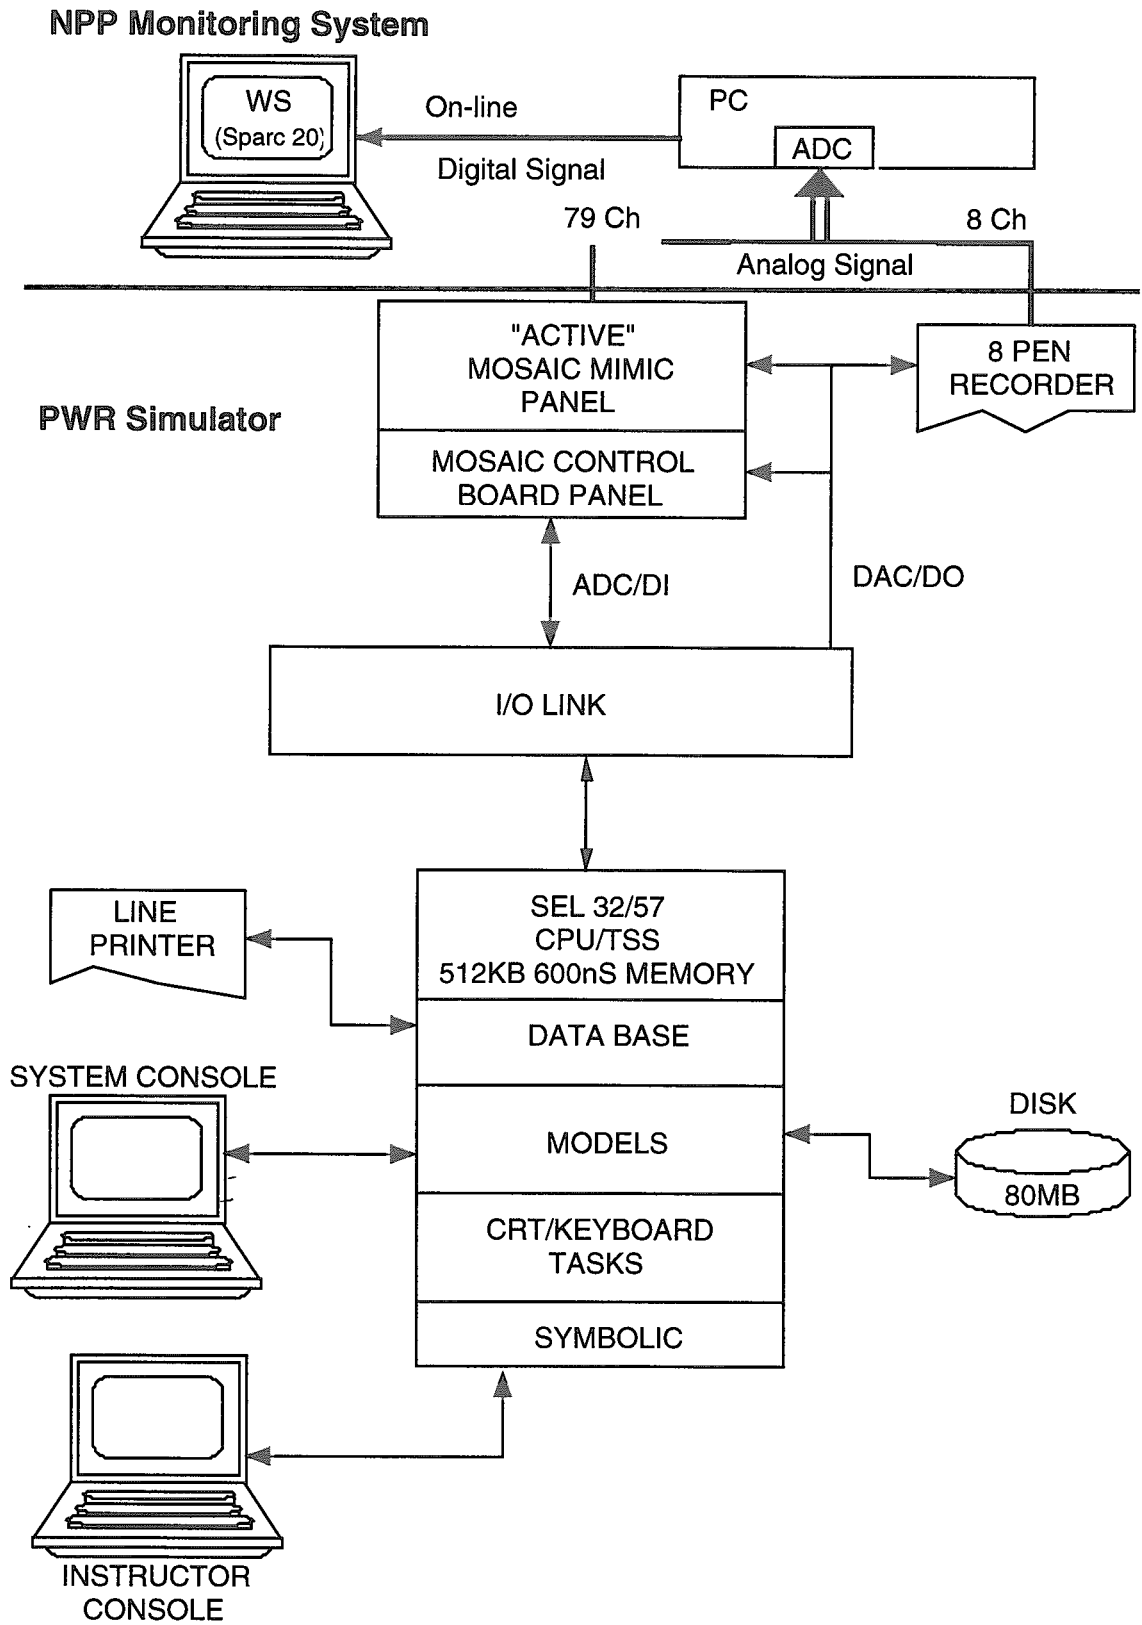


図 3 - 1 シミュレータ構成図

- 監視信号点 (12)
- ★ 異常事象発生点 (5)

MIMIC PANEL

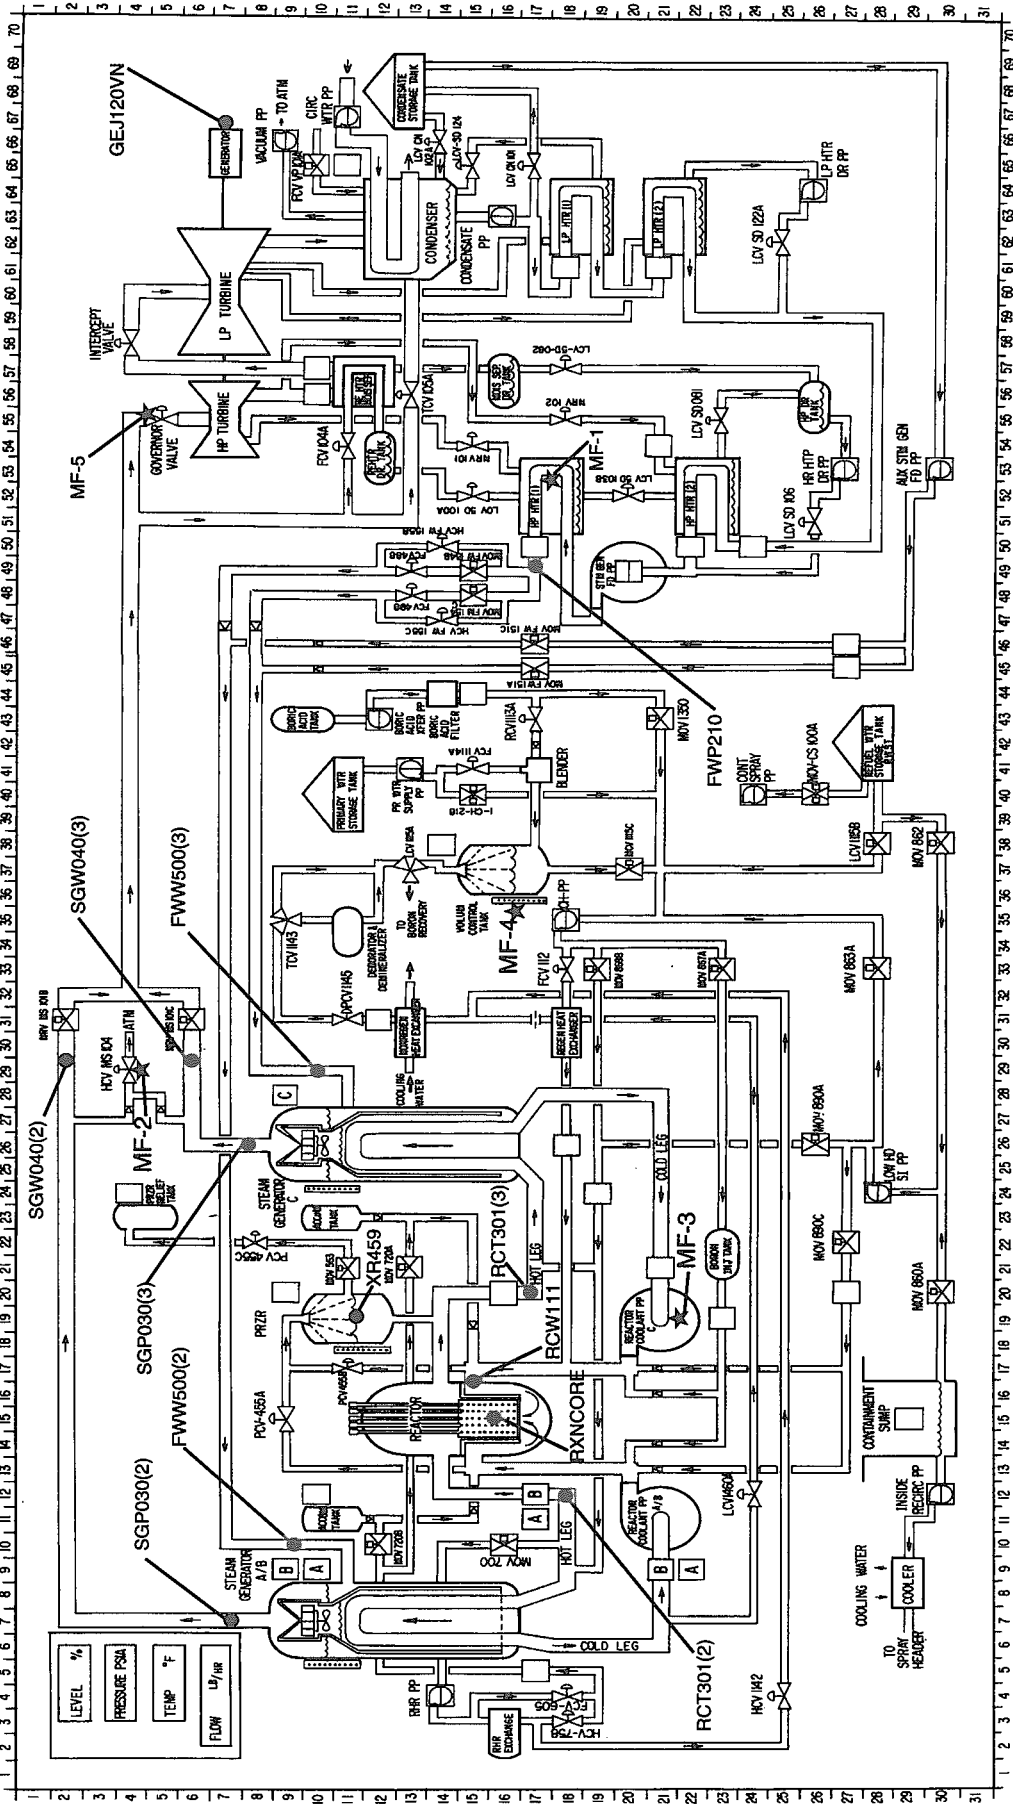


図3-2 PWRプラントモデル図 (ミミックパネル)

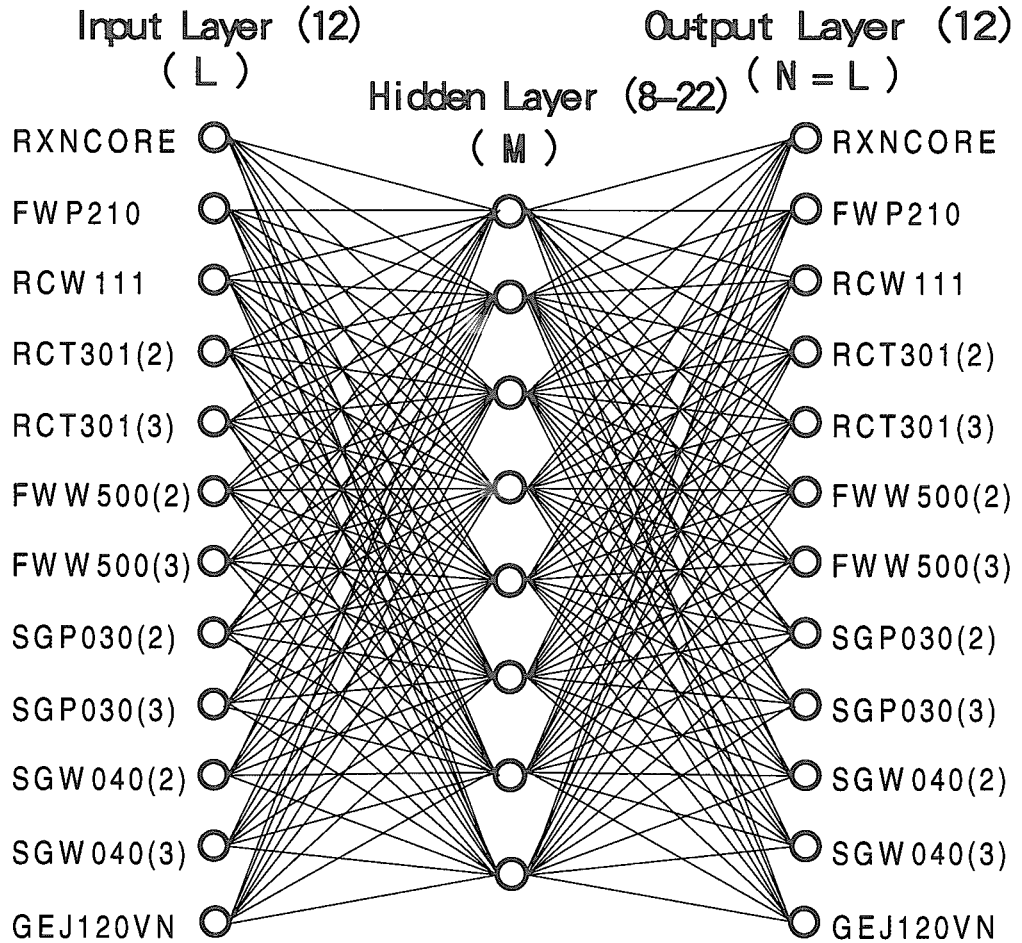


図 3-3 オートアソシアティブネットワークモデル

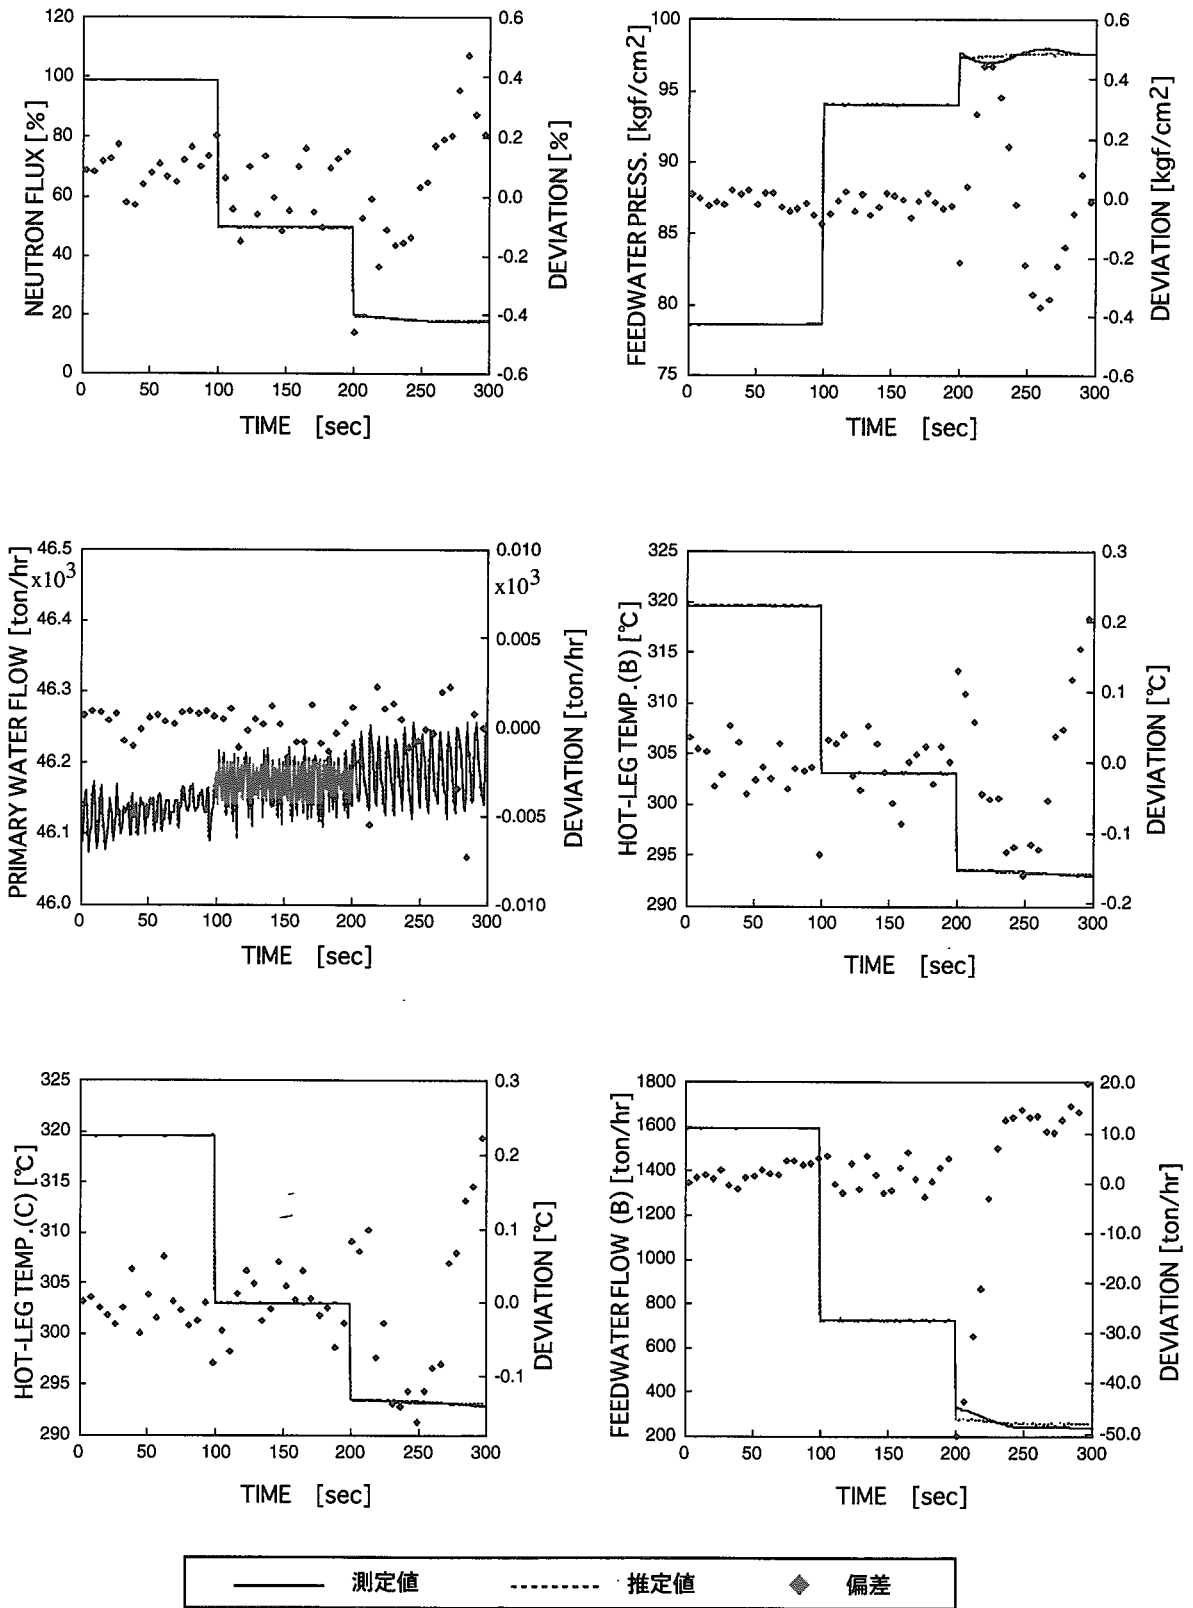


図 3-4 (a) 初期学習結果 (1)

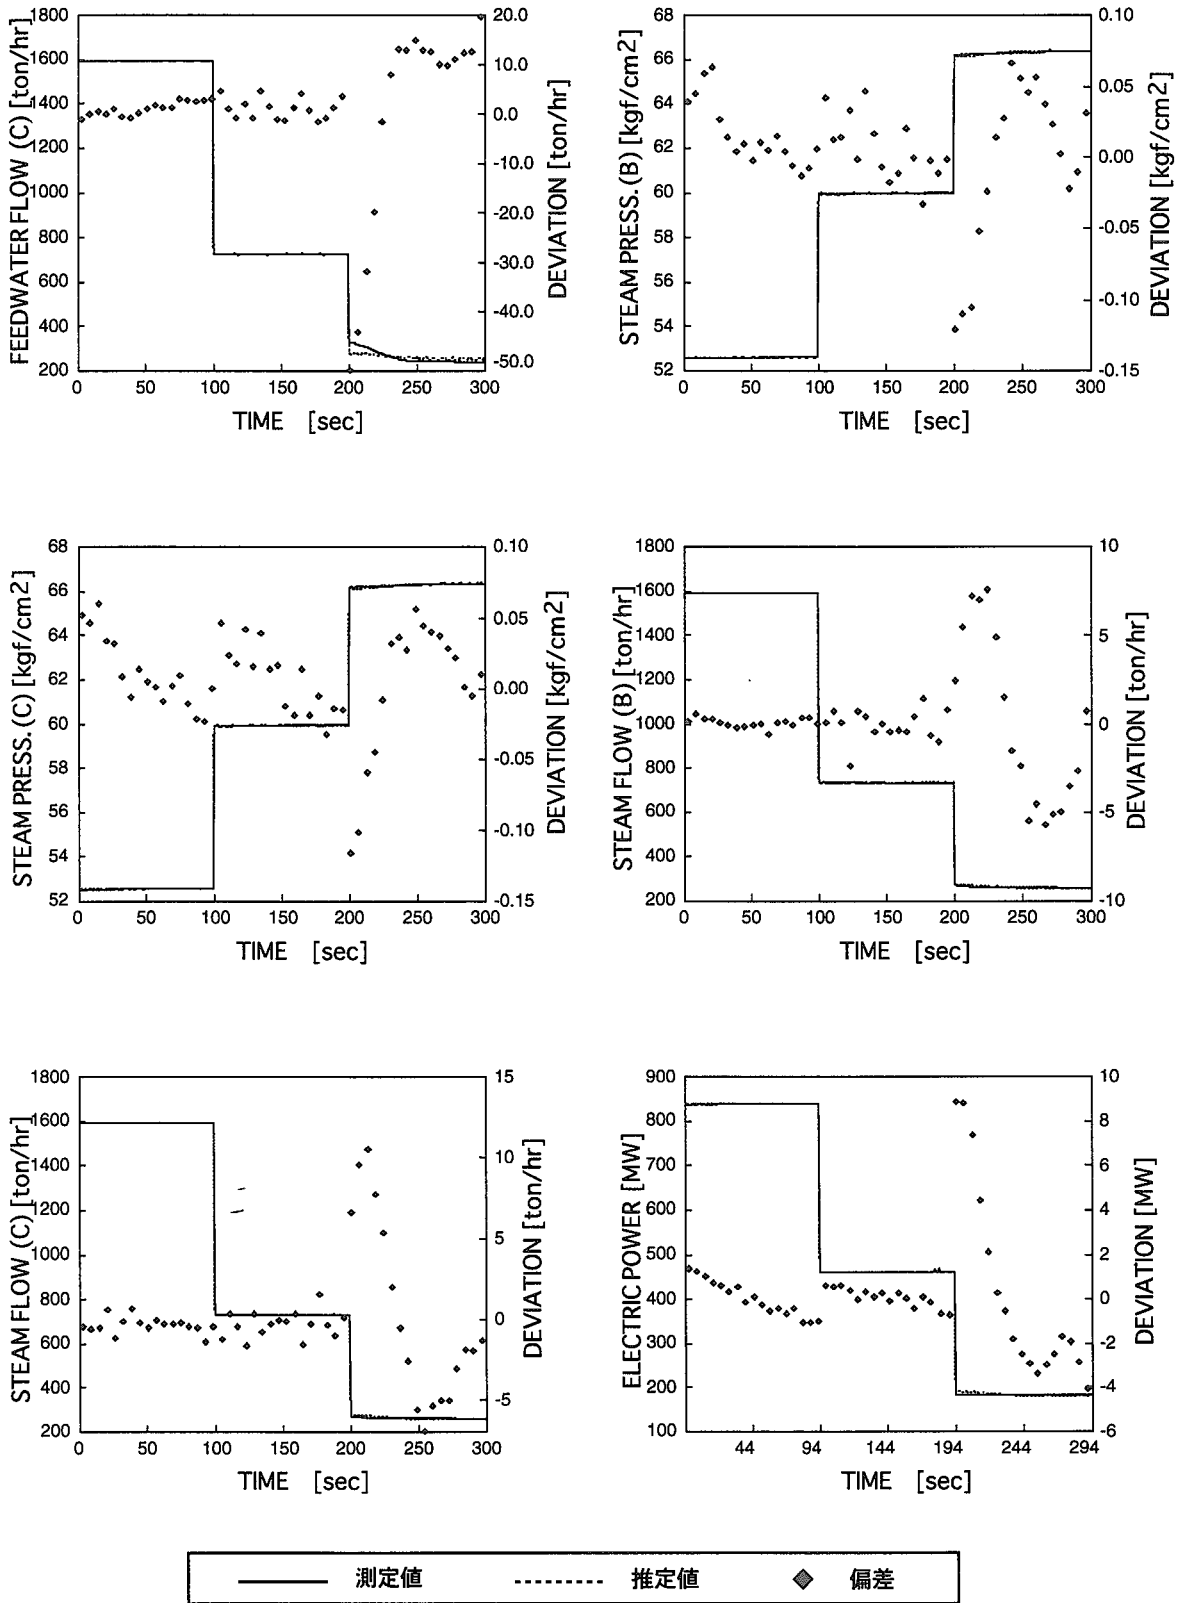


図 3 - 4 (b) 初期学習結果 (2)

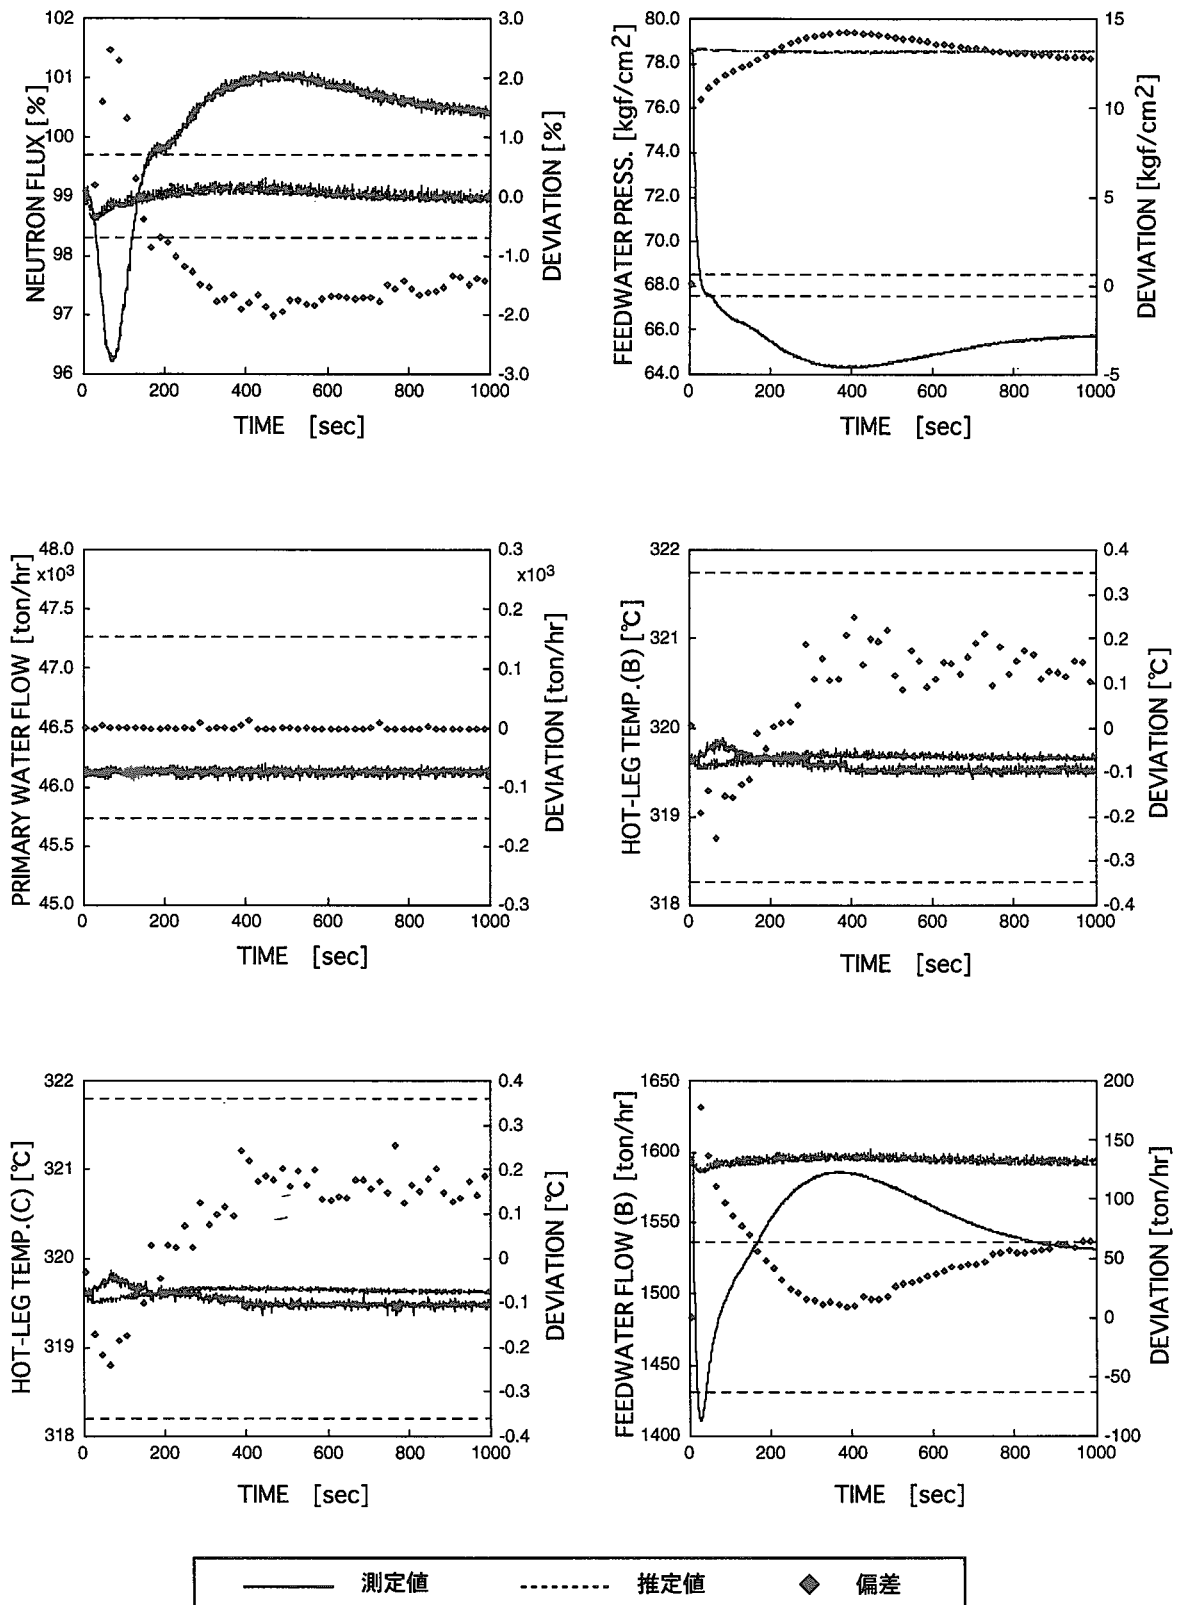


図3-5(a) 主給水部分喪失時の応答 (1)

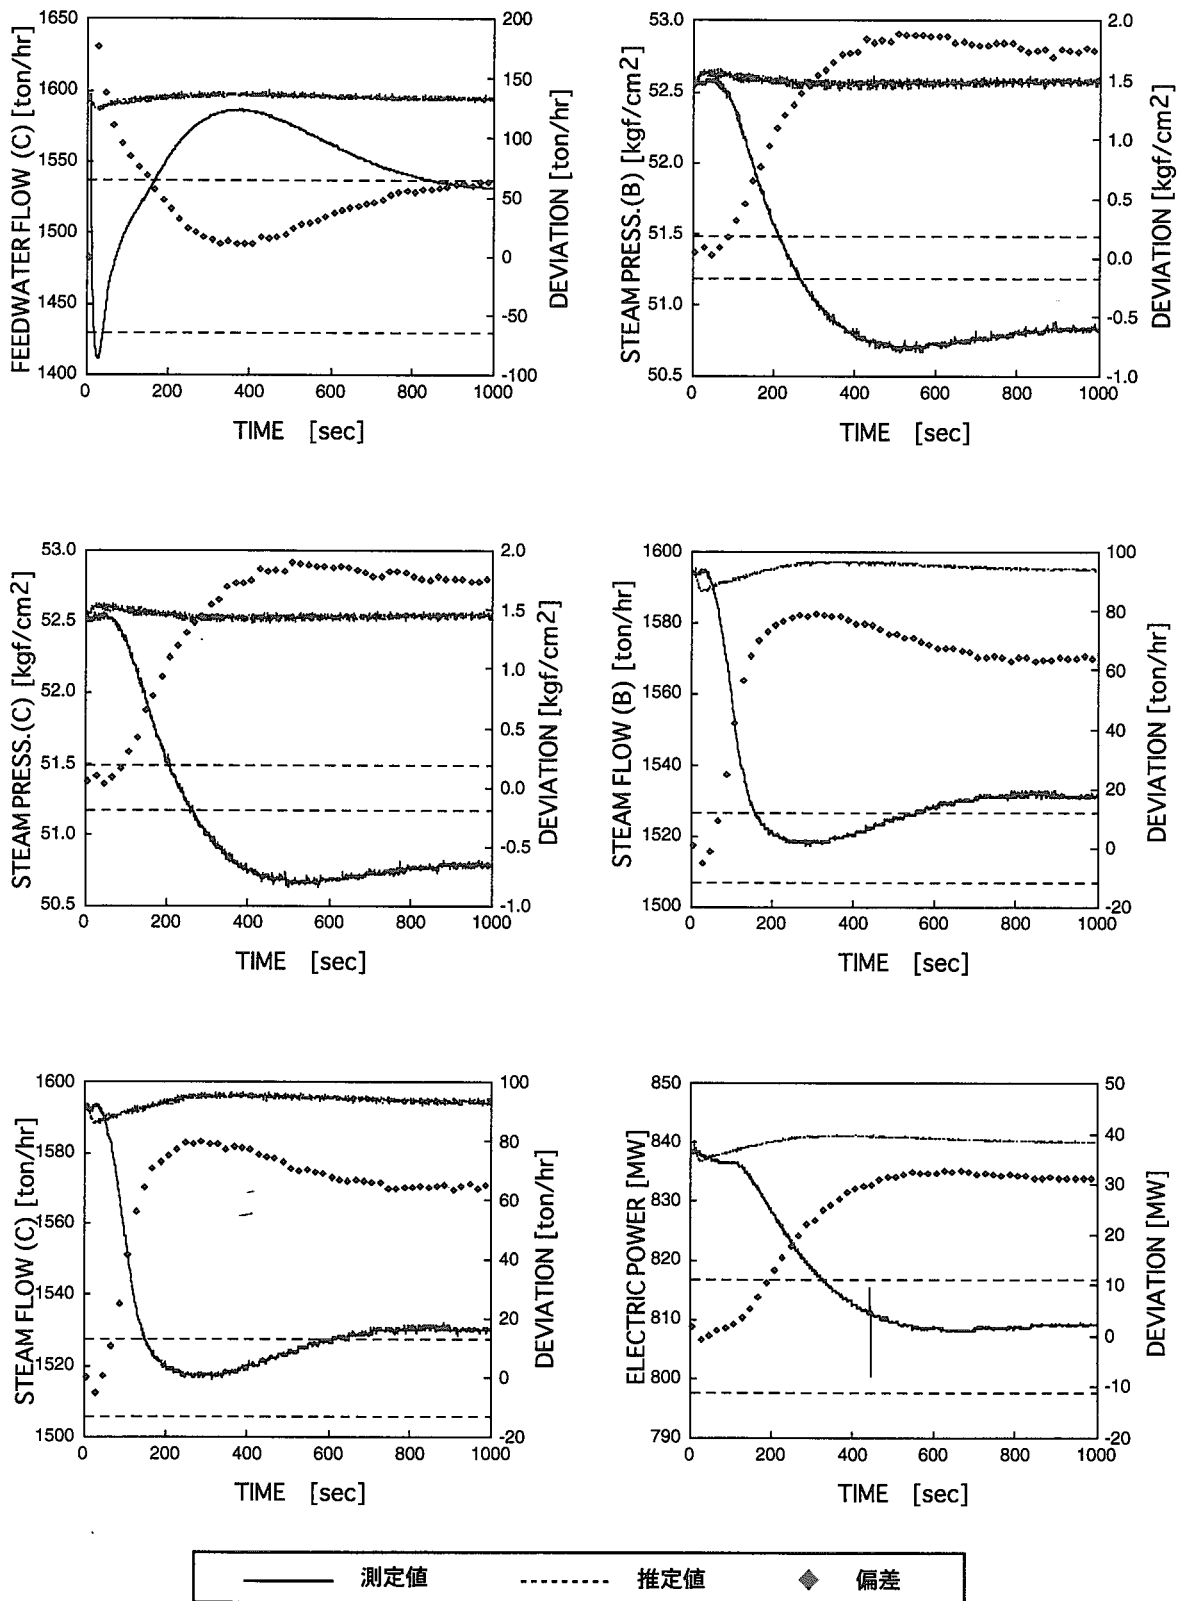


図3-5(b) 主給水部分喪失時の応答 (2)

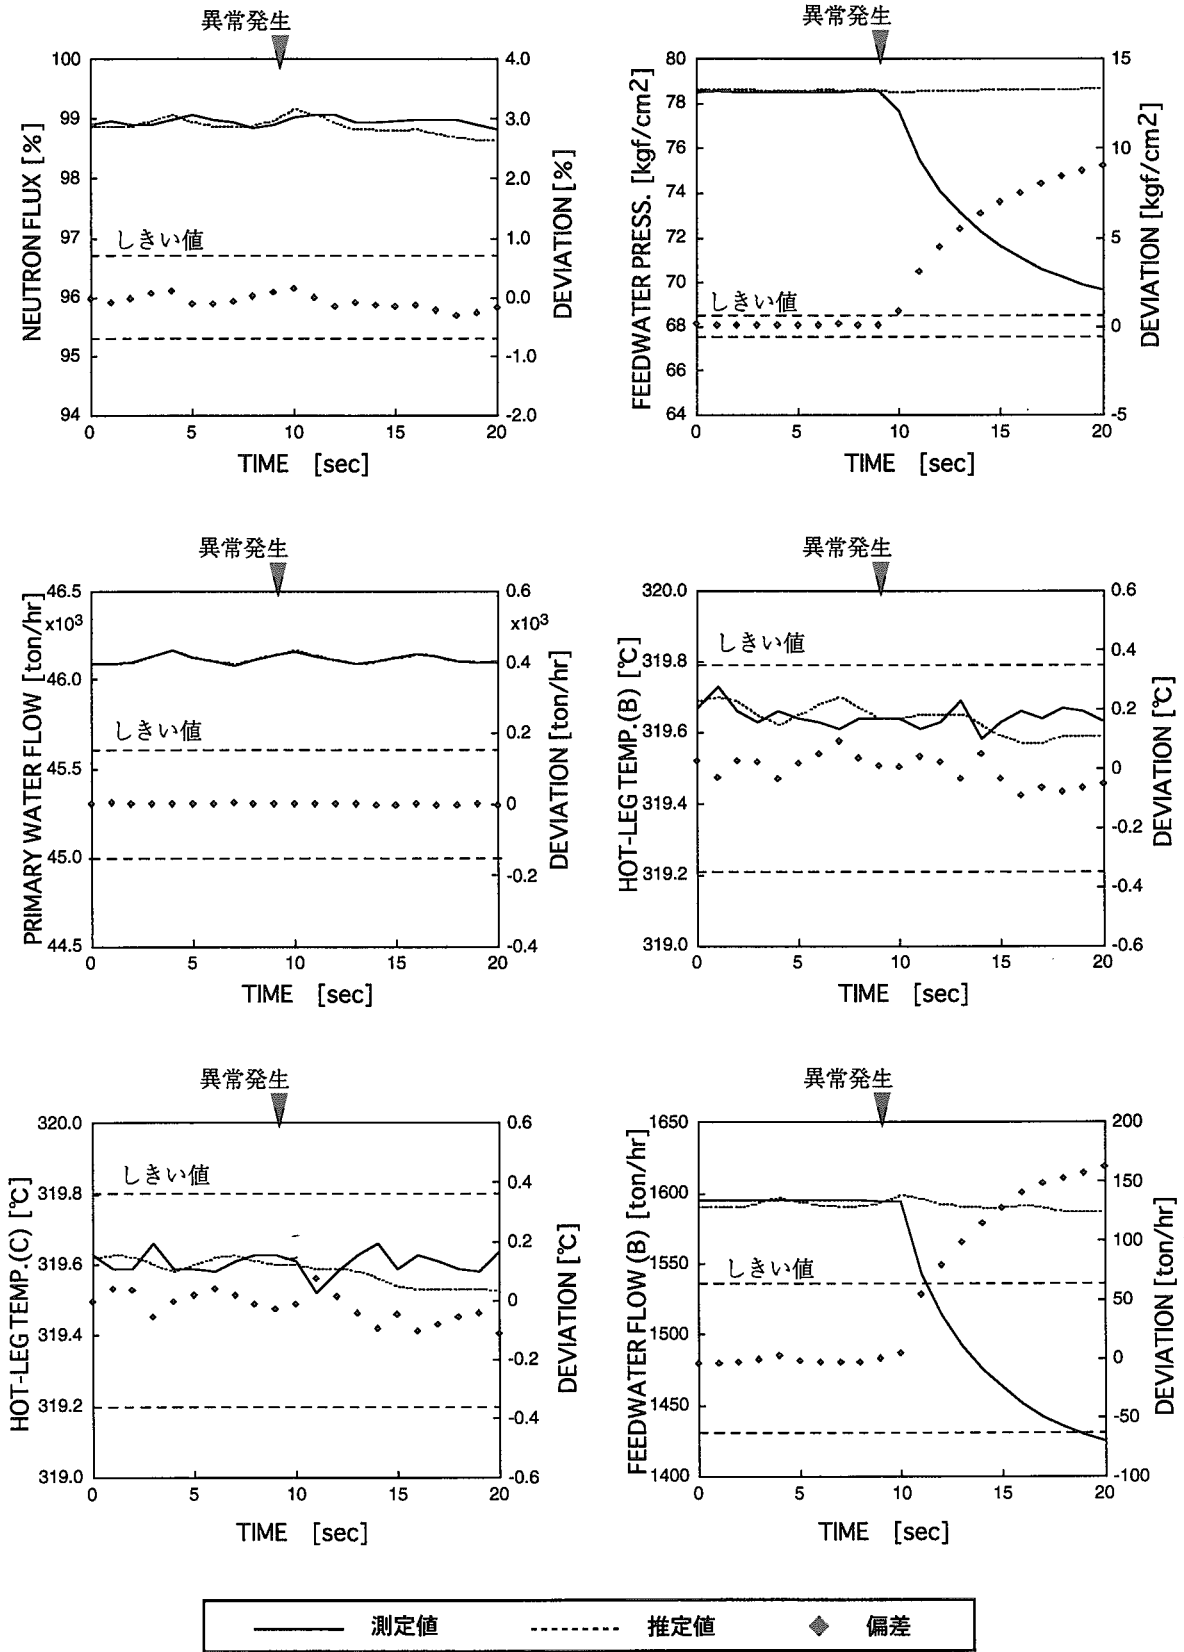


図3-6(a) 主給水部分喪失時の応答 (0-20秒)

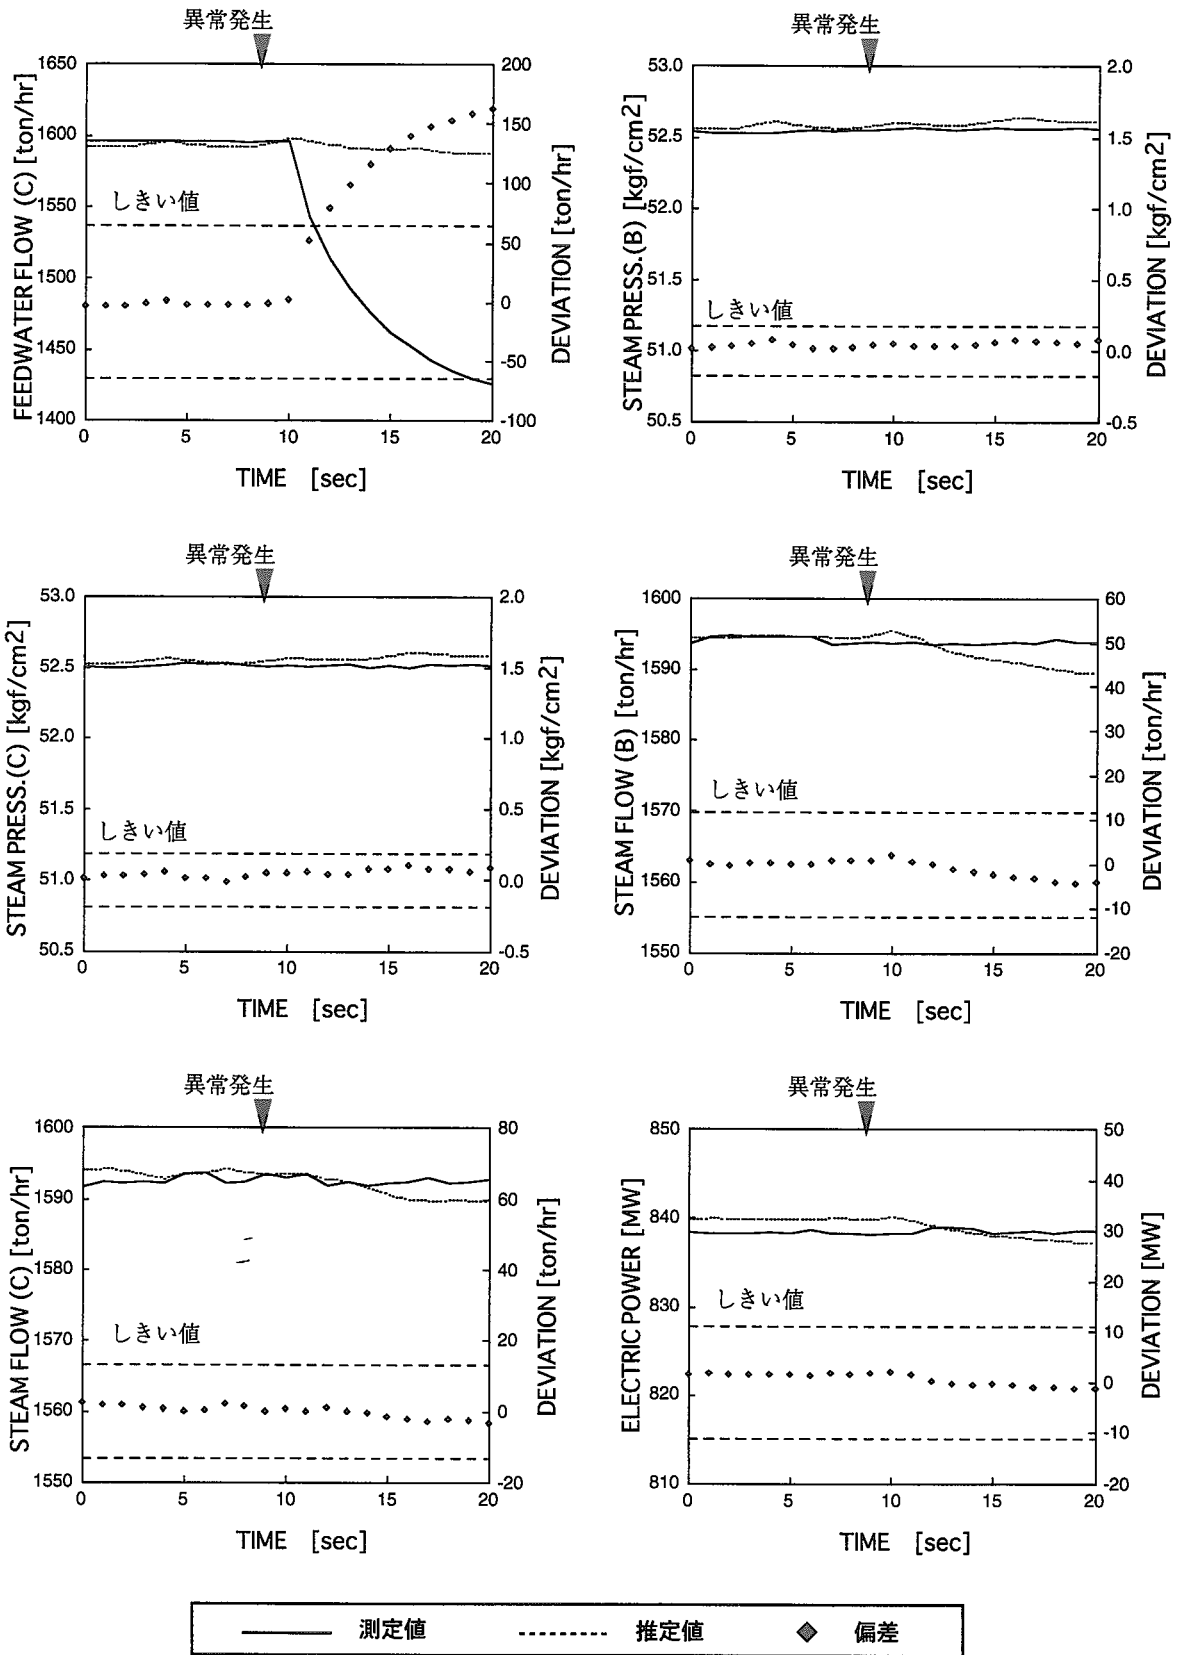


図3-6(b) 主給水部分喪失時の応答 (0-20秒)

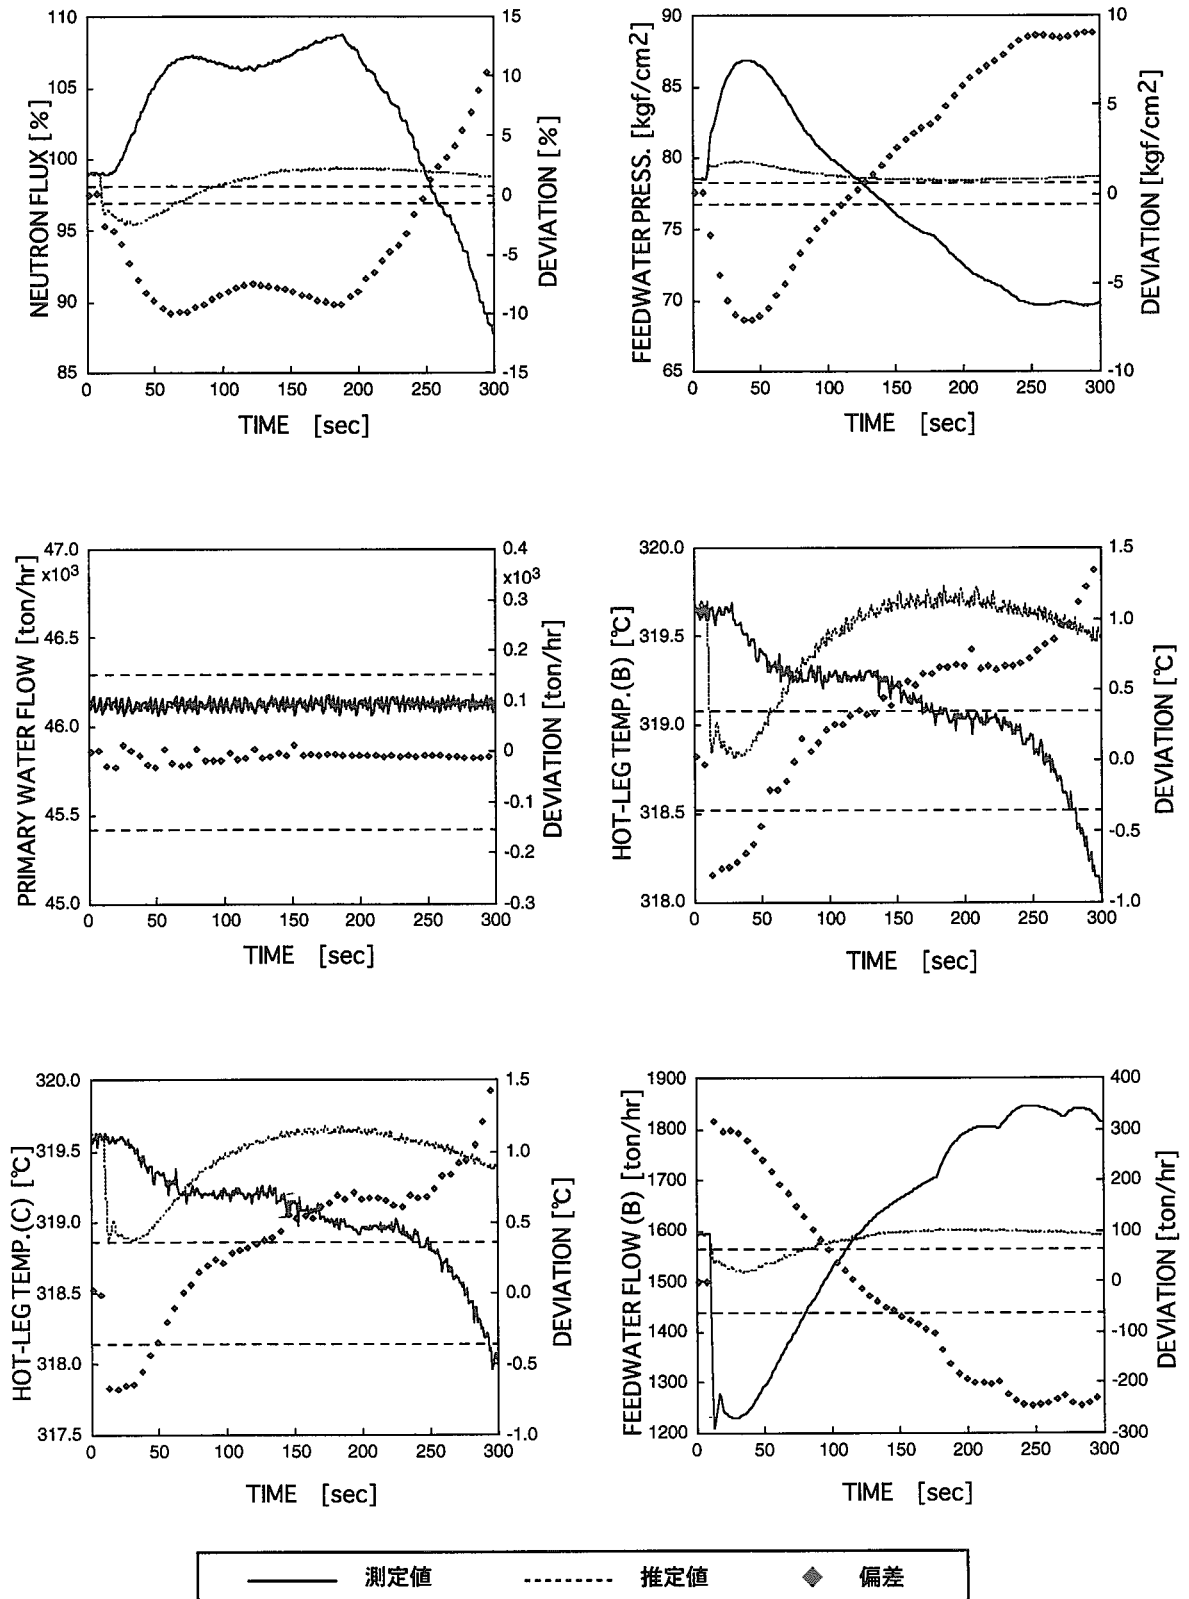


図3-7(a) 大気放出弁の漏洩時の応答 (1)

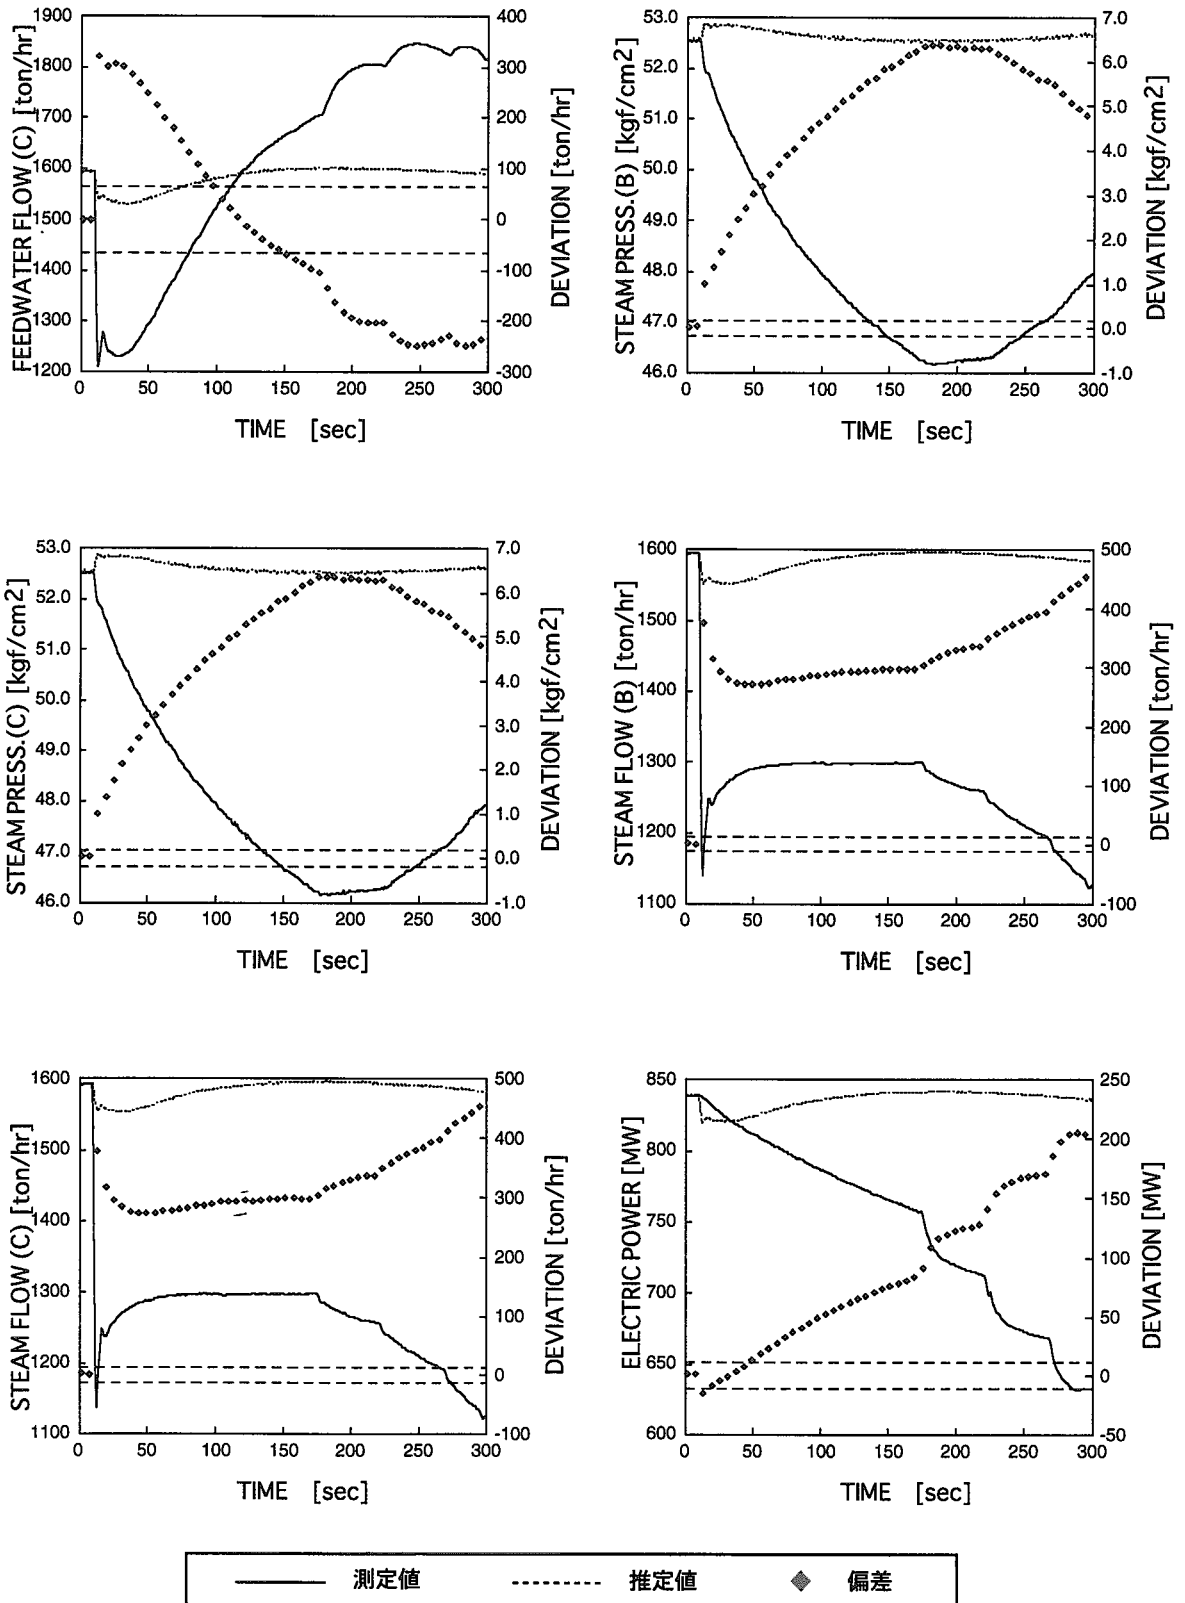


図 3 - 7 (b) 大気放出弁の漏洩時の応答 (2)

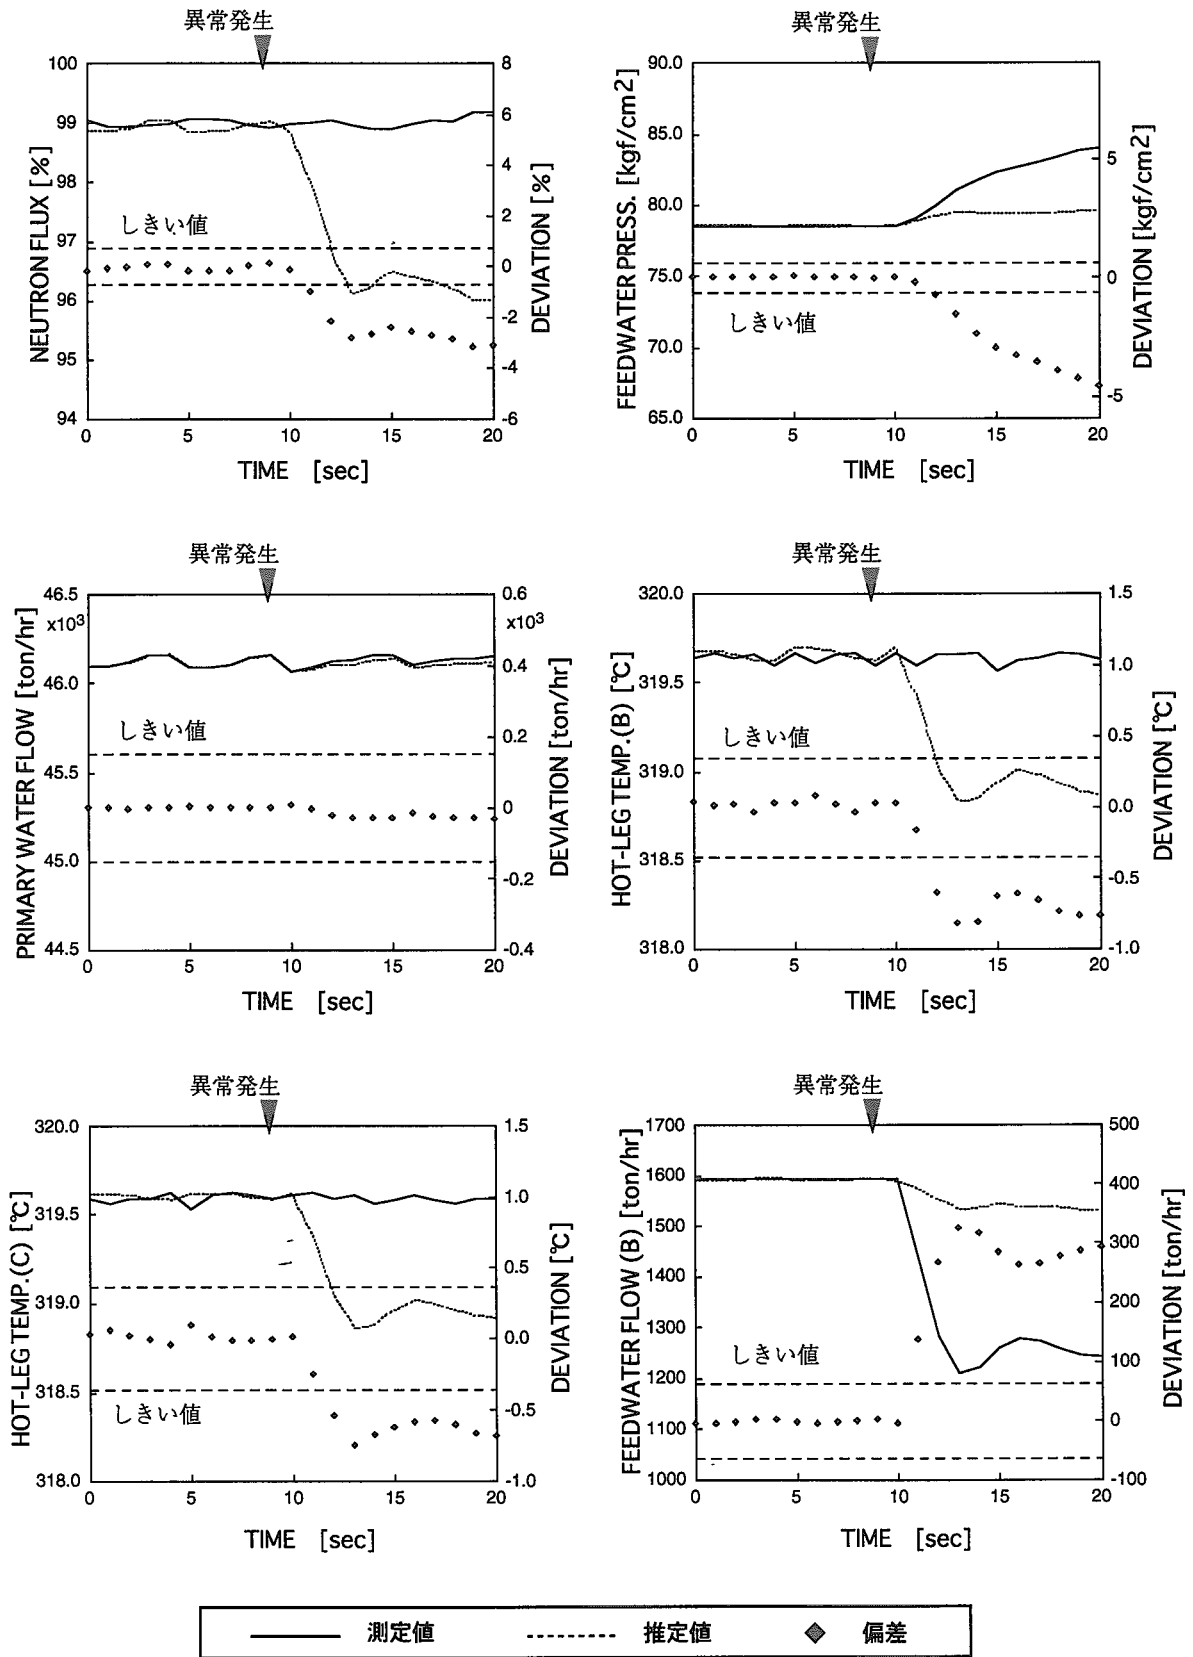


図3-8(a) 大気放出弁の漏洩時の応答 (0-20秒)

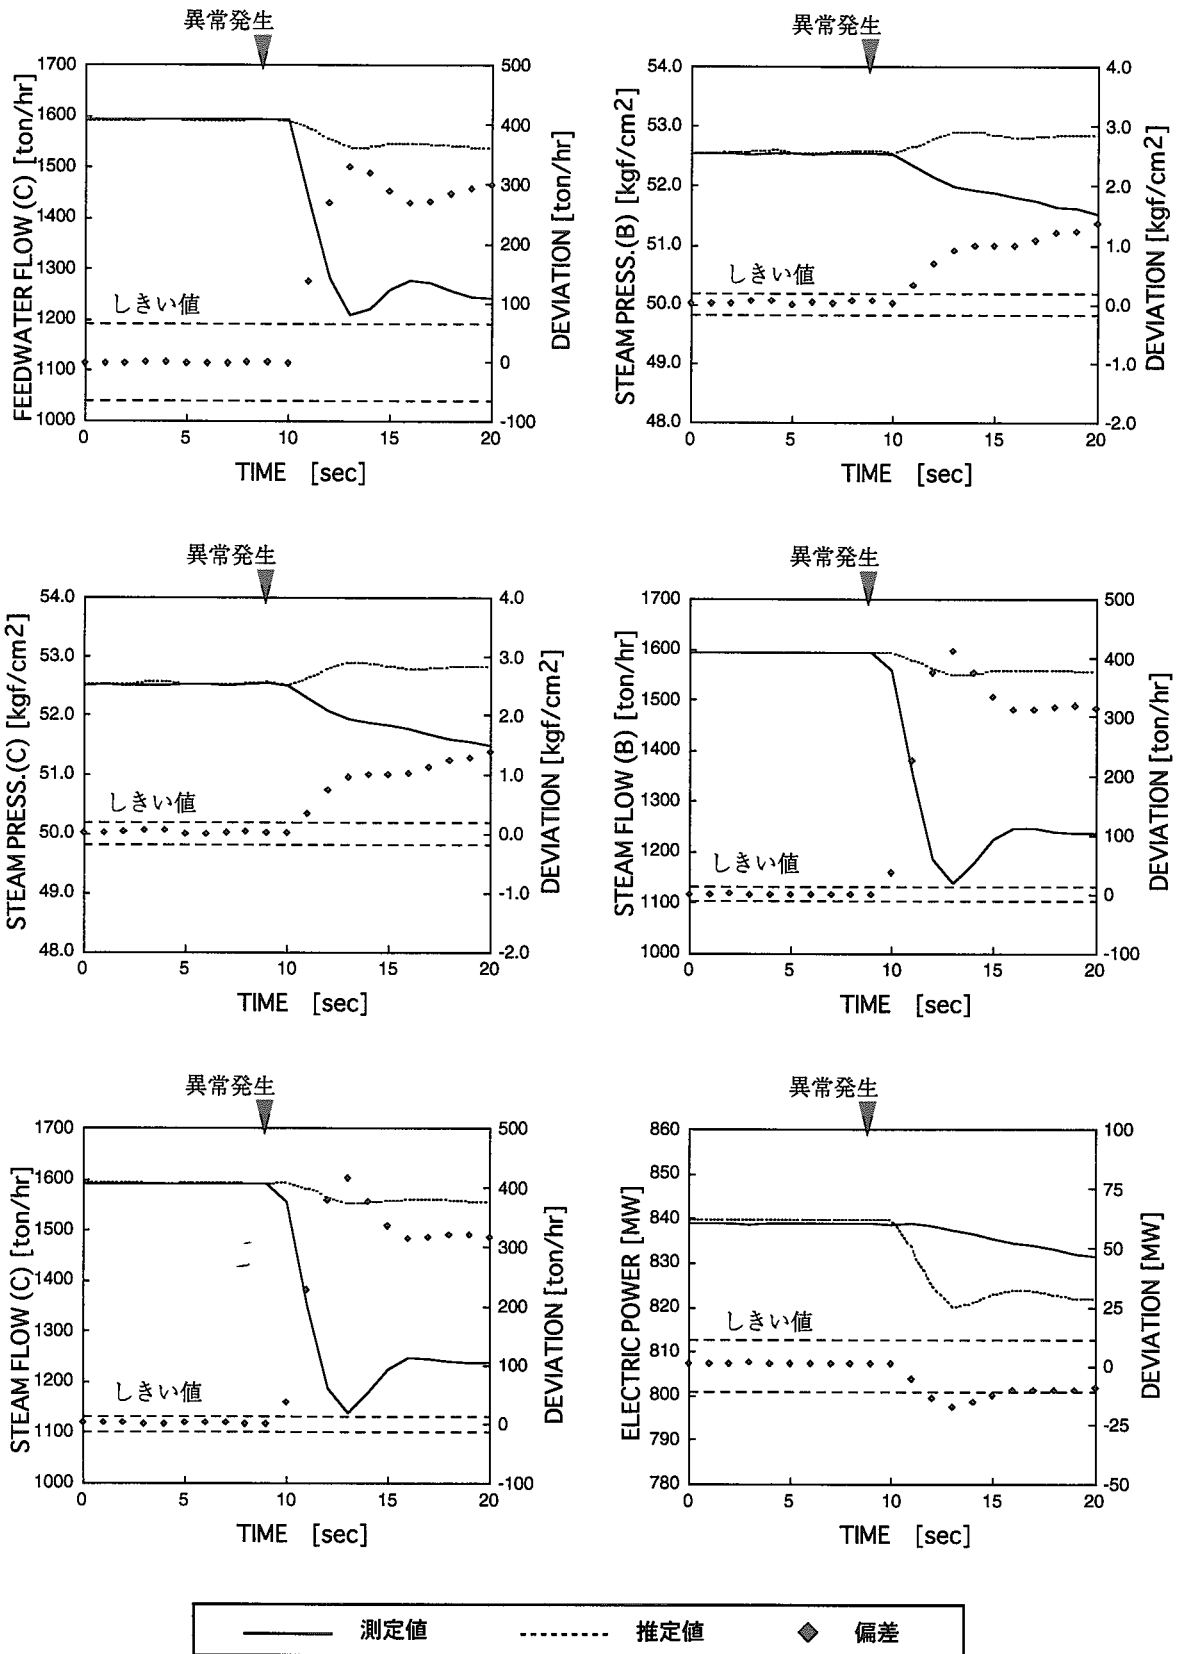


図3-8(b) 大気放出弁の漏洩時の応答 (0-20秒)

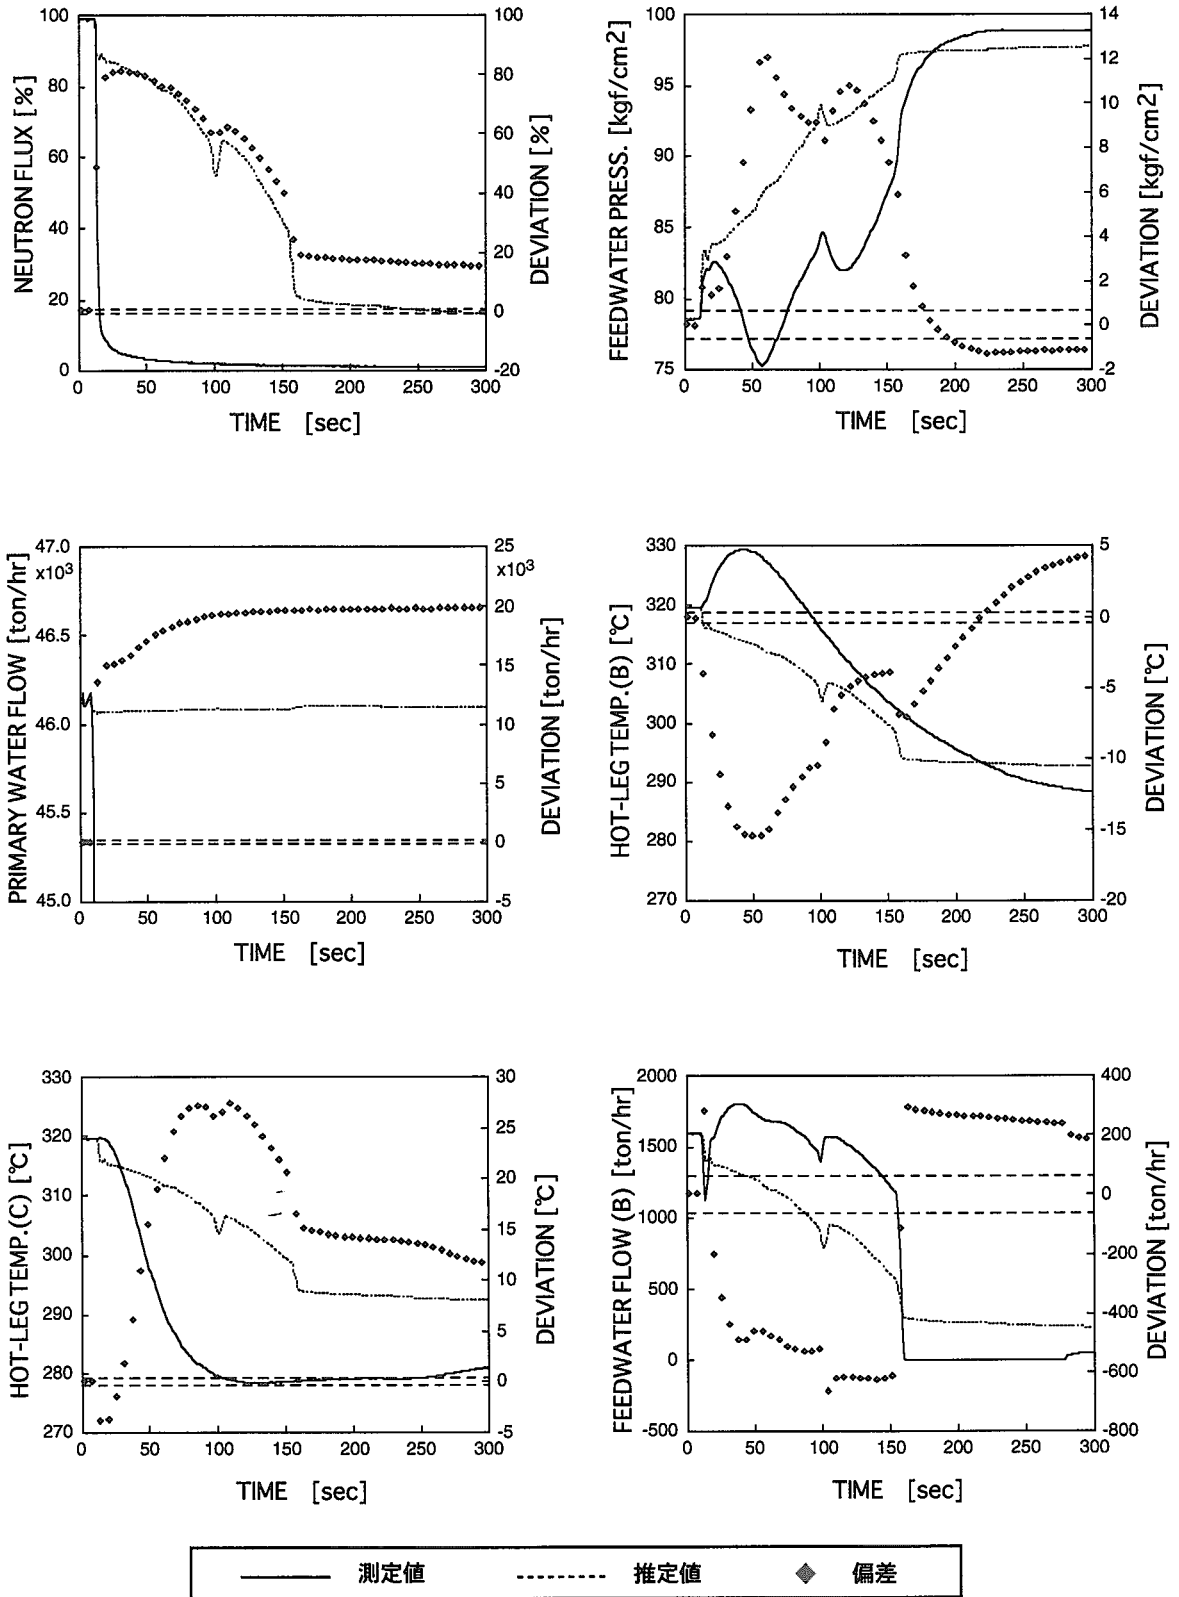


図3-9(a) 一次冷却材部分喪失時の応答 (1)

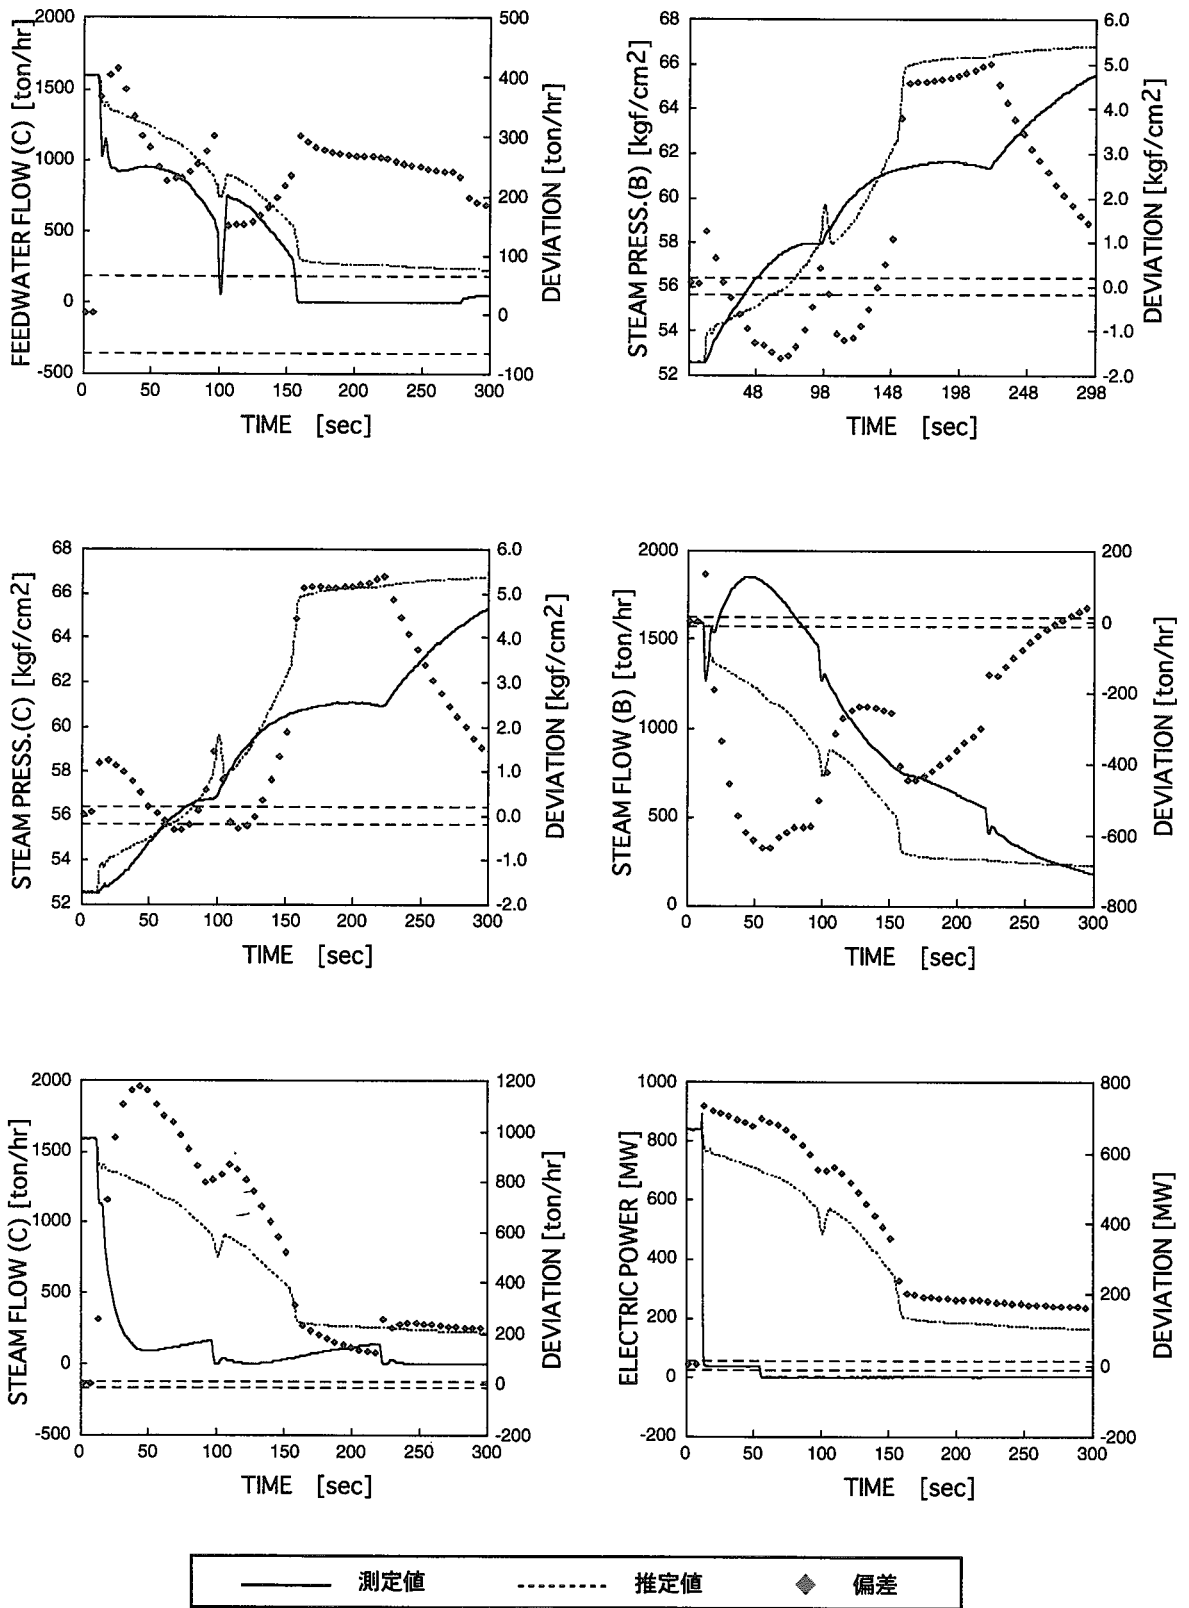


図 3 - 9 (b) 一次冷却材部分喪失時の応答 (2)

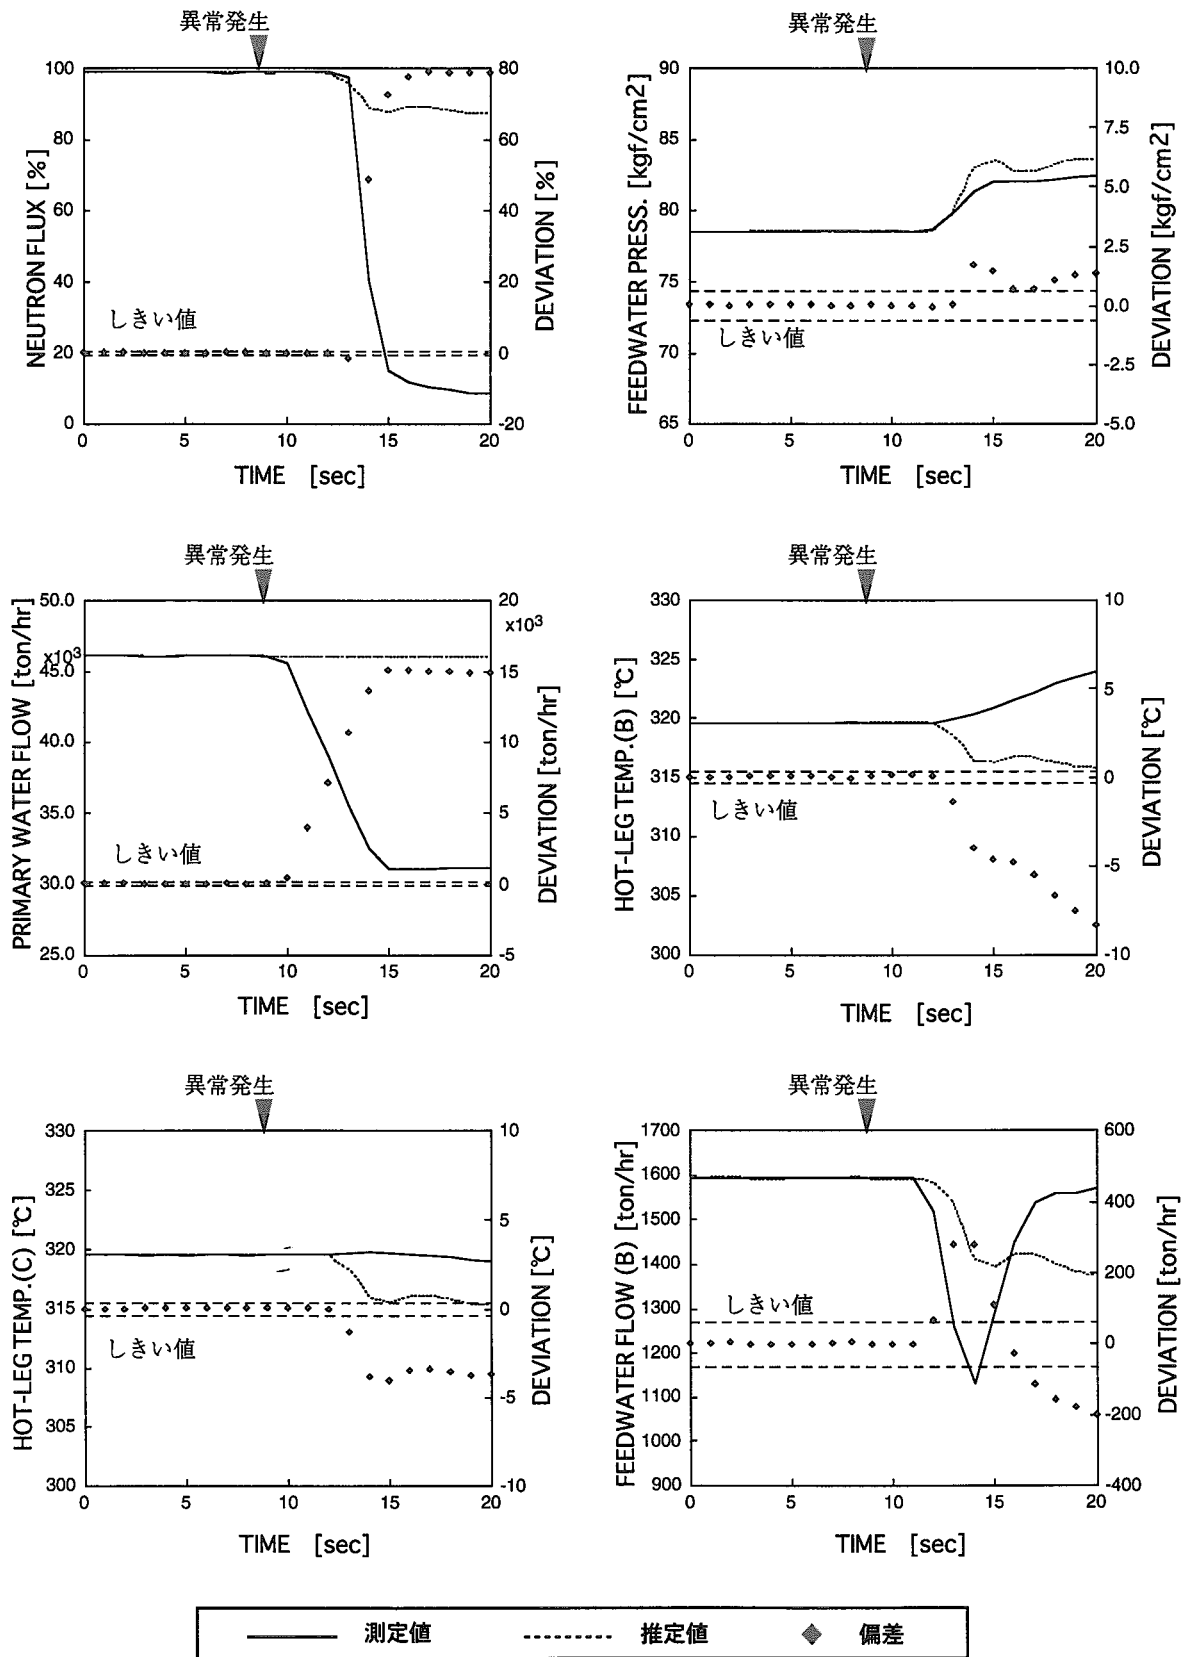


図3-10(a) 一次冷却材部分喪失時の応答 (0-20秒)

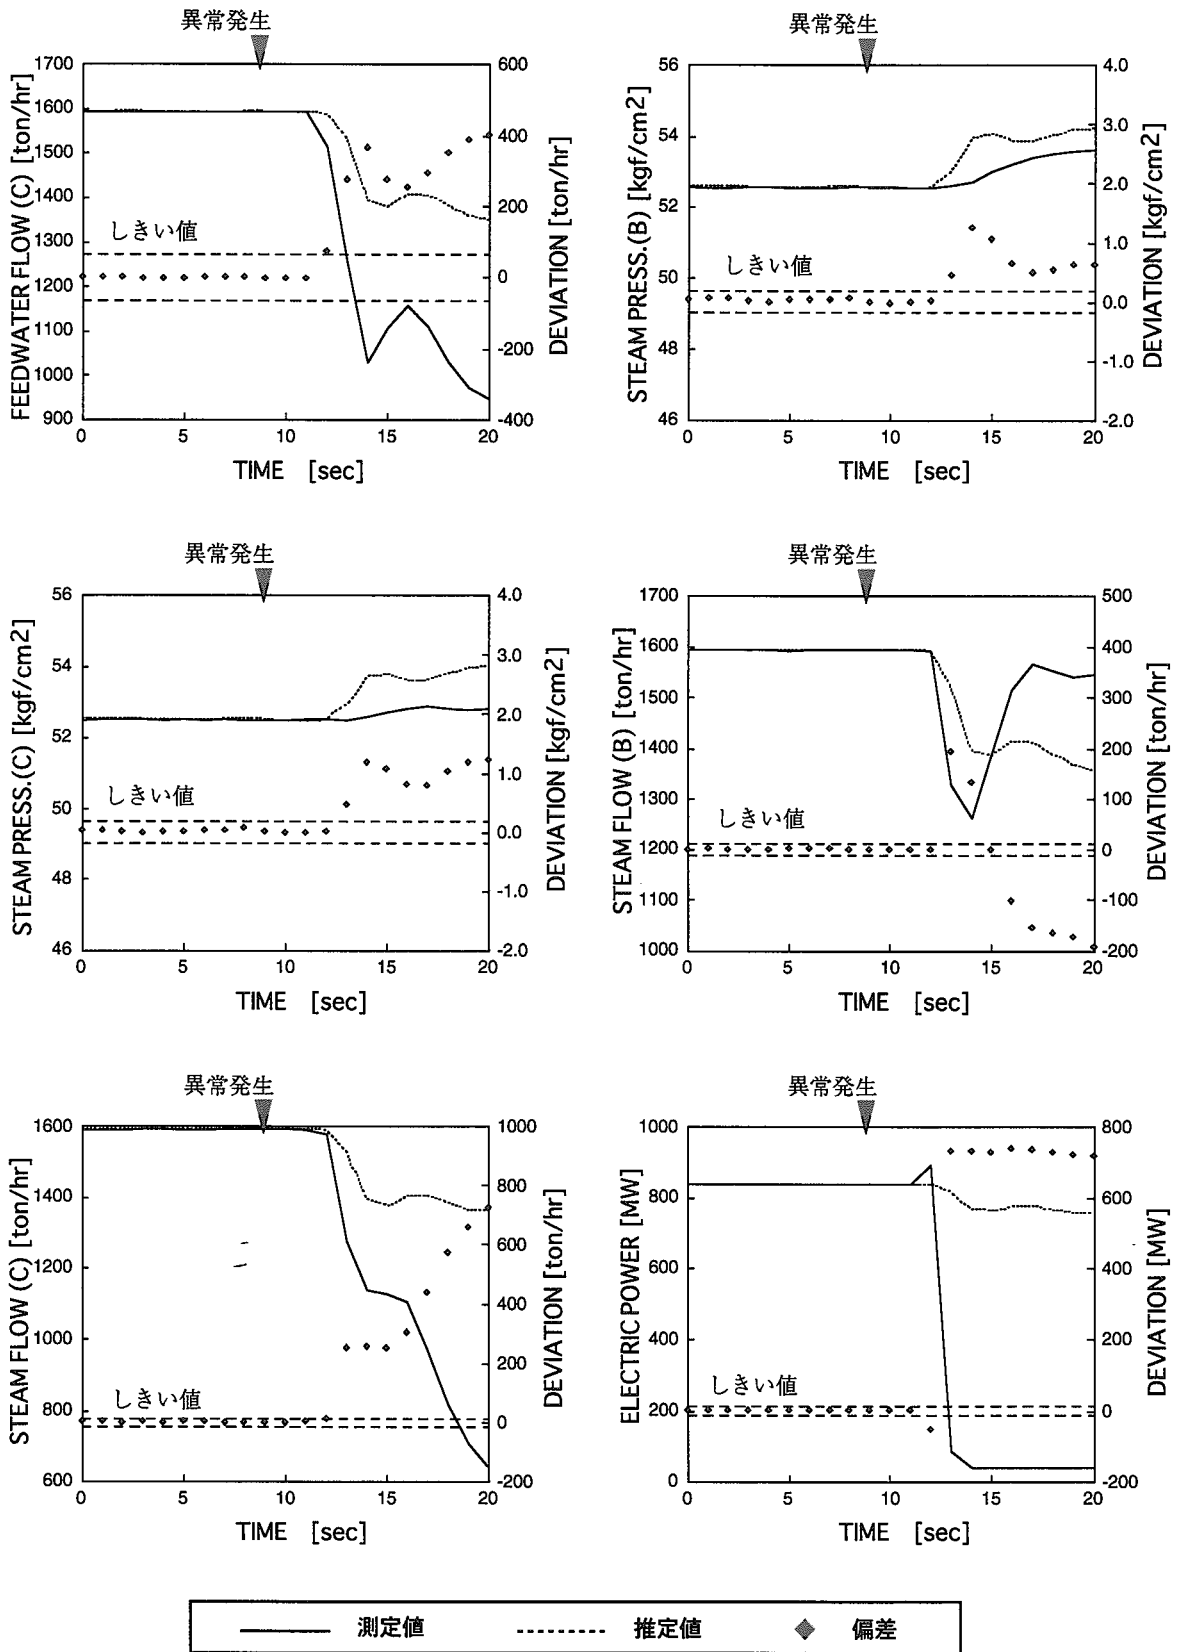


図 3 - 1 0 (b) 一次冷却水部分喪失時の応答 (0-20秒)

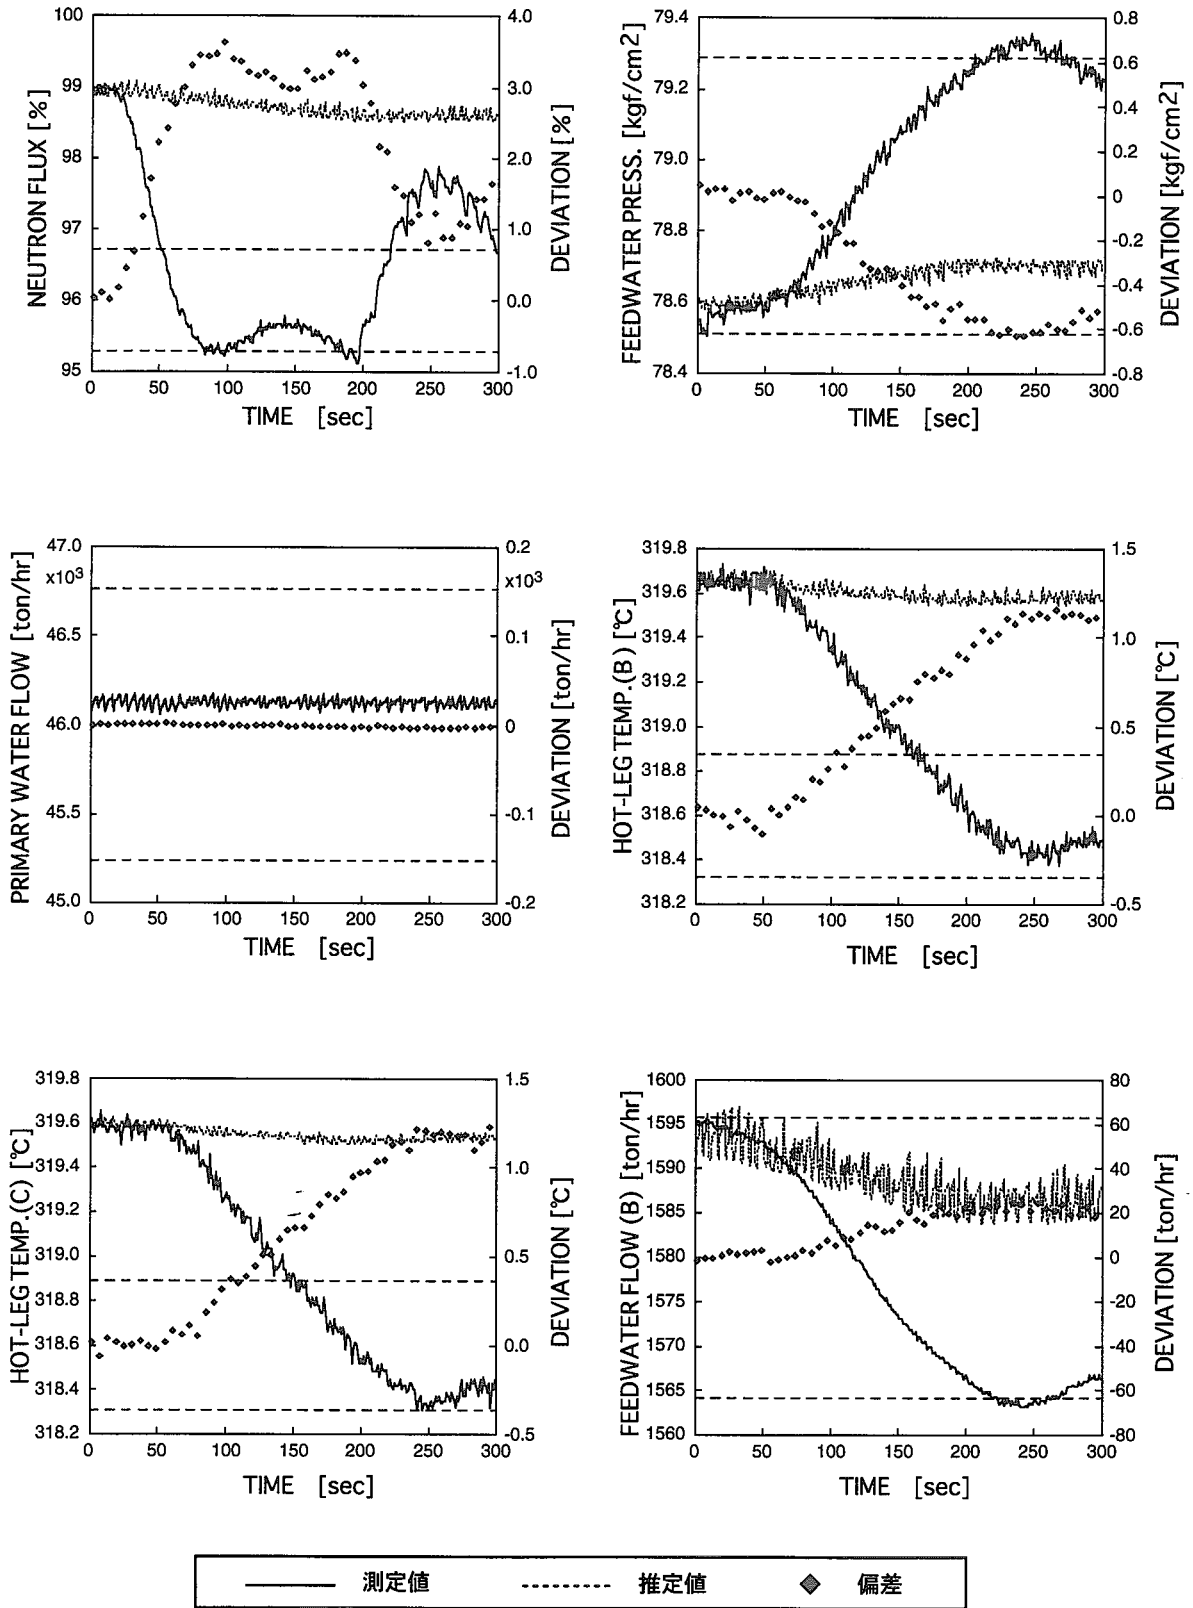


図3-11(a) 体積制御タンク低水位誤検知時の応答 (1)

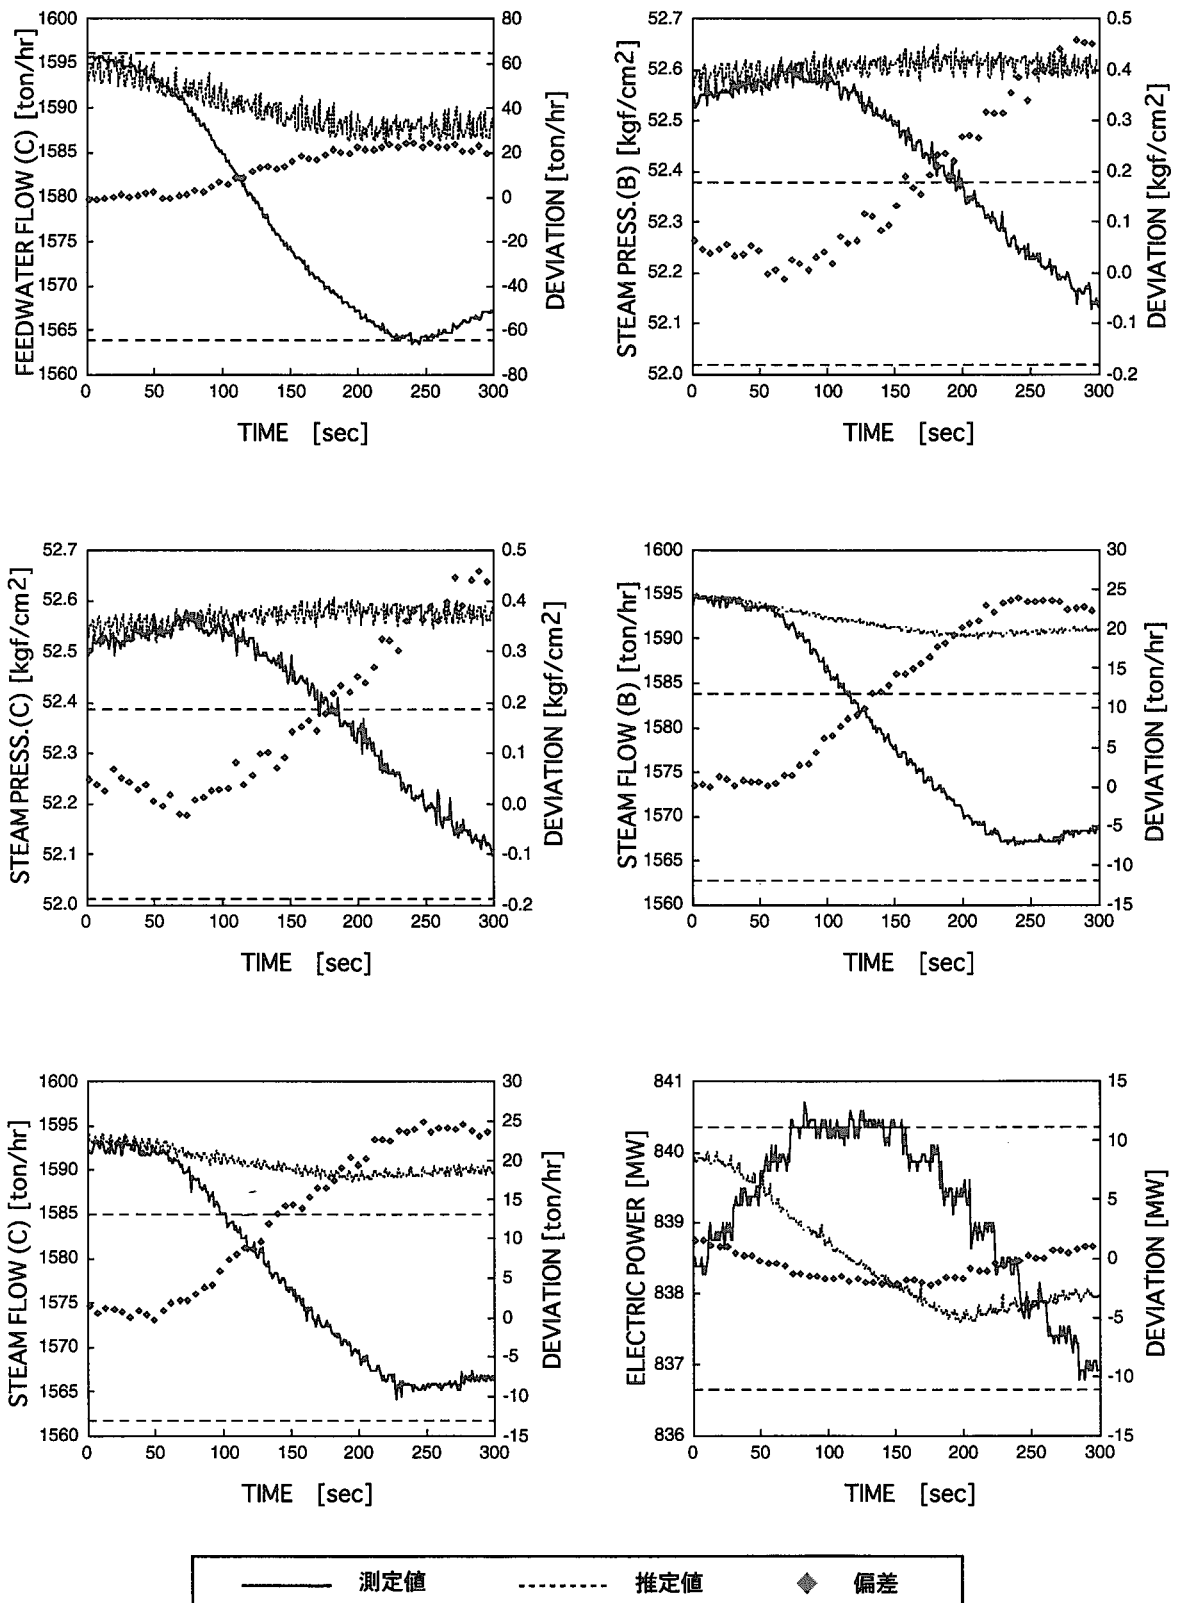


図 3-1-1 (b) 体積制御タンク低水位誤検知時の応答 (2)

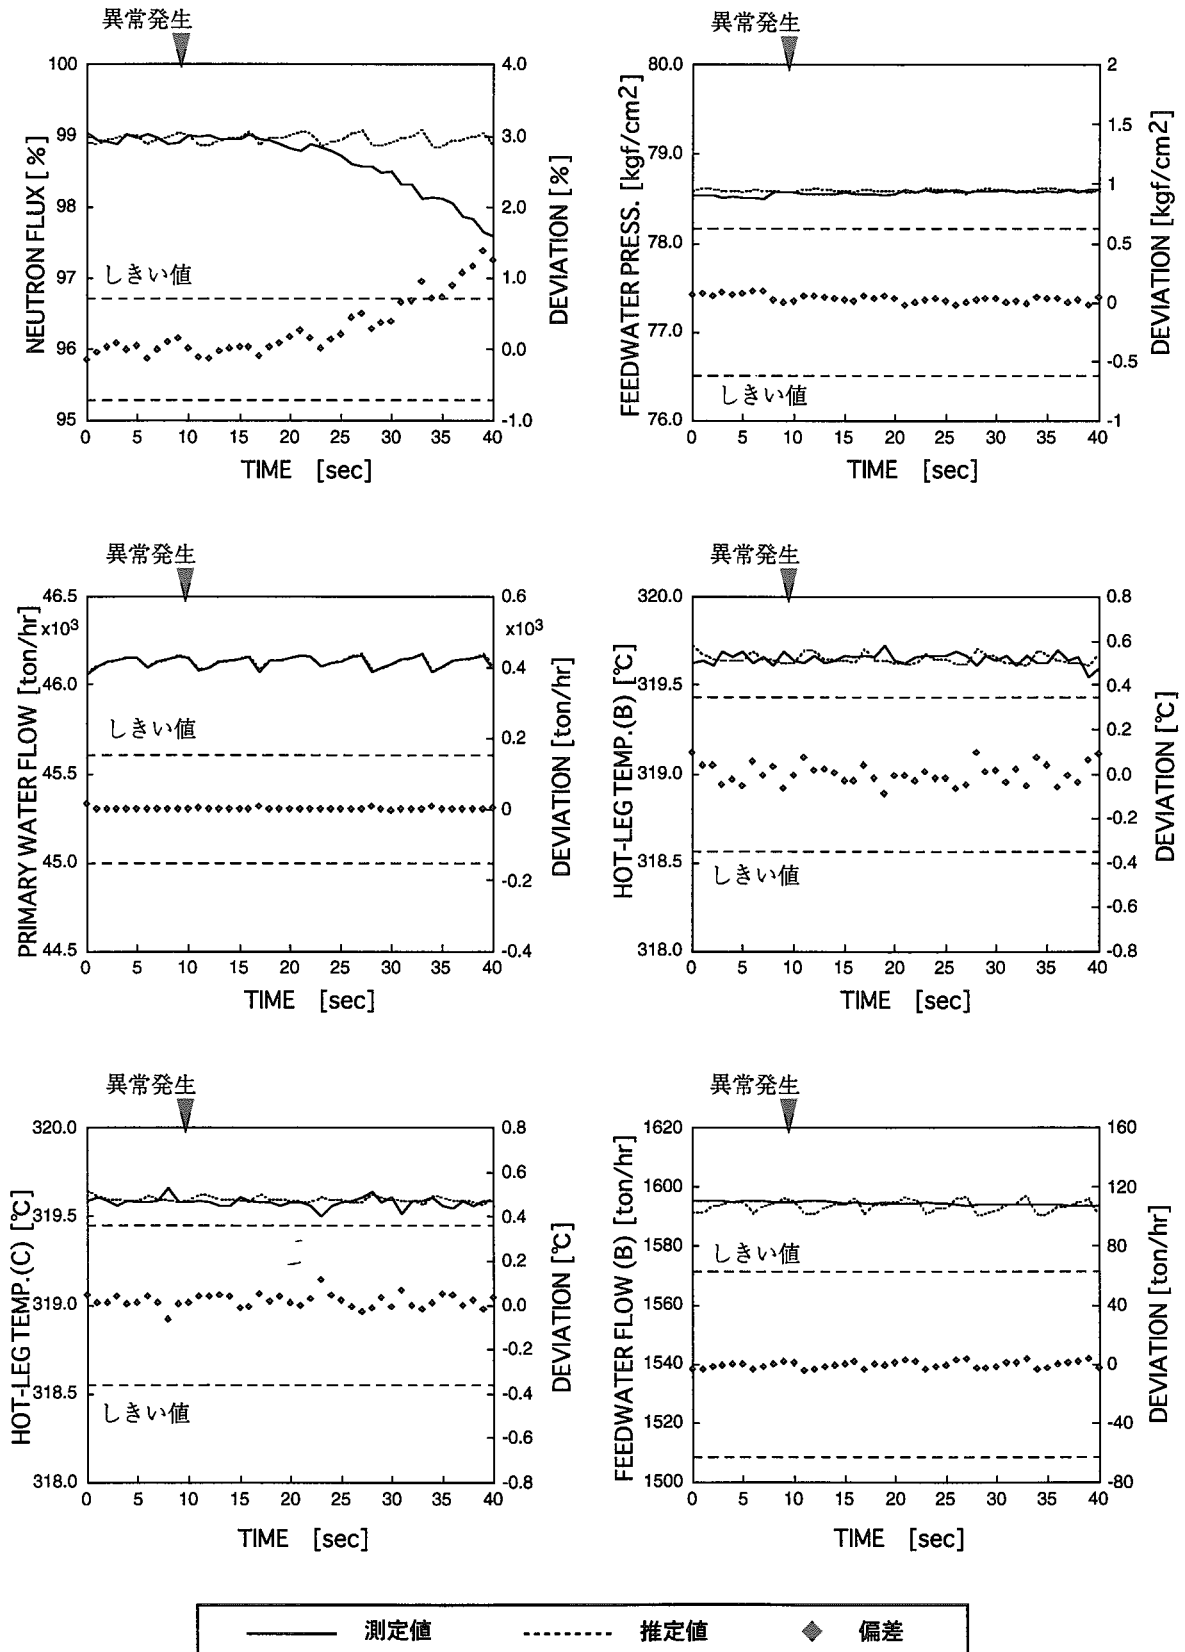


図3-12(a) 体積制御タンク低水位誤検知時の応答 (0-40秒)

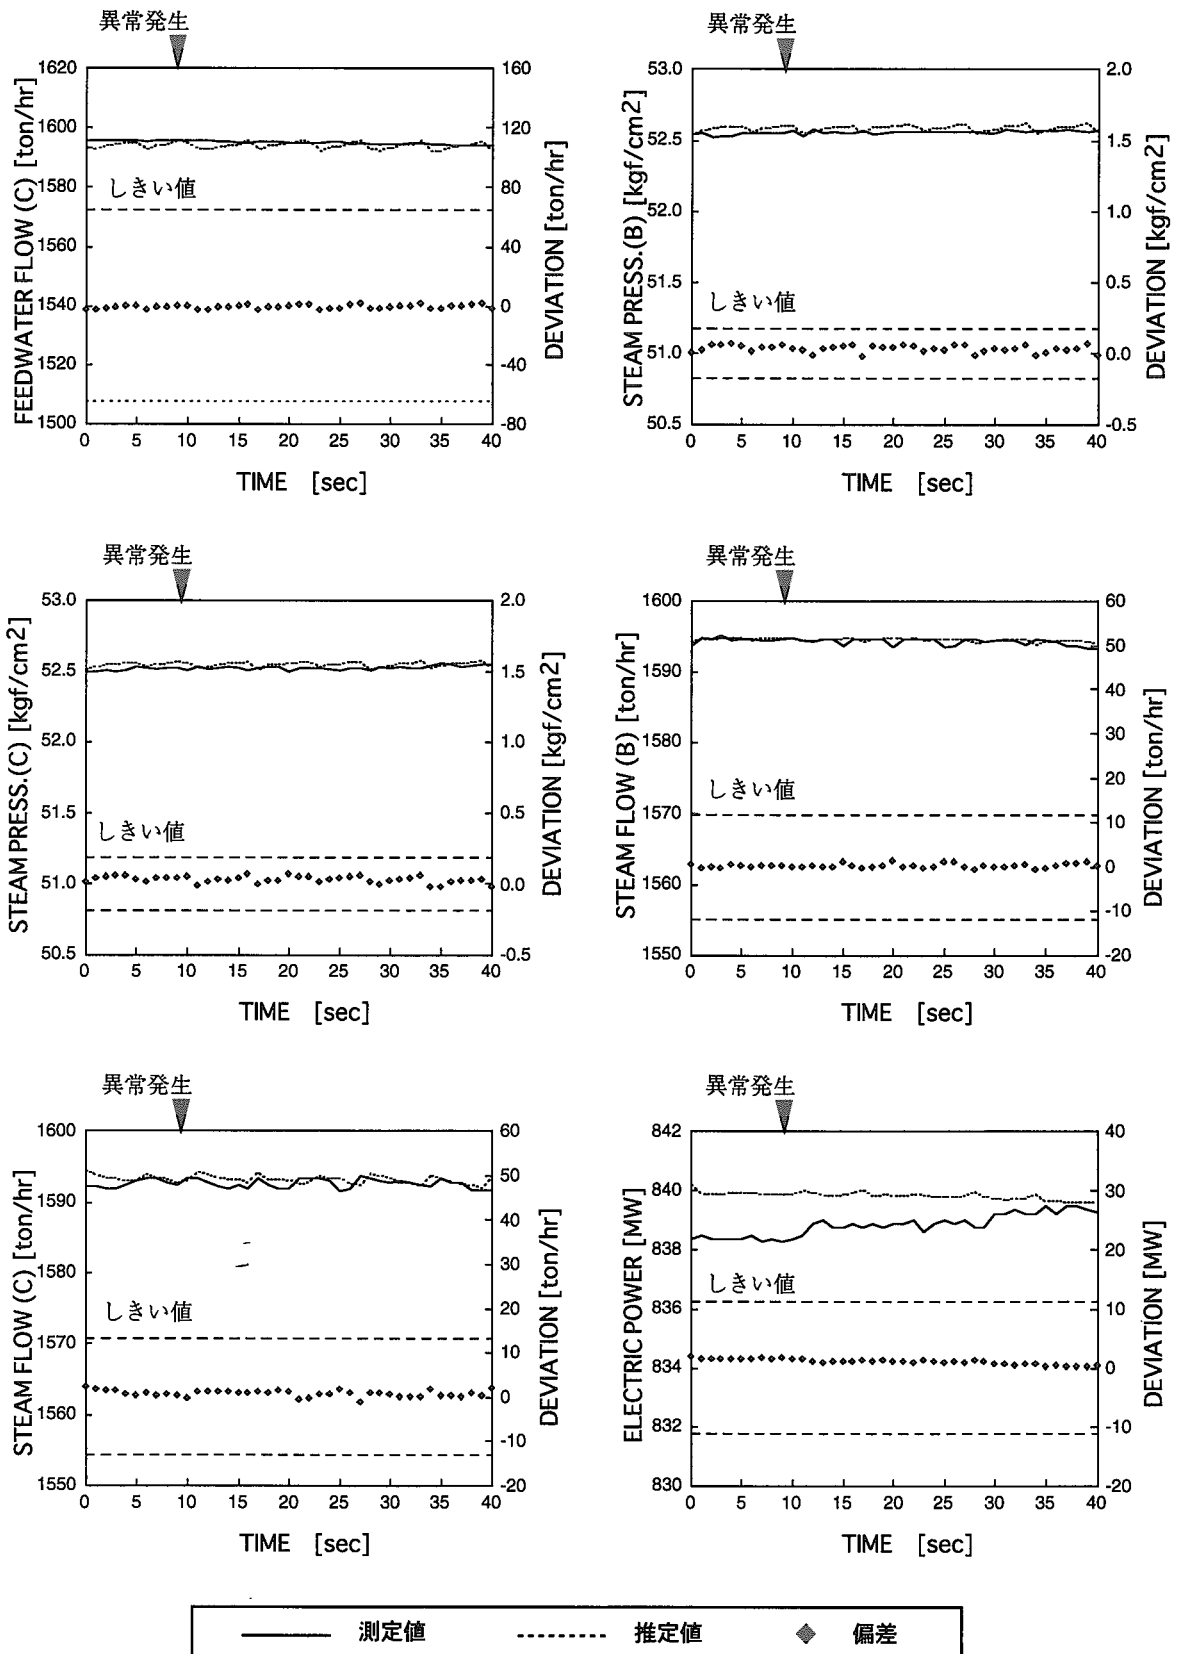


図 3 - 1 2 (b) 体積制御タンク低水位誤検知時の応答 (0-40秒)

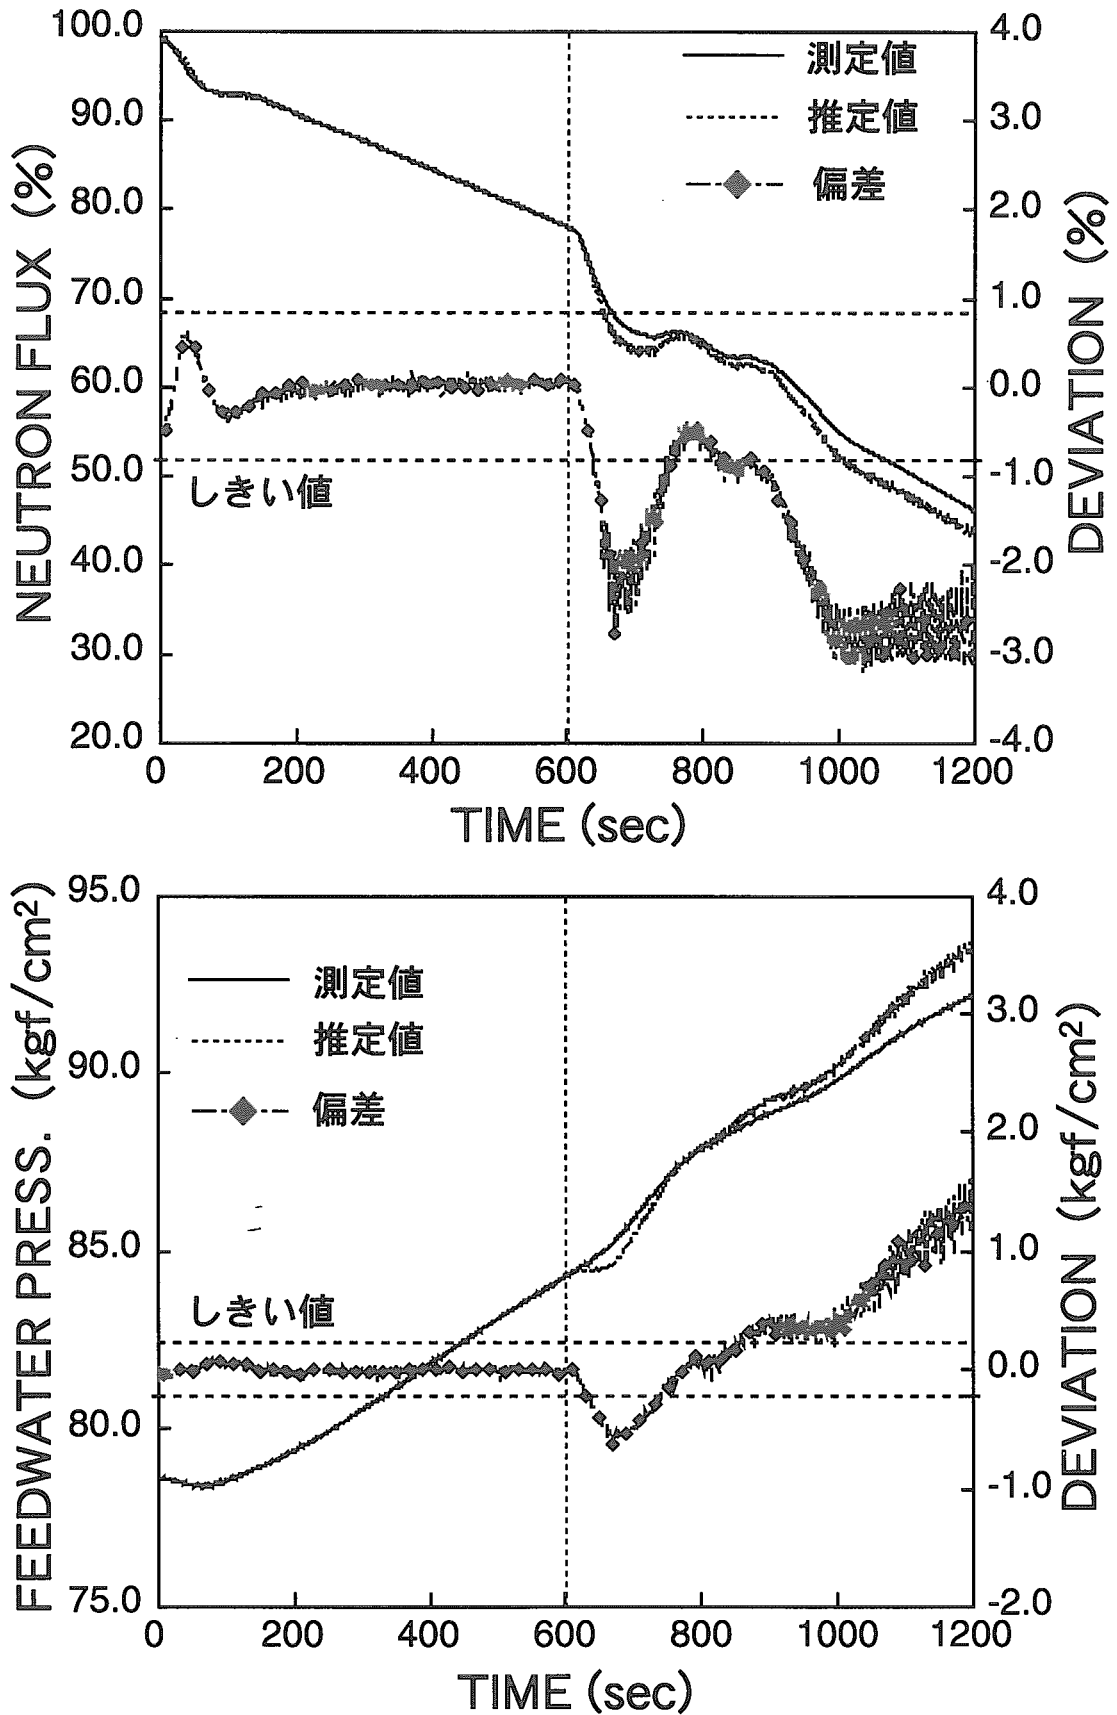


図3-13 過渡運転時の異常検知結果 (体積制御タンク低水位誤検知)





図3-14 過渡運転時の適応学習効果 (体積制御タンク低水位誤検知)

第4章 適応学習付フィードフォワード型ニューラルネットワーク

による異常検知手法の検証 2

—実プラントへの適用—

本章では、オランダにある実際の原子力プラント Borssele 炉のために、ニューラルネットワークを利用したオンラインプラント監視システムを構築し、異常検知に適用した結果について報告する。

4.1 Borssele 炉の概要

今回対象にしたプラントは、オランダ南西部 Zeeland 州のスヘルデ西河口付近にある NV EPZ 社（南オランダ電力会社）の Borssele 原子力発電所である。この原子炉は、電気出力 47 万 kW の加圧水型炉 (PWR) で、二次系は 2 ループからなっている。表 4-1 に Borssele 炉の主要なプラントパラメータを、図 4-1 に簡単なプラント図を示す。

発電所内に設置されているデータ収録システムは、220km 離れたオランダ北西部のオランダエネルギー研究センター (ECN) にある監視用コンピュータまで、電話回線を利用してオンライン接続されている。常時、32 種類のプラント DC 信号 (1 秒間隔) と 8 種類の AC 信号 (サンプリング周波数 64Hz) を合わせたデータブロックが、4 秒毎に転送されている¹⁹⁾。この収録システムは、運転状態によって、収録する信号の種類を ECN から遠隔操作で変更することが可能になっている。表 4-2 及び表 4-3 は、燃料サイクル初期及び中期に収録された DC 信号の一覧である。今回の異常監視には、32 種類の DC 信号の中からプラント状態を把握するのに重要で、かつ同一燃料サイクル内で変更することなく常時収録されている 14 種類の信号 (表中の太文字) を使用した。

ECN においては、長年にわたり炉雑音解析を主とした異常診断システムが構築され、これまでに数々の成果を挙げてきた。しかしながら、このシステムによる診断は、オフラインで 1 日に 1 回行われるだけなので、異常発生後の解析には有効であるが、緊急時には対応できないという欠点があった。そのため、リアルタイムで、しかも自動的に異常診断を行うシステムの開発が必要とされていた。そこで今回、ニューラルネットワークを利用した原子炉のリアルタイム異常監視システムの開発を行い、オフライン及びオンラインでの解析を実施した。

4.2 Borssele 炉のモデル化

使用したニューラルネットワークは、3層構造のフィードフォワード型で、図4-2に示されるような12入力12出力のオートアソシアティブ（自己連想型）ネットワークである。オートアソシアティブネットワークでは、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。ここでは選択された12個の入力は、Borssele 炉から送られてくる32チャンネルの信号の中で、もっとも重要だと考えられるプラントパラメータである。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比較的容易であると考えられたからである^{20),21)}。

第3章でも述べたように、オートアソシアティブネットワークを使用してモデル化を行う場合、自己相関が強くなりすぎる危険性が指摘される。しかし、第6章に示されているように、今回のネットワークでも、各信号の自己寄与率は20%以下となっており、適切なモデル化が行われていることが証明されている。

4.3 リアルタイムプラント監視システムの構築

本監視システムの構成を図4-3に示す。ニューラルネットワークプログラムがインストールされているワークステーションは、Borssele 炉のオンラインデータ収録装置からプラントデータを受け取り、異常診断を開始する。原子力発電所から4秒毎に送られて来る32チャンネルのプラント信号のうち、14変数がニューラルネットワークの入力として取り込まれる。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ため、もしこれまで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。

監視結果は図4-4の様なプラント画面と共にオンライン表示され、同時にオフラインプロット用のファイルが作成される。また、異常を検知した場合には、別のスクリーンにエラーメッセージが表示されると共に、エラーメッセージのログファイルも自動的に作成されるため、後日、異常事象の詳細な解析に役立てられる。

表4-4は、1年間の第19期燃料サイクルの中で、本監視システムに使用した運転データ25ケースの一覧であり、原子炉の起動、定常運転、停止及び異常データを含んでいる。表中のData Nameは、以下で使用する運転データの識別名であり、Timeは運転時間、 ΔT はオフラインプロット用に保存されたデータセットの時間間隔であり、実際にオンラインで適用する場合の時間間隔は4秒（ただし、B19404Aのみは2秒）である。またModeは、

ニューラルネットワークで使用するモード（初期学習、テスト、適応学習等）を表している。Blocks はオフラインデータのパターン数である。

これらのデータのうち、14番目のB19270以降は、オンラインでの運用を試みた。

4.4 初期学習

ニューラルネットワークは、初期学習において広範囲な学習データを必要とする。その大きな理由は、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は十分な性能を示すが、外挿は不得意である。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。今回用いたフィードフォワード型ネットワークの場合には、30%から100%出力までの運転データをランダムな順序で1500回ずつ学習させて、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。

実際の初期学習では、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させた。原子炉起動データ(B19068A)は、出力を約30%から100%まで13時間かけて上昇させたもので、学習パターン数は1375である。定常運転データ(B19106A)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、300パターンから成っている。原子炉停止データは、正確には3時間かけて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150となっている。これらの全学習データ1825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。この初期学習に要した時間は、VAX- α 計算機で約4分であった。

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しておく。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、定常運転時に不規則的に行われる。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。

また、電気出力が100MWe以下の場合の運転データは、学習の範囲から除外した。その理由は、低出力運転時は、運転モードによってプラントの状態が大きく異なるため、一概的なモデル化が困難であるからである。たとえば、出力上昇運転時には、出力が100MWeに達するまでタービンを作動しないが、原子炉の停止時には、100MWe以下の低出力になっても

タービンは動作している。

図4-5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、横軸は学習データのパターン数、縦軸（左）はそれぞれの信号値、縦軸（右）は偏差の値である。図中の実線は測定値、○は推定値を表しており、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だと考えられる。図中中央付近の実線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、異常判定時のしきい値を設定する際に参照される。

4.5 初期値の設定

ニューラルネットワークのユニット間の重み及びユニット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、ユニットしきい値の初期値は-1.0~1.0の範囲内の乱数値から始められる。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状態から始まり、最終的に学習が収束した時の重み等も全く異なっているが、収束時の学習誤差はほとんど同じ値になっており、異常検知性能にも目立った差異は見られない。これは、ニューラル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モデルの精度に影響を与えないことを示している。

4.6 隠れ層のユニット数

隠れ層（中間層）のユニット数の最適化は、ニューラルネットワークの研究の中でも重要な課題の一つである。なぜなら、学習時間を短縮する上で、なるべく隠れ層のユニット数を少なくすることが望ましいからである。また、隠れ層が多すぎると逆にテスト誤差が増加する傾向にあることも指摘されている。今回の適用例では、初期学習において隠れ層のユニット数を変化させ、その時の誤差の二乗和を比較した。図4-6に示されるように、ユニット数が6個以下の場合には初期学習の誤差が大きくなり、収束しなかった。したがって、この原子炉のモデル化には、隠れ層のユニットが最低7個以上必要となる。隠れ層ユニット数が7から45個の間では、ユニット数の増加とともに誤差の二乗和は小さくなっていく。隠れ層が8、20、45個の場合の、学習誤差の推移を図4-7に示す。隠れ層のユニット数が少ないほど、学習の収束が早いことが明らかである。

また、表4-5は、初期学習後の3つのネットワークで、B19178A及びB19222Aの異常診断を行った際の、異常検知ポイントを示している。隠れ層ユニット数は多くなると、学習誤差も小さくなるので、それに伴い異常判定しきい値も厳しくなる。しかし、この表か

ら明らかなように、隠れ層ユニット数の異なる3つのネットワークで、その検知性能に目立った差異は見られなかった。したがって、実時間で使用する際の適応学習時間をなるべく少なくするために、今回は8個の隠れ層ユニット数を持つニューラルネットワークを採用した。ここで必要最小限の隠れ層ユニットより1ユニットだけ多くした理由は、初期学習の後に新たな運転パターンを再学習する可能性を考慮して、ネットワーク構造に余裕を持たせるためである。

4.7 学習パラメータの設定

第2章(2.6)式中の学習率(η)及びモーメンタム項の係数(α)は、学習速度と収束率に大きな影響を与えるため、その設定には十分な注意が必要である。一般的に、これらの係数を大きくすると学習速度は速くなるが、学習が収束しない可能性も出てくる。一方、これらの係数を小さくすると、収束に時間がかかる。入出力データを0~1で規格化している場合には、一般的に、 η や α の値は0.1程度に設定されている例が多い。また、これらの係数を、学習の進行とともに大きく、あるいは小さくしていくと、学習が速く収束する例もいくつか挙げられているが、一般的には学習率を小さくしていく方法が有効であると言われている。いろいろな学習パラメータを採用した場合の最終的な誤差の二乗和を表4-6に示す。その中で今回は、No.11に示されるように、学習回数が150回までは η を1.2、 α を0.6に、151回から300回までは η を0.6、 α を0.3に、そして301回から1500回までは η を0.1、 α を0.1にと、段階に小さくして学習させたネットワークを、実際の異常検知に利用した。しかしながら、その後の詳細なパラメータサーベイの結果、No.12の場合が、もっとも学習誤差が小さくなることが明らかになった¹⁸⁾。

このように学習パラメータの異なるネットワークを使用して、実際の運転データをテストした結果、異常検知性能にほとんど違いは見られなかった。しかも、初期学習誤差が小さくなりすぎると、それに伴い異常判定のしきい値も小さくなるため、しきい値の係数を現在の1.25より大きくする必要が出てくる。また、学習誤差が信号自身のノイズ成分よりも小さくなれば、当然誤報の確率は大きくなると考えてよい。したがって、学習パラメータや隠れ層の数などを最適化し、初期学習誤差を小さくしたネットワークが必ずしも異常検知に有効であるとは一概には言えない。

4.8 しきい値の設定

初期学習の結果をもとにして、監視の際にプラントが異常であるかどうかの判定基準となるしきい値の設定を行う。しきい値は、初期学習の際に得られた各チャンネル毎の最大誤差の1.25倍と定義されている。ここで、係数1.25倍は、経験的に得られた値であり、この値より小さく設定した場合には、正常運転時においても頻繁に異常を誤検知した。

また、今回の例では、全ての信号において、初期学習時の最大誤差 (ϵ) が、定常運転時における標準偏差の2倍の値 (2σ) より大きくなった。実際の異常診断に用いられた各信号のしきい値を表4-7に示す。

以上のように、隠れ層のユニット数、重み等の初期値、学習パラメータ等の違いによって、最終的に到達する学習の収束状態は異なってくる。したがって、当然しきい値も異なってくるが、各信号のノイズ成分の大きさを考慮して、初期学習時の最大誤差が3%以下になれば、原子炉の異常診断に十分に利用できることが明らかになった。

4. 9 適応学習の効果

原子炉は約1年間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ていくため、燃料サイクル初期と末期におけるプラント特性は大幅に異なってくる。適応学習は、このゆっくりと変化するプラントの状態にフィードフォワード型ニューラルネットワークのモデルを追従させていく上で、必要不可欠なアルゴリズムである。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。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、正常と判断、さらにその最新のデータを使って適応学習を行い、ネットワーク内部の重みやしきい値を少しずつ更新していく。この際の学習率(η)及びモーメント項の係数(α)は、初期学習時に比べて小さい値(実際例: $\eta=0.005, \alpha=0.005$)が設定された。なお、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。今回の計算では、計算機の処理時間がデータ受信間隔の4秒以内になるよう、過去30点のデータを適応学習に使用した。一方、どれか一つでも信号誤差がしきい値を超えた場合、適応学習は行わず、どの信号が異常であるかのメッセージを出力して、次に送られてくるデータの診断に進む。

ニューラルネットワークで実際のプラント診断を開始した場合、適応学習を行わないと1週間以内にプラント状態の変化に追従することができなくなり、正常運転時においても異常警報を発することが明らかになった^{22), 23)}。

4. 10 ニューラルネットワークによる監視結果

4. 10. 1 出力上昇運転時(B19170A2)の監視結果

初期学習後の最初のテストデータは、出力390MWから475MWへの出力上昇運転データで、初期学習で使用した出力減少運転データの直後のものである。このデータは16秒間隔でサンプリングされパターン数は200点である。図4-8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、横軸のブロック数は4秒間隔のデータNo.、縦軸(左)

はそれぞれの信号値、縦軸（右）は偏差の値を示している。この図から明らかなように、ネットワークは原子炉の動特性を正確に推定し、監視した12個のプラント信号の測定値（実線）とニューラルネットワークによる推定値（○）の偏差（実線）は、ほとんどしきい値の範囲内にある。以上の結果はこの出力上昇が通常の運転状態であり、しかも異常事象も全く無いことを示している。同時に、この運転データは適応学習され、ネットワークの重みやしきい値を徐々に更新していく。

4. 1 0. 2 同位相リンシング運転時(B19178A)の監視結果

図4-9に、100%定常出力時に行われた同位相リンシング運転のテスト結果を示す。このタイプのリンシング運転は既に初期学習において学習されているので、偏差はしきい値よりも小さく、異常は検知されない。

4. 1 0. 3 逆位相リンシング運転時(B19222A)の監視結果

定常運転時におけるリンシング（逆位相）のデータのテスト結果を図4-10に示す。逆位相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の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。

ここで、注目すべき点は、このリンシング運転の逆位相現象を運転員は認識しておらず、また従来の警報システムもアラームを発していないことである。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、微小な異常兆候を検知するだけでなく、どの信号が異常であるかも的確に判定できるため、異常事象の原因を突き止める際にも非常に有効な手段になり得ると考えられる。

また、逆位相リンシング運転の後に、別の小規模なリンシング運転が見られるが、この運転は同位相リンシングであるため、異常は検知されない。なお、逆位相リンシング運転区間を除いて正常だと判断された運転データは、常に適応学習に用いられる。

4. 1 0. 4 炉停止運転時(B19268N1)の監視結果

この運転では、480MWから260MWまで、3段階に分けて急激に出力を減少させており、その出力減少幅が急な部分で多くの信号に鋭いピークが見られ、ニューラルネットワークもそれらの点で異常を検知した。図4-11に示された結果から、これが緊急な炉停止で

あったことがわかる。

4. 1 0. 5 起動運転時(B19270A)の監視結果

原子炉の再立ち上げを行ったこの運転以降、実際にニューラルネットワーク監視システムをオンラインで適用した。結果を図4-12に示す。この図中で、横軸のブロック数は30秒間隔のデータ No. を表している。

この起動運転中、ニューラルネットワークは常にプラントが異常であると判定した。その理由として、この運転が急激な炉停止の後に行われたために、ネットワークが初期学習した燃料初期の起動運転と動特性が大きく異なることが考えられた。そこで、オフラインでこのデータを含めた初期学習を行い、プラントの特性にネットワークモデルを追従させた後、テストを再開した結果、偏差は小さくなった。しかし後日、このエラーは、原子炉サイトの運転員が、こちらに知らせることなく検出器のキャリブレーションを行ったためであることが判明した。このように、人為的に運転条件を変更された場合には、これまでのニューラルネットワークを適用できず、あらためてオフラインでの初期学習を必要とすることが、今後の課題である。

4. 1 0. 6 ストレッチアウト運転時(B19393S1)の監視結果

「ストレッチアウト」運転とは、燃料サイクル末期に行われる運転モードで、主にヨーロッパやアメリカで、発電所の経済効率を高めるために行われる。最終炉停止直前の原子炉は、ポロンによる制御が不可能で、しかも制御棒は完全に引き抜かれている状態になっている。もはや正の反応度になるほどの燃料は残っていないため、原子炉の熱出力は次第にゆっくりと減少していくことになる。この運転モードによって、数週間にわたって炉出力を引き延ばすことができるので、燃料交換の時期を予定されたスケジュール通りに調整することが可能となる。

この運転モードの初期において、ニューラルネットワークは2次系圧力信号等で異常を検知した。これまでの運転では、通常、100%出力から電気出力や蒸気流量が下がると、2次系圧力信号は増加する傾向にあった。例えば、初期学習で使用したB19170Aでは、出力が20MWe下がると、蒸気圧力は2 ata増加する。ところが、ストレッチアウト運転モードでは、出力の減少とともに圧力信号も減少する傾向にある。ニューラルネットワークはこの現象を全く学習していないので、当然の事ながら偏差が大きい値を越えてしまう。そこで、図4-13の様に、最初の300分間のデータを大きなしきい値に変更して強制的に適応学習させ、偏差を小さくした後、テストを再開した。その結果、次のストレッチアウト運転でも、偏差は小さくなっている。なお、この図中の横軸のブロック数は、プロット用に1分間隔のデータ No. を表しているが、実際のデータは4秒間隔で送られてきてい

る。

4. 1 0. 7 最終炉停止時(B19404A)の監視結果

この運転データは、第19期燃料サイクルの最後の炉停止時のもので、この直後、原子炉は燃料交換及び定期点検に入る。図4-14から明らかなように、ストレッチアウト運転後、100%から徐々に出力を下げている。また、その間にコンデンサのリンシングを試みているが、この場合には逆位相のリンシング運転になっている。この図中で、横軸のブロック数は1分間隔のデータ No. を表しているが、実際のデータは2秒間隔で送られている。また、実線は測定値、点線はニューラルネットワークによる推定値、一点鎖線は2つの値の偏差を表しており、この偏差がしきい値の範囲を超えた場合にプラントが異常であると判定する。

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、流量等が異常であるという診断を行っている。図4-15は、リンシング運転時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、400分過ぎに二次系圧力信号等の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、正常なリンシング運転の場合、No.2ループの蒸気圧力はNo.1ループと同じ挙動になるべきであることを示しており、したがってNo.2ループの偏差が大きくしきい値を超えている。また、No.1ループの蒸気圧力信号の偏差は、同じようにしきい値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。

さらに低出力運転になると、全ての信号の偏差がその許容範囲を超えた。これは、ニューラルネットワークがプラントの異常を検知したからではなく、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からで、前述のようにニューラルネットワークはモデルの外挿が不得意であることに起因する。したがって、これ以降の低出力運転は、監視の対象外になる。

4. 1 1 まとめ

ニューラルネットワークを用いたプラント監視システムを構築し、実際の原子炉に適用した。その結果、ニューラルネットワークは従来の監視システムや運転員が気づかないような微小な異常兆候を検知できることが明らかになった。同時に、実際の原子炉に適用する場合には、適応学習が不可欠であり、しかも有効に動作することが示された。

この監視システムは、1997年2月に原子炉の大幅な改造工事のために長期間

Borssele 炉が停止するまでの数年間、原子力プラント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常時稼働しており、原子炉の異常予知診断に役立っていた。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に適用できる可能性を十分に示したと言える。

現在は、ニューラルネットワークに実時間エキスパートシステムを組み合わせ、異常検知だけでなく、異常診断も含めた総合的な原子炉監視システムを構築中である^{24), 25)}。

表4-1 Borssele 炉の主要プラントパラメータ

Electric power rating	477 MW
Thermal power rating	1370 MW
Number of fuel assemblies	121
Active core height	2.65 m
Core diameter	2.68 m
U235 enrichment: 41 assemblies =	2.5 %
40 assemblies =	2.8 %
40 assemblies =	3.1 %
Prompt neutron lifetime	2.2×10^{-5} s
Delayed neutron fraction	0.007
Coolant inlet temperature	295.4 °C
Coolant outlet temperature	319.4 °C
Core coolant flow rate	9200 kg/s
Average core coolant flow velocity	4.28 m/s
Water volume	8.937 m ³
U-tubes	4234
Mass of water per SG	26289 kg
Mass of steam per SG	2663 kg

表4-2 プラント信号リスト (第19期燃料サイクル初期)

Raw Data File. : B19068A1.FRM			
Type of the data set : Power Increase B19 ; B3 Power 110 --> 380 MWe			
Date : June 10, 1992, ST: 19:43 - 08:36 (13 hr)			
Identification number: B19068A1.FRM 1-11589 Block (every 4 block)			
Patterns : original 2898 (Time interval 16 sec)			
Channel Nr.	Signal Identification	Code	Units
1	Excore	D82	mV
2	Excore	D62	mV
3	Excore	D72	mV
4	Excore	D52	mV
5	Pressure Primary Loop 1	YA01-P002	kgf/cm ²
6	Pressure Primary Loop 2	YA02-P002	kgf/cm ²
7	SG1, Feed Water Pressure	RL40-P001	kgf/cm ²
8	SG2, Feed Water Pressure	RL50-P001	kgf/cm ²
9	Incore neutron detector	IN23-11	mV
10	Incore neutron detector	IN23-12	mV
11	Incore neutron detector	IN23-13	mV
12	Incore neutron detector	IN23-14	mV
13	Incore neutron detector	IN23-15	mV
14	RCS Cold Leg Temperature Loop 1	YA01-T090	°C
15	RCS Hot Leg Temperature Loop 1	YA01-T098	°C
16	RCS Cold Leg Temperature Loop 2	YA02-T090	°C
17	RCS Hot Leg Temperature Loop 2	YA02-T098	°C
18	SG1, Feed Water Flow	RL40-F001	T/h
19	SG2, Feed Water Flow	RL50-F001	T/h
20	Axial Vibrations, Coolant Pump 1	YD01-V004	mm/s
21	Axial Vibrations, Coolant Pump 2	YD02-V004	mm/s
22	Radial Vibrations, Coolant Pump 1	YD01-V003	mm/s
23	Radial Vibrations, Coolant Pump 2	YD02-V003	mm/s
24	SG1, Steam Pressure	RA01-P001	kgf/cm ²
25	SG2, Steam Pressure	RA02-P001	kgf/cm ²
26	SG1, Steam Mass Flow	RA01-F001	T/h
27	SG2, Steam Mass Flow	RA02-F001	T/h
28	Pressurizer Pressure	YP01-P001	kgf/cm ²
29	Generated Electric Power	GEP	MWe
30	Control-Rod Bank,	D-Bank	Step
31	Control-Rod Bank,	L-Bank	Step
32	Boron Concentration	(parts per million)	PPM

表4-3 プラント信号リスト (第19期燃料サイクル中期)

Raw Data File. : B19290A.FRM			
Type of the data set : Stationary operation core B19 ; B3 Power 480 --> 430 --> 480 MWe			
Date : November 30, 1992, ST: 22:59 - 04:49 (6 hr)			
Identification number: B19290A.FRM 1-5249 Block (every 4 block)			
Patterns : original 1313 (Time interval 16 sec)			
Channel Nr.	Signal Identification	Code	Units
1	Excore	D82	mV
2	Excore	D62	mV
3	Excore	D72	mV
4	Excore	D52	mV
5	Pressure Primary Loop 1	YA01-P002	kgf/cm ²
6	Pressure Primary Loop 2	YA02-P002	kgf/cm ²
7	SG1, Feed Water Pressure	RL40-P001	kgf/cm ²
8	SG2, Feed Water Pressure	RL50-P001	kgf/cm ²
9	Differential Pressure Pump 1	YA01-P003	kgf/cm ²
10	Differential Pressure Pump 2	YA02-P003	kgf/cm ²
11	SG1, Water Level	YB01-L001	cm
12	SG2, Water Level	YB02-L001	cm
13	Incore neutron detector	IN23-13	mV
14	RCS Cold Leg Temperature Loop 1	YA01-T090	°C
15	RCS Hot Leg Temperature Loop 1	YA01-T098	°C
16	RCS Cold Leg Temperature Loop 2	YA02-T090	°C
17	RCS Hot Leg Temperature Loop 2	YA02-T098	°C
18	SG1, Feed Water Flow	RL40-F001	T/h
19	SG2, Feed Water Flow	RL50-F001	T/h
20	Axial Vibrations, Coolant Pump 1	YD01-V004	mm/s
21	Axial Vibrations, Coolant Pump 2	YD02-V004	mm/s
22	Steam Temperature Loop 1	RA01-T011	°C
23	Steam Temperature Loop 2	RA02-T011	°C
24	SG1, Steam Pressure	RA01-P001	kgf/cm ²
25	SG2, Steam Pressure	RA02-P001	kgf/cm ²
26	SG1, Steam Mass Flow	RA01-F001	T/h
27	SG2, Steam Mass Flow	RA02-F001	T/h
28	Pressurizer Pressure	YP01-P001	kgf/cm ²
29	Generated Electric Power	GEP	MWe
30	Feed Water Temperature Loop 1	RA01-T011	°C
31	Feed Water Temperature Loop 2	RA02-T011	°C
32	Boron Concentration	(parts per million)	PPM

表4-4 第19期PWR運転データ一覧

No.	Data Name	Power Change	Operation	Time	ΔT	Mode ^{*)}	Blocks
1	B19068A1	110 → 380 MW	Power Inc.	13 hr	16s	L	11589
2	B19106A	478 → 464 MW	Rinsing(SP)	2 hr	16s	L	1349
3	B19123A	478 → 450 → 480 MW	Rinsing(RP)	7 hr	16s	T	6001
4	B19126A2	479 → 468 → 478 MW	Rinsing(SP)	2 hr	16s	T	2049
5	B19141A	477 → 461 → 480 MW	Rinsing(SP)	5 hr	16s	T	4497
6	B19170A	470 → 390 MW	Power Red.	3 hr	16s	L	2653
7	B19170A2	390 → 475 MW	Power Inc.	3 hr	16s	R	3001
8	B19178A	476 → 450 → 476 MW	Rinsing(SP)	3 hr	16s	R	3001
9	B19189A1	481 → 440 → 481 MW	Rinsing(RP)	4 hr	16s	T	3597
10	B19222A	481 → 450 → 481 MW	Rinsing(RP)	6 hr	16s	T	5101
11	B19250A	483 → 474 → 483 MW	Rinsing(RP)	5 hr	16s	R	4497
12	B19255A	484 → 450 → 484 MW	Rinsing(RP)	6 hr	16s	T	5249
13	B19268N	480 → 0 MW	Shutdown	1 hr	4s	T	700
14	B19270S2	0 → 450 MW	Start-up	8 hr	1m	L	923
15	B19290A	480 → 430 → 480 MW	Rinsing(RP)	6 hr	16s	T N	5249
16	B19326A	480 → 450 → 480 MW	Rinsing(RP)	5 hr	16s	T N	4501
17	B19330S	478 MW	Stationary	46 hr	1m	T N	2760
18	B19337S	480 MW	Stationary	68 hr	1m	T N	4070
19	B19346S	480 MW	Stationary	40 hr	1m	T N	2391
20	B19380S2	476 → 470 MW	Stretch out	40 hr	1m	T N	2400
21	B19393S1	460 → 456 MW	Stretch out	21 hr	1m	L N	1260
22	B19397S1	453 → 450 MW	Stretch out	24 hr	1m	R N	1467
23	B19401S	443 → 441 MW	Stretch out	22 hr	1m	R N	1340
24	B19403A	440 MW	Before SD	5 hr	16s	R N	4757
25	B19404A	440 → 0 MW	Shutdown	8 hr	16s	R N	14233

*) Mode ;

L = Learning Data

R = Recall (Testing & Adaptive Learning)

T = Testing only

N = On-line Monitoring

表4-5 3つのネットワークによる異常検知結果

Operation Data	Anomaly Detection Points		
	12-8-12	12-20-12	12-45-12
B19178A	121 1569~1605	5~45 1569~1609	21 1569~1613
B19222A	1~121 1897~2441	1~125 1897~2441	1~121 1901~2453

表4-6 学習パラメータによる学習収束度

No	Learning Parameters		Sum of Square Error
	η	α	
1	0.1	0.1	0.3954
2	0.2	0.1	0.2971
3	0.4	0.2	0.2469
4	0.6	0.3	0.2097
5	1.2	0.6	0.1869
6	2.0	1.0	0.1758
7	3.0	1.5	0.1641
8	4.0	2.0	0.2699
9	5.0	2.5	3.5052
10	6.0	3.0	120.5
11	1.2, 0.6, 0.1*	0.6, 0.3, 0.1	0.2513
12	1.8, 1.7, 1.6**	1.7, 1.5, 1.3	0.1625

* $\eta=1.2$ $\alpha=0.6$ (1-150 cycle), $\eta=0.6$ $\alpha=0.3$ (151-500), $\eta=0.1$ $\alpha=0.1$ (501-1500)

** $\eta=1.8$ $\alpha=1.7$ (1-50 cycle), $\eta=1.7$ $\alpha=1.5$ (51-300), $\eta=1.6$ $\alpha=1.3$ (301-1500)

表4-7 初期学習後のネットワークのしきい値

channel No.	signal	symbol	SD*2 2 σ	Max Error during initial learning; ϵ
1	ex-core neutron flux	EX-CORE	7.98	22.14 [mV]
2	feedwater pressure (loop-1)	SG1FWP	0.3095	0.3868 [kgf/cm ²]
3	feedwater pressure (loop-2)	SG2FWP	0.3425	0.4282 [kgf/cm ²]
4	temperature difference between hot-leg and cold-leg (loop-1)	DTL1	0.4419	0.6807 [°C]
5	temperature difference between hot-leg and cold-leg (loop-2)	DTL2	0.4013	0.6615 [°C]
6	feedwater flow (loop-1)	SG1FWF	14.26	25.34 [T/h]
7	feedwater flow (loop-2)	SG2FWF	14.25	33.63 [T/h]
8	steam pressure (loop-1)	SG1SP	0.1815	0.2950 [kgf/cm ²]
9	steam pressure (loop-2)	SG2SP	0.2323	0.2985 [kgf/cm ²]
10	steam flow (loop-1)	SG1SF	11.44	35.04 [T/h]
11	steam flow (loop-2)	SG2SF	14.10	44.91 [T/h]
12	generated electric power	GEP	1.577	8.722 [MWe]

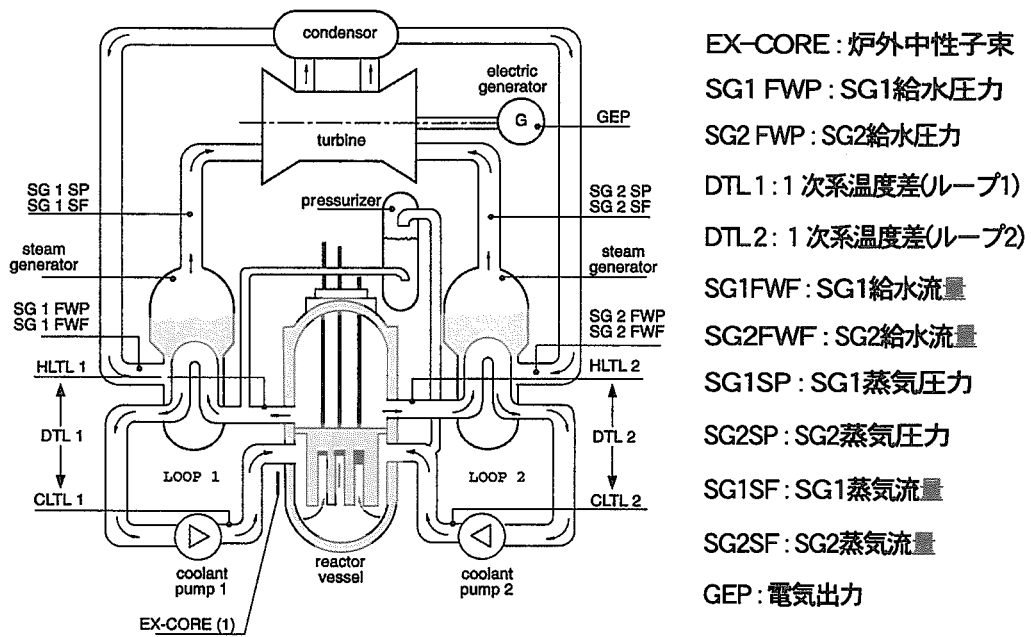


図4-1 Borssele炉のプラント概略図と監視信号

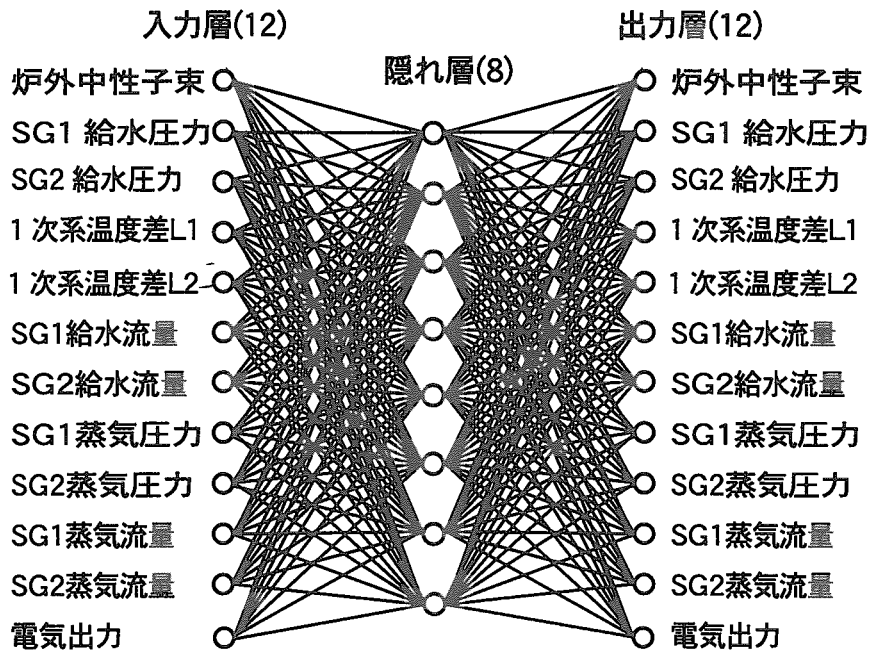


図4-2 オートアソシアティブニューラルネットワークモデル

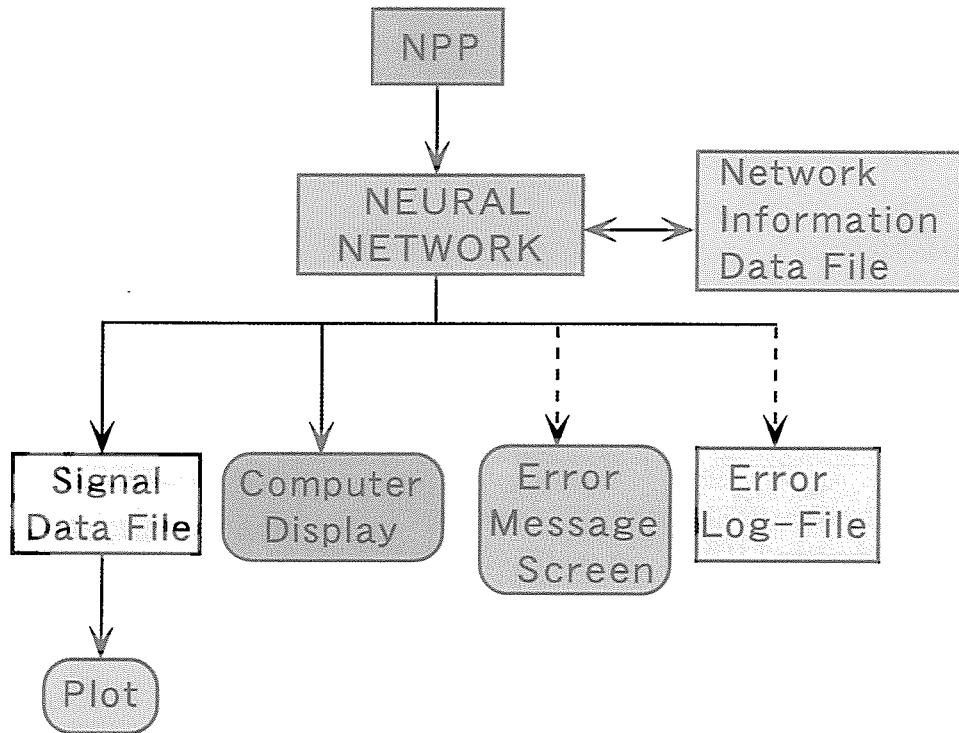


図4-3 監視システム構成図

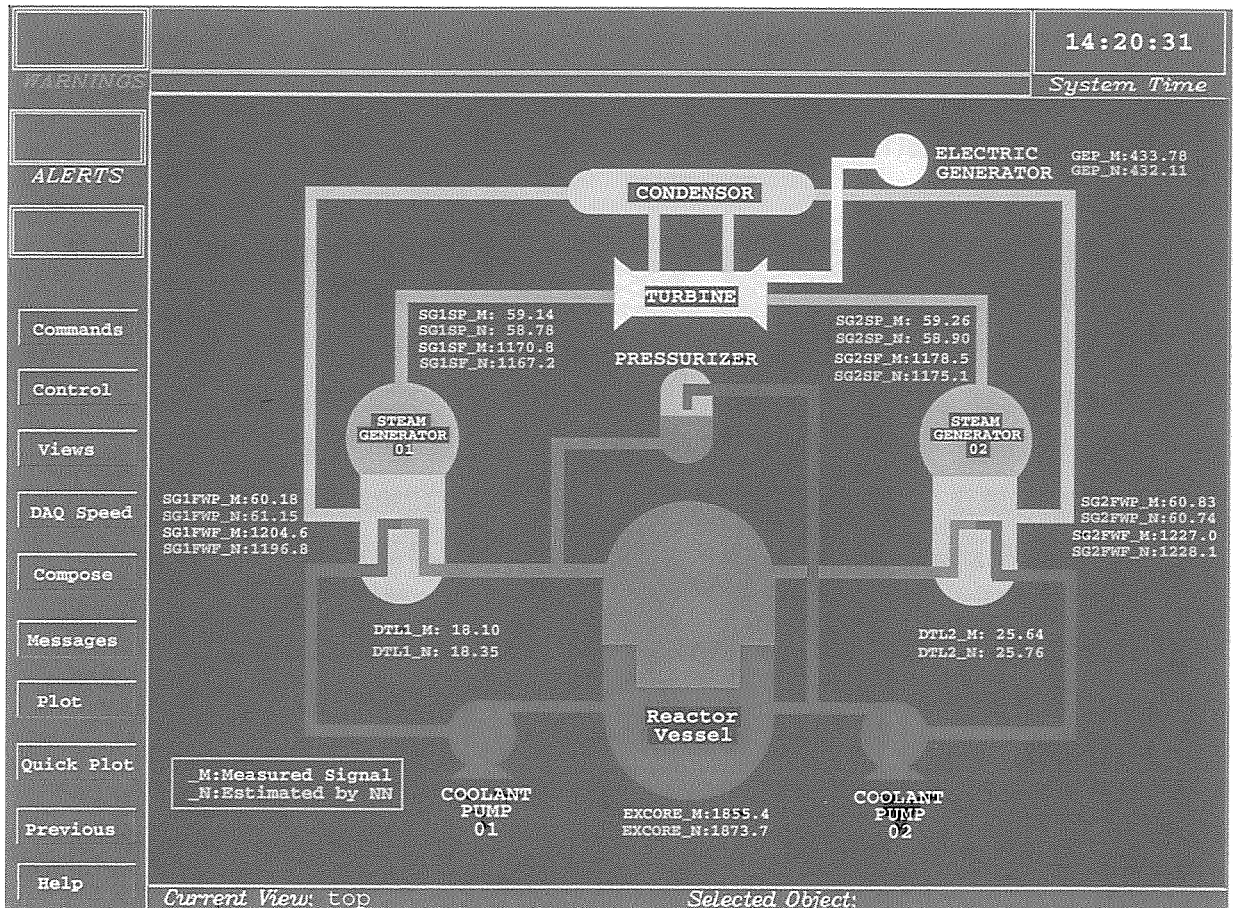


図4-4 オンライン監視画面





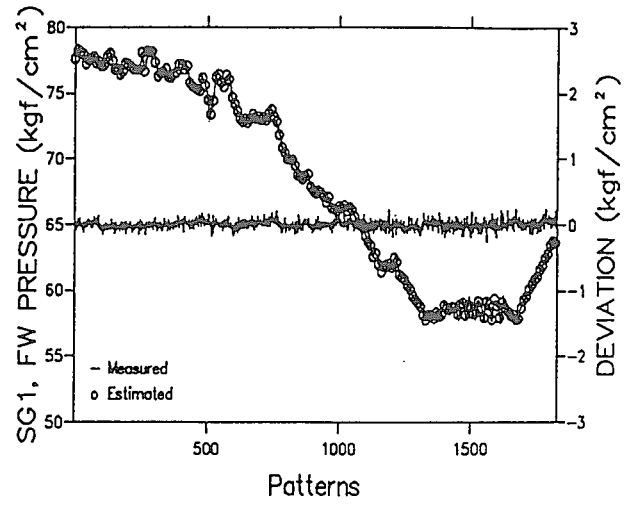



図4-5(a) 初期学習結果

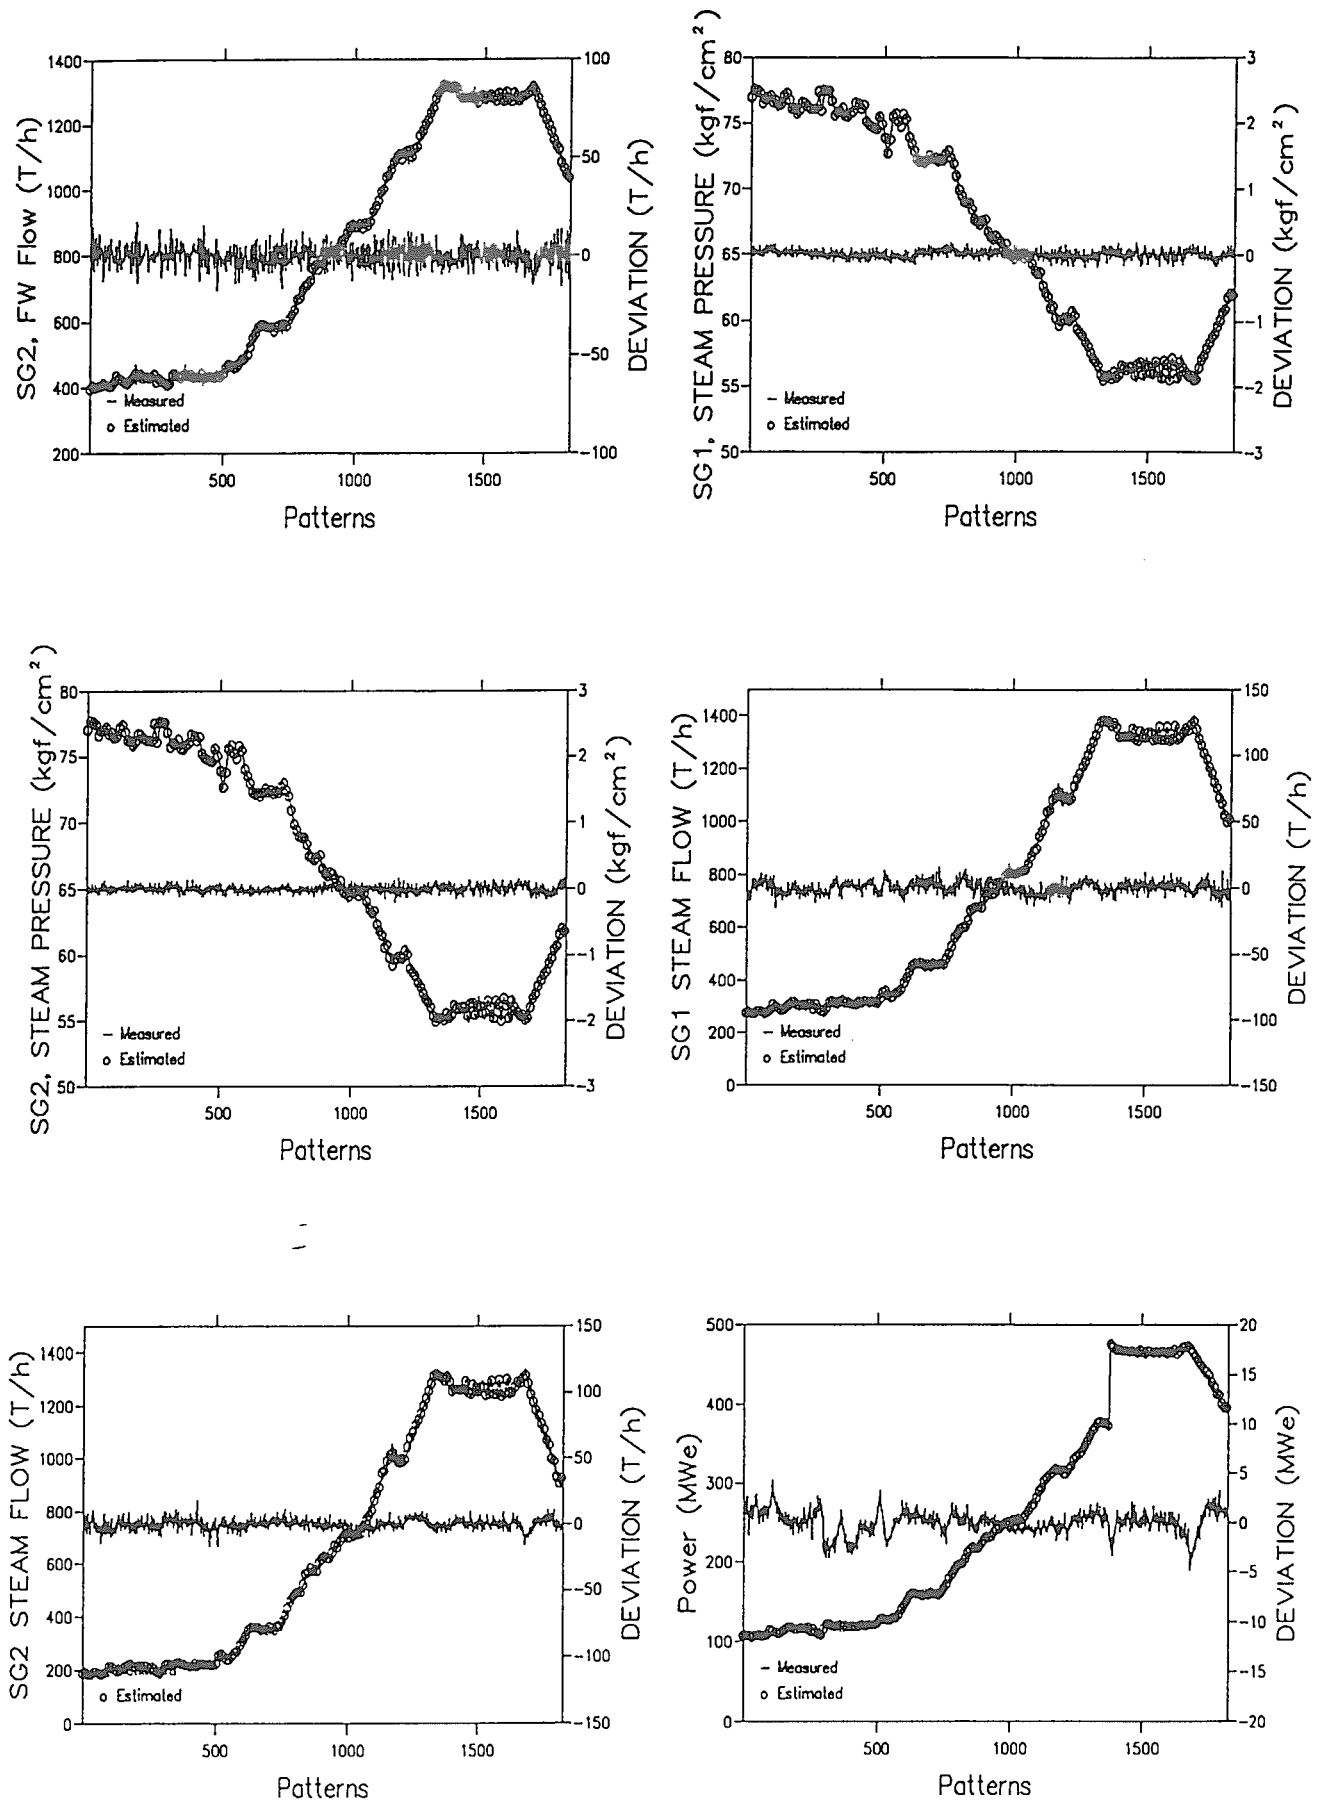


図4-5(b) 初期学習結果 (続き)




図4-6 中間層のユニット数による初期学習の収束誤差




図4-7 ネットワークの学習誤差の推移

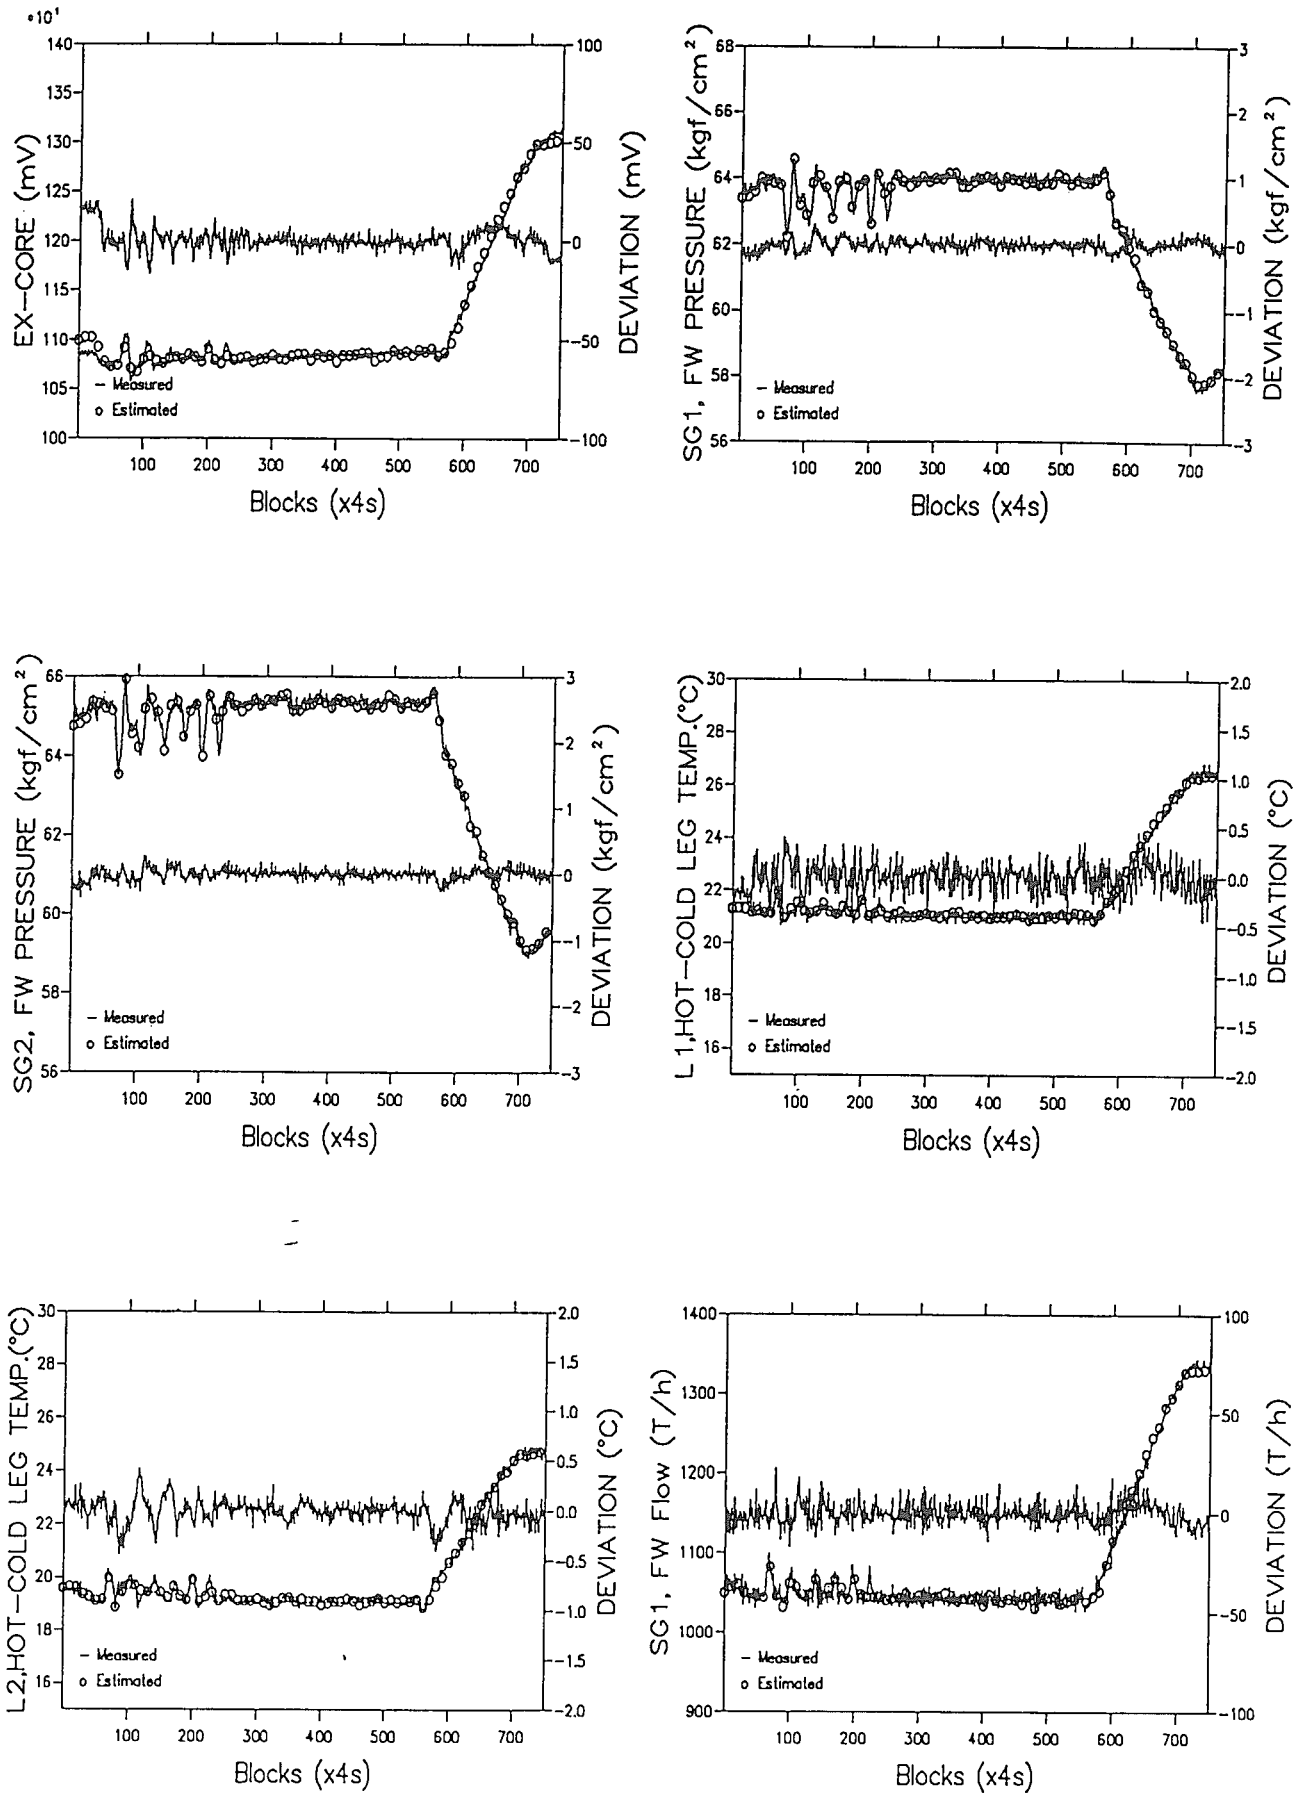


図4-8(a) 出力上昇運転時(B19170A2)の監視結果

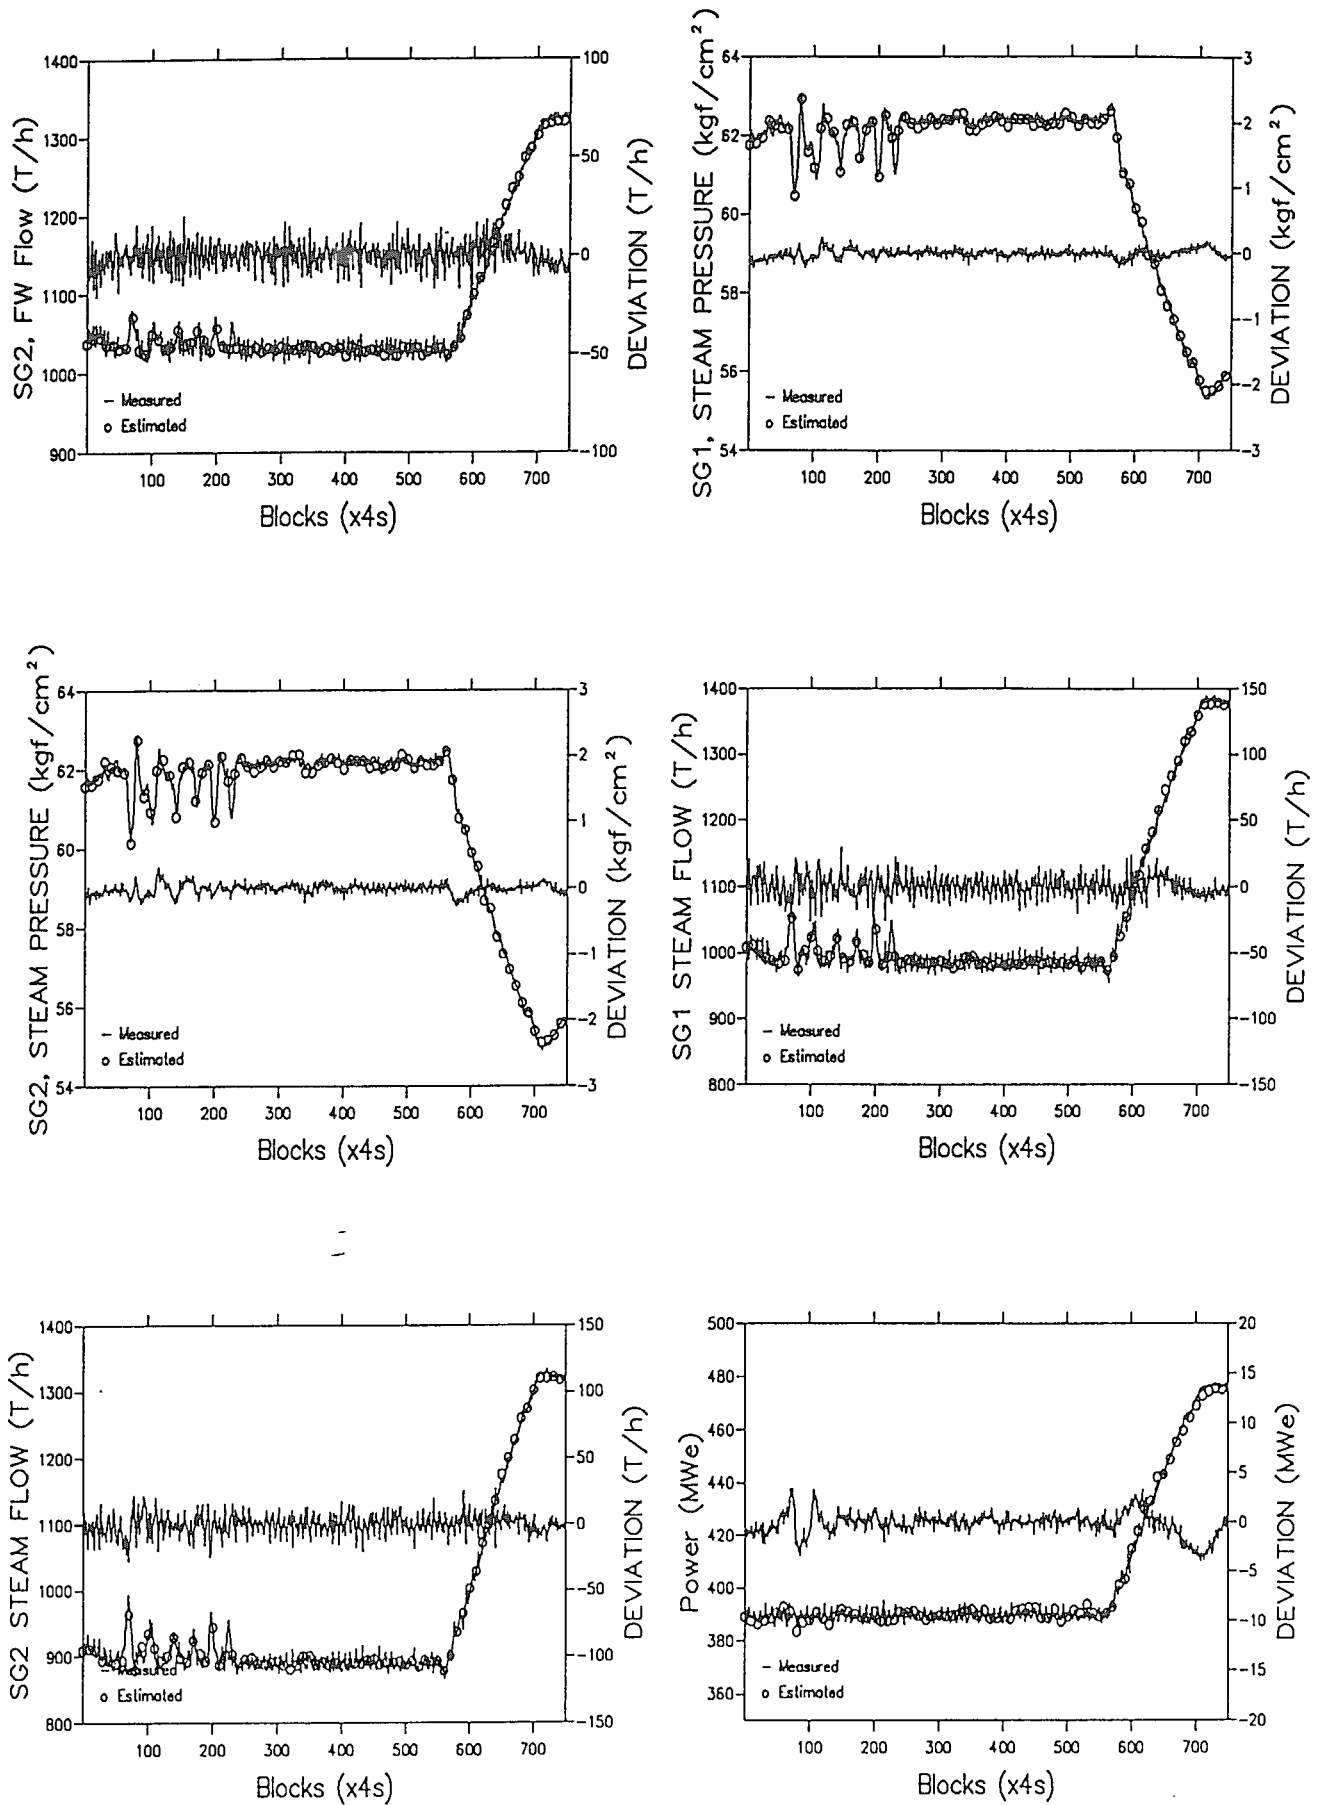


図4-8 (b) 出力上昇運転時(B19170A2)の監視結果 (続き)

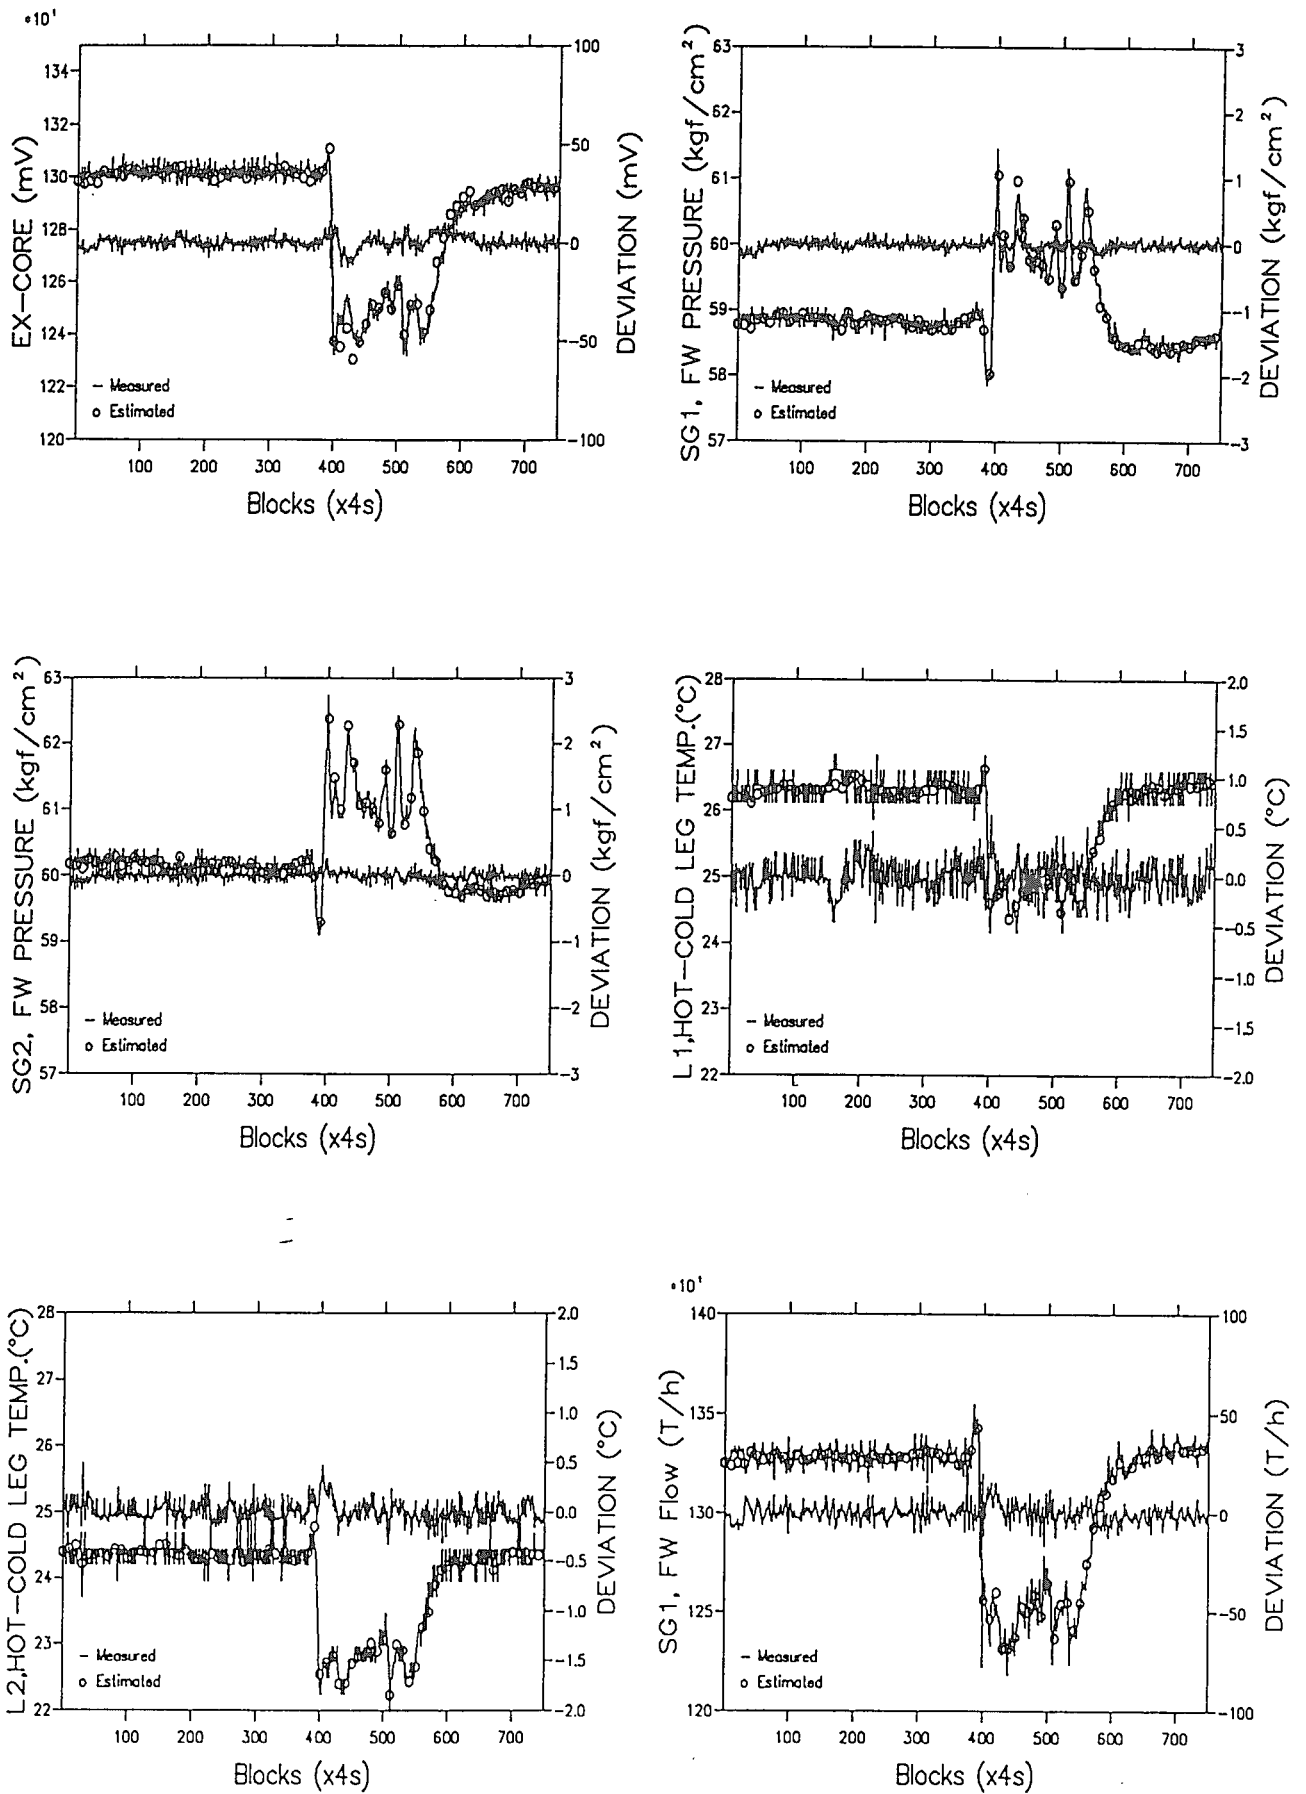


図4-9(a) 同位相リンスング運転時(B19178A)の監視結果









図4-9 (b) 同位相リンスング運転時(B19178A)の監視結果 (続き)

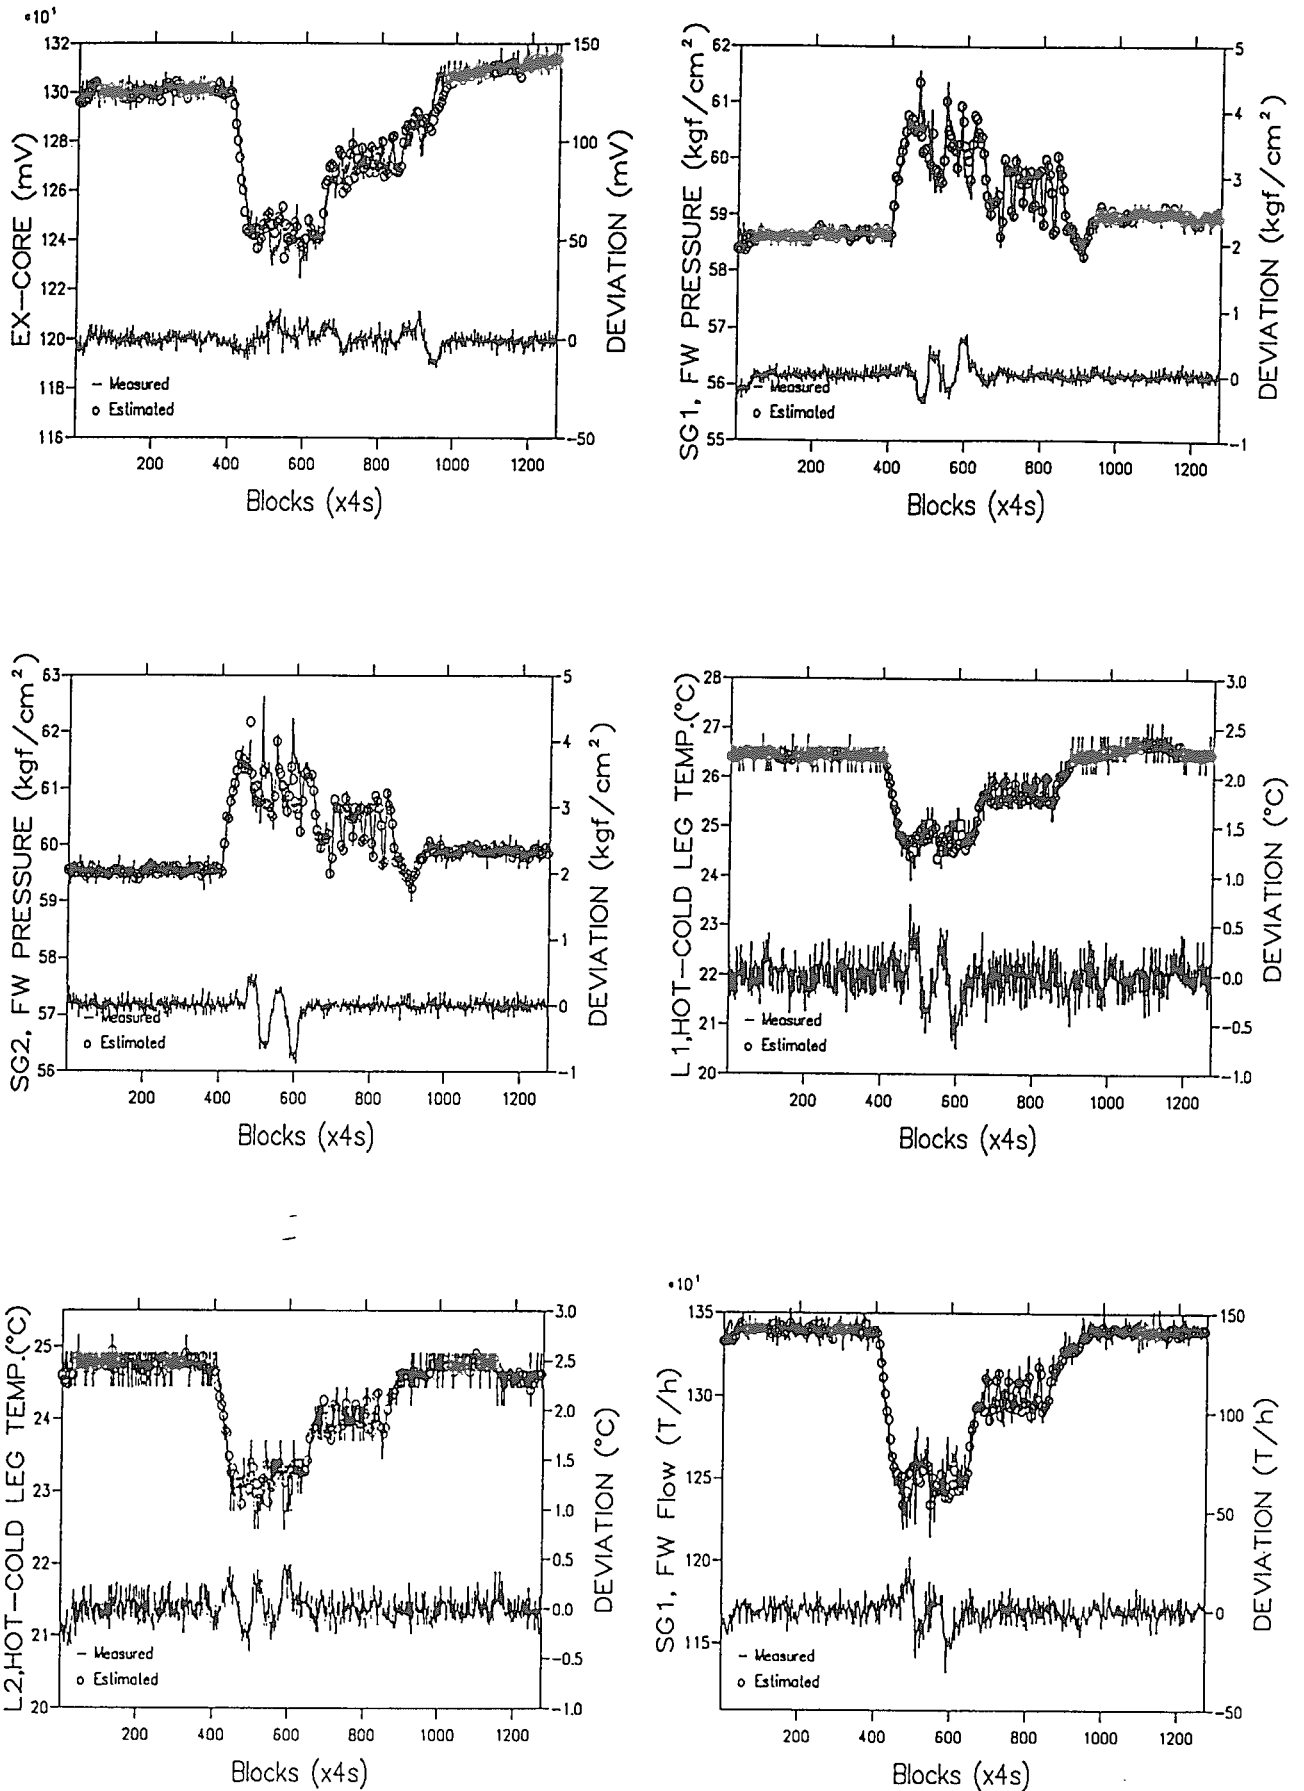


図4-10(a) 逆位相リンシング運転時(B19222A)の監視結果

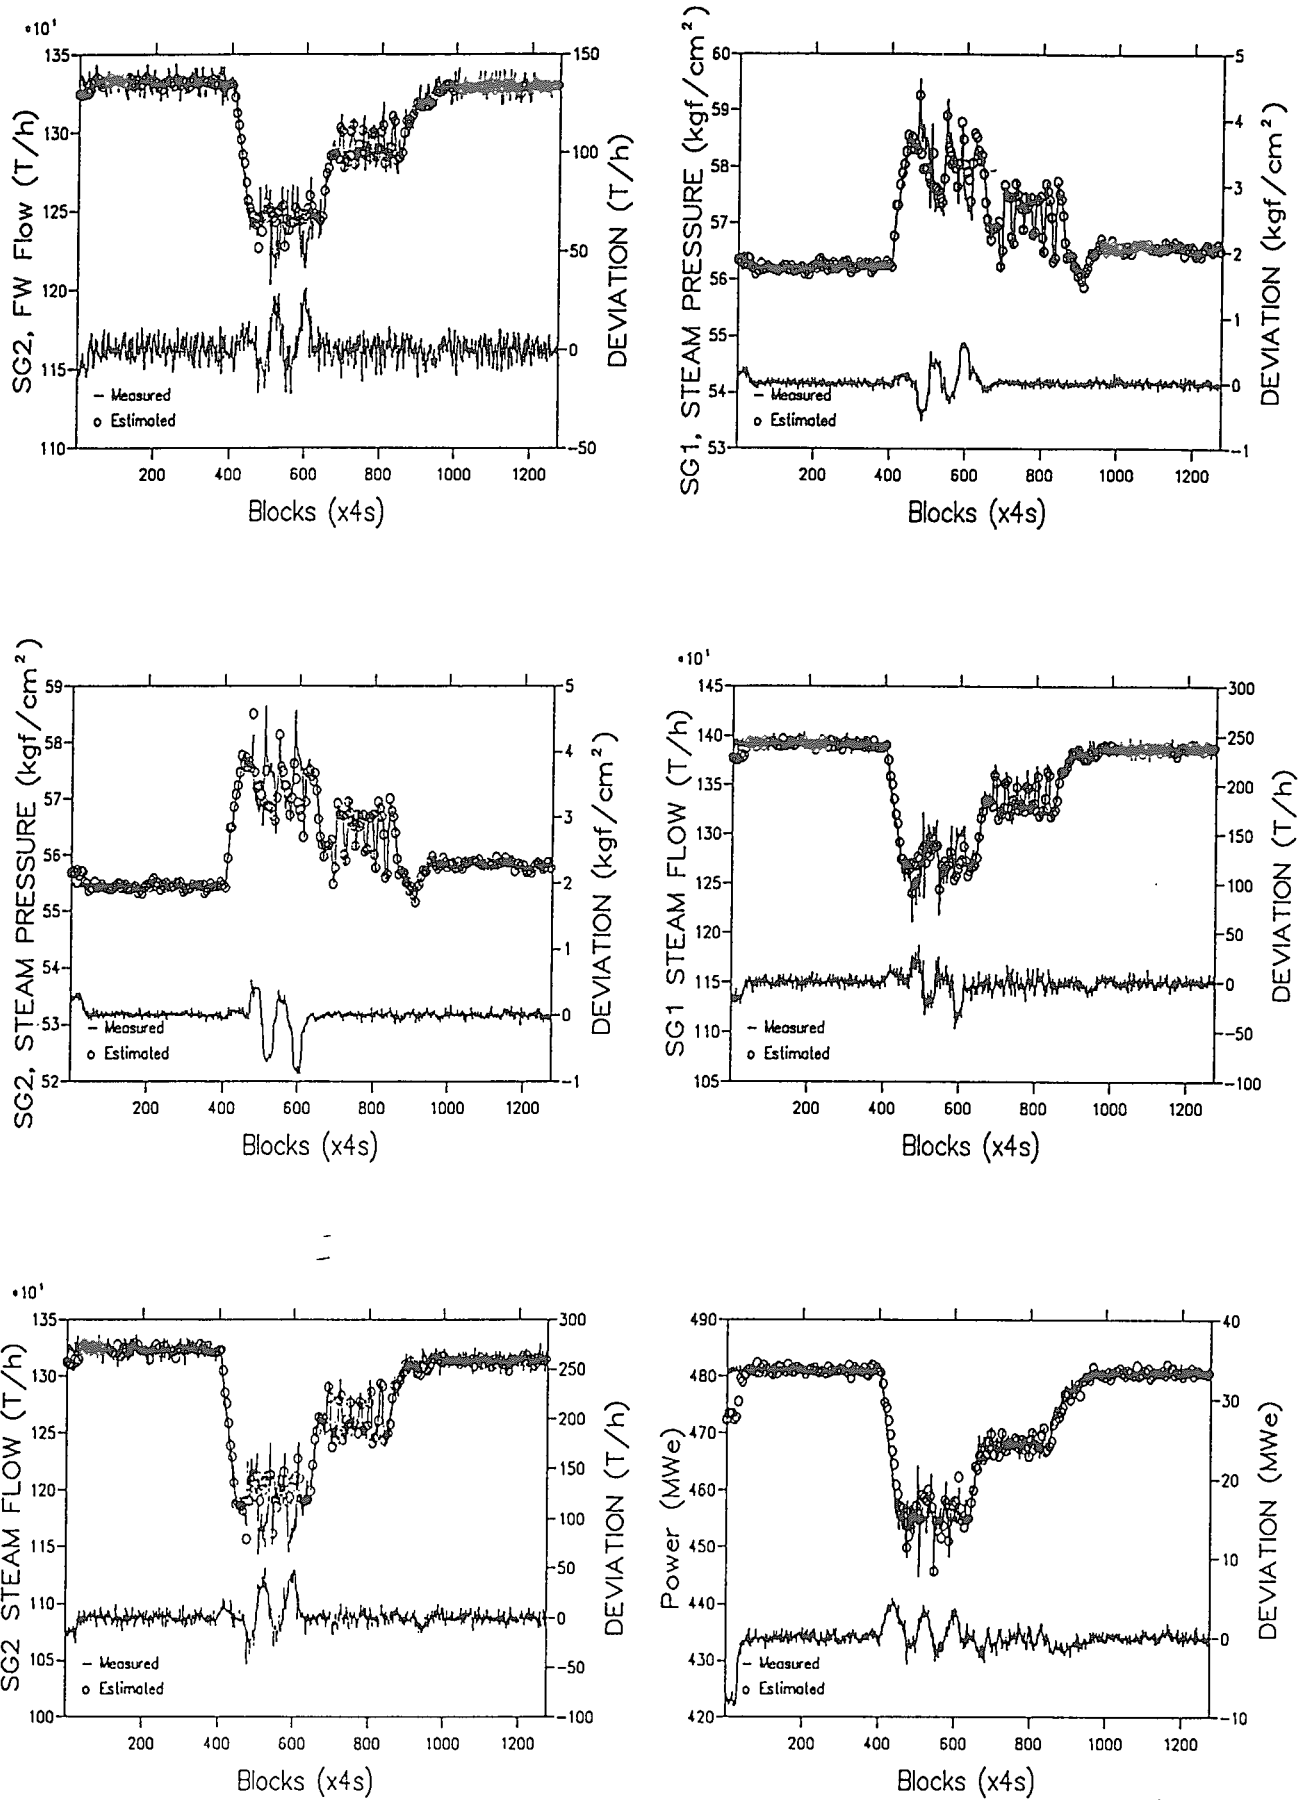


図4-10(b) 逆位相リンスング運転時(B19222A)の監視結果(続き)

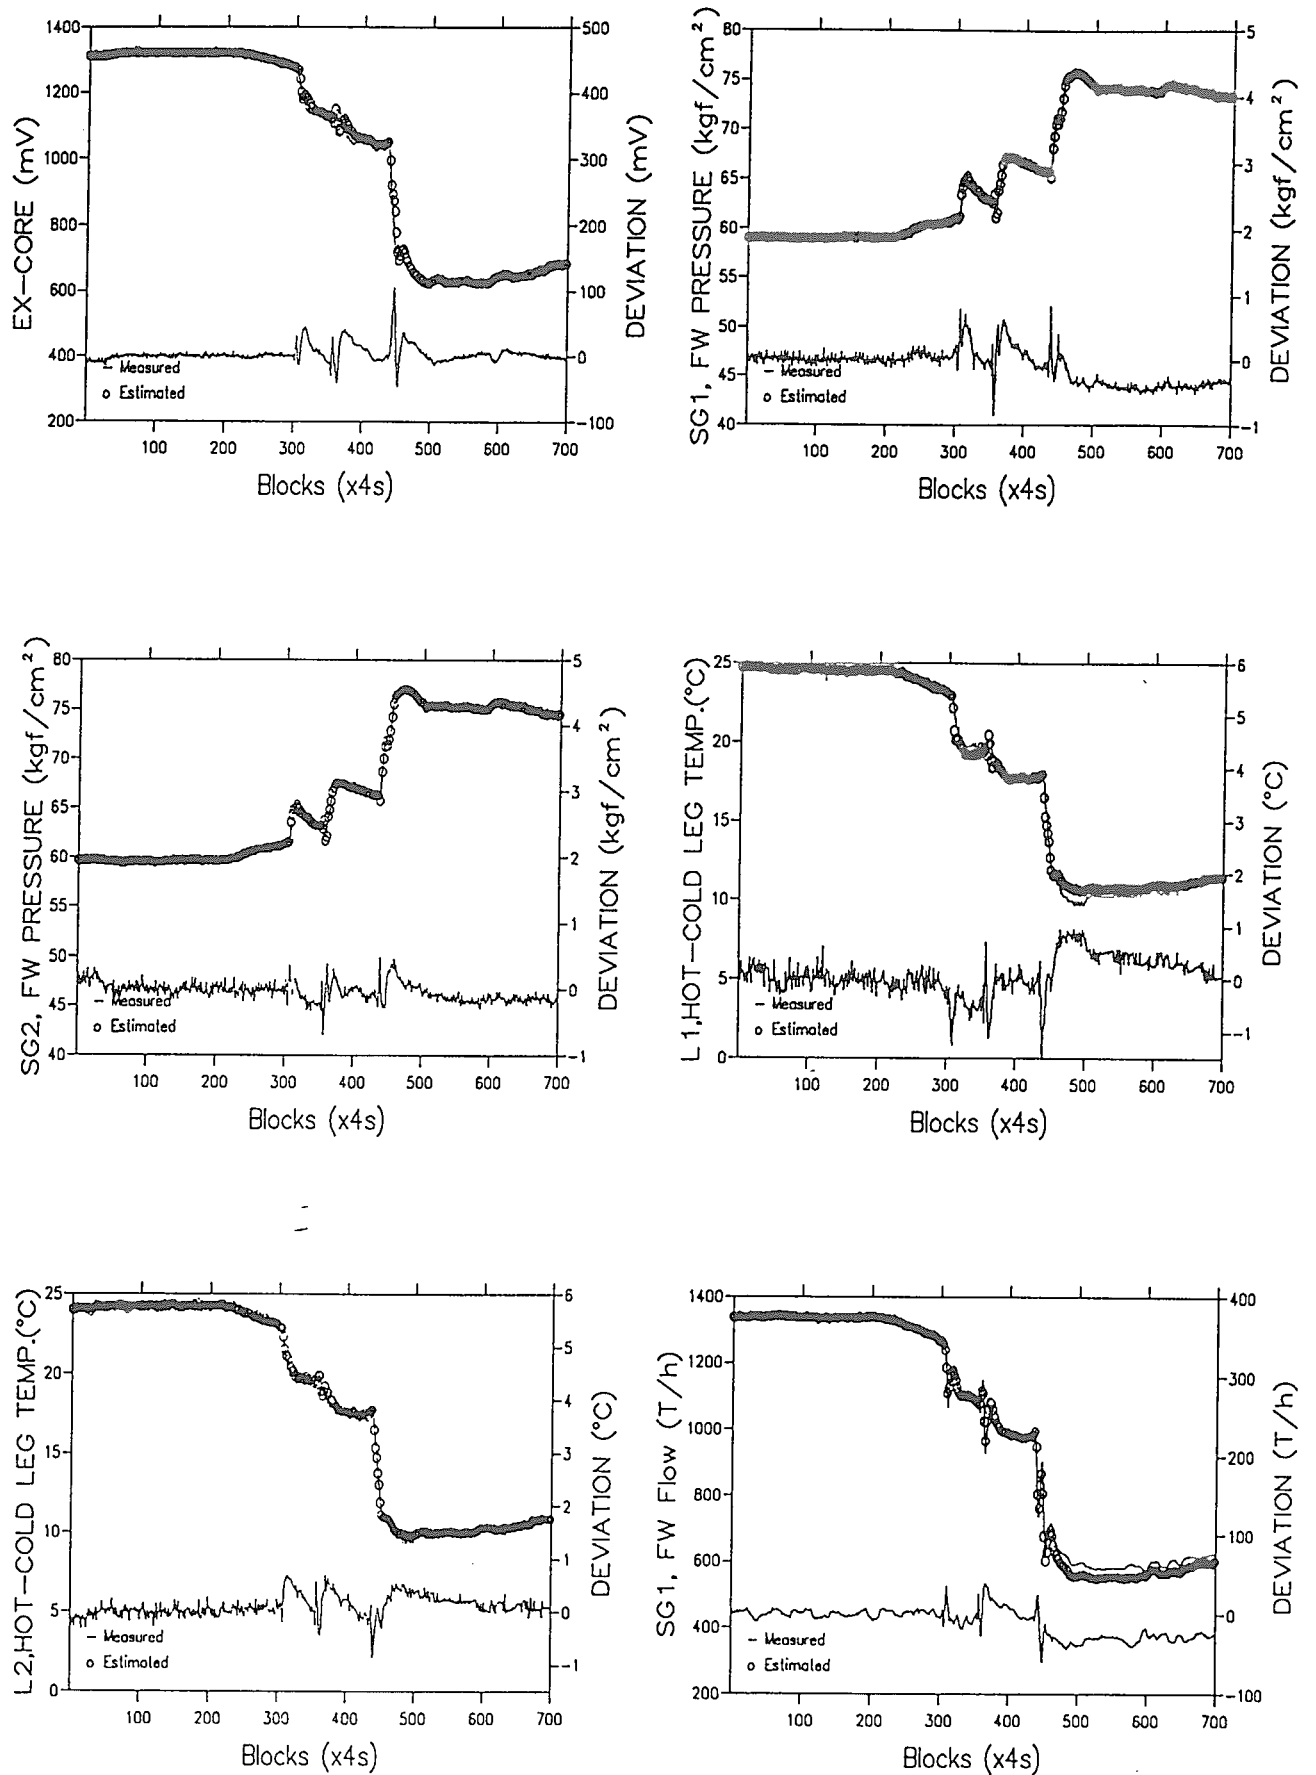


図 4 - 1 1 (a) 炉停止運転時(B19268N1)の監視結果

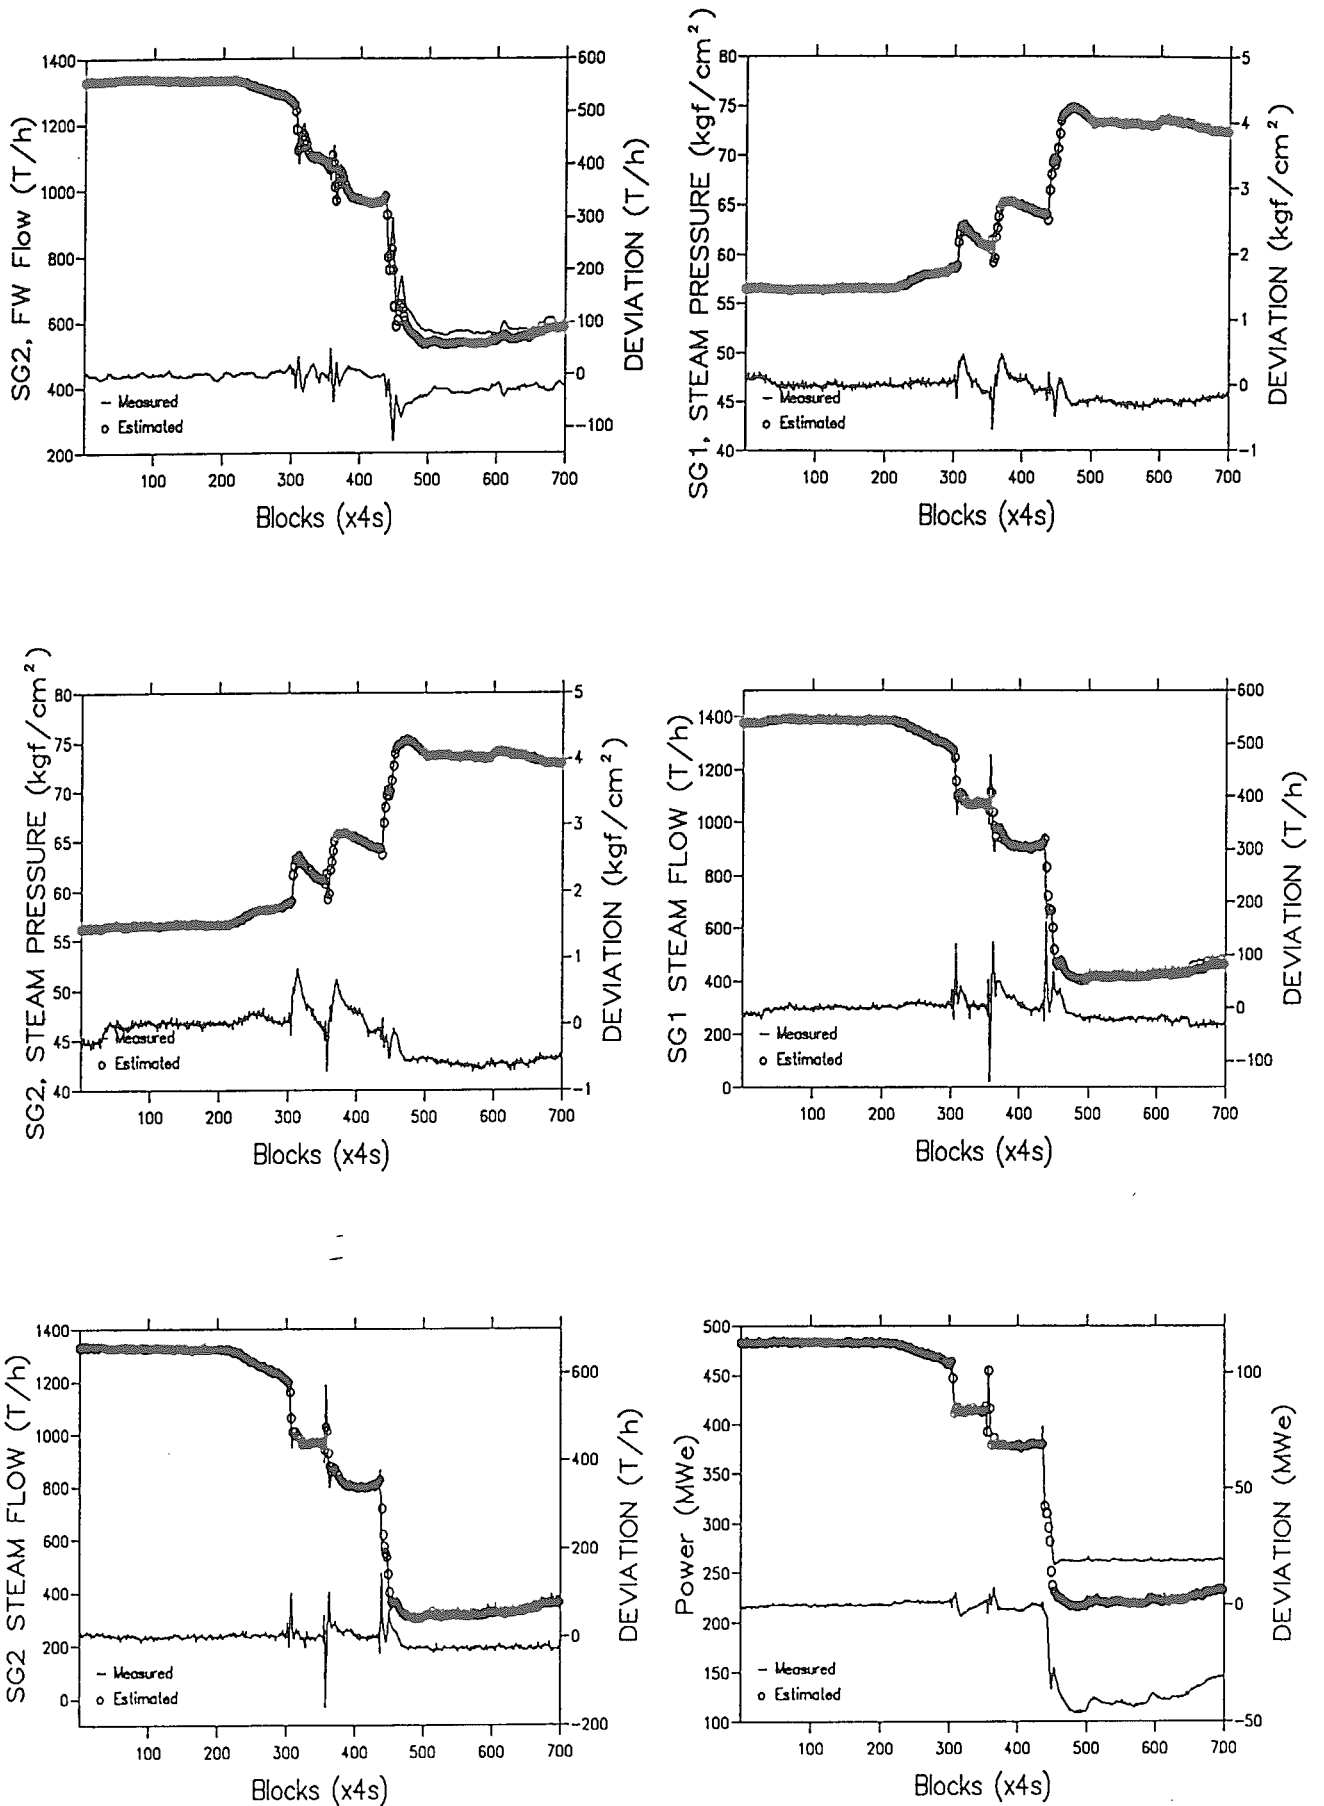


図4-11(b) 炉停止運転時(B19268N1)の監視結果(続き)









図 4 - 1 2 (a) 起動運転時(B19270A)の監視結果

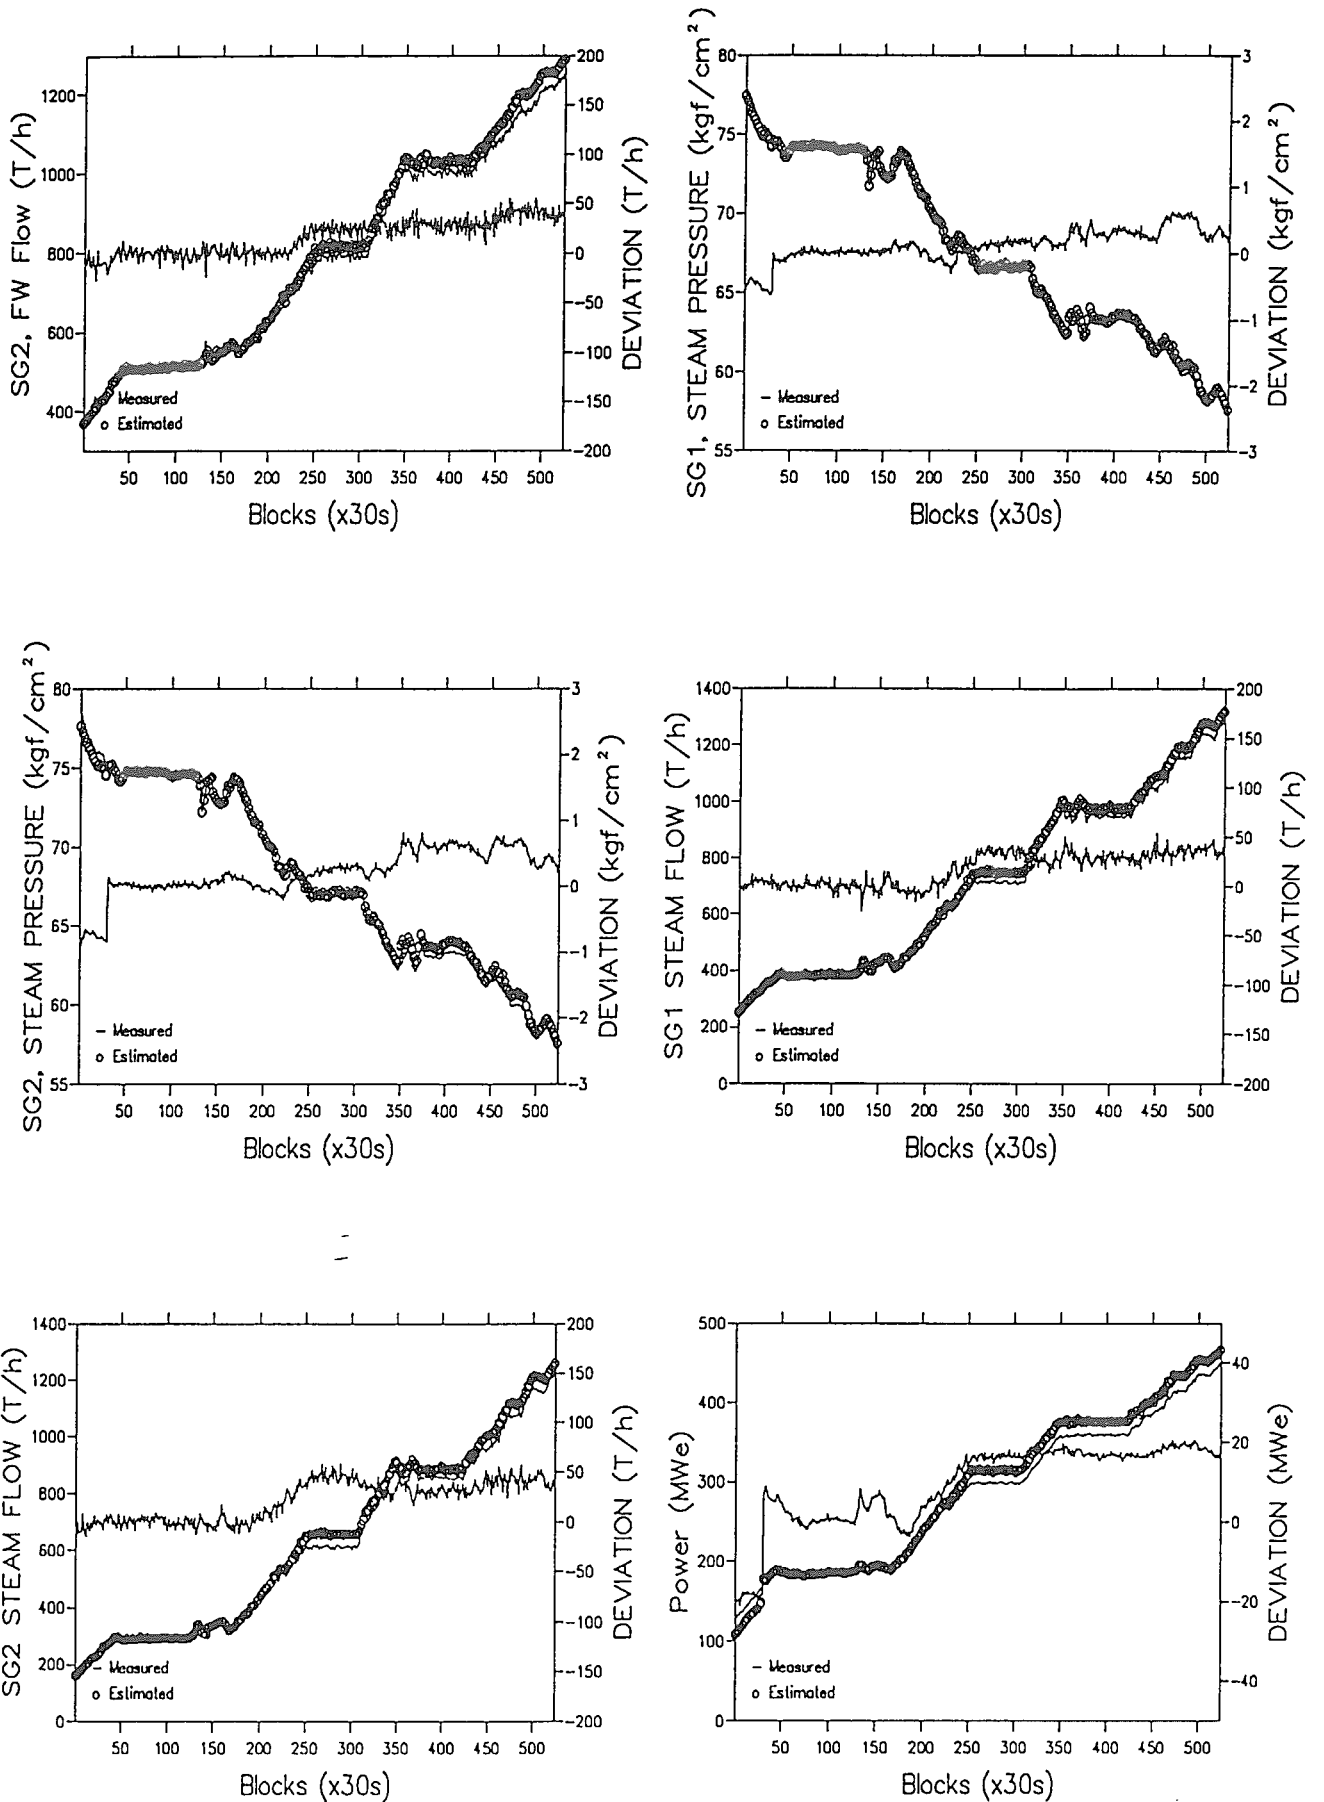


図4-12(b) 起動運転時(B19270A)の監視結果 (続き)

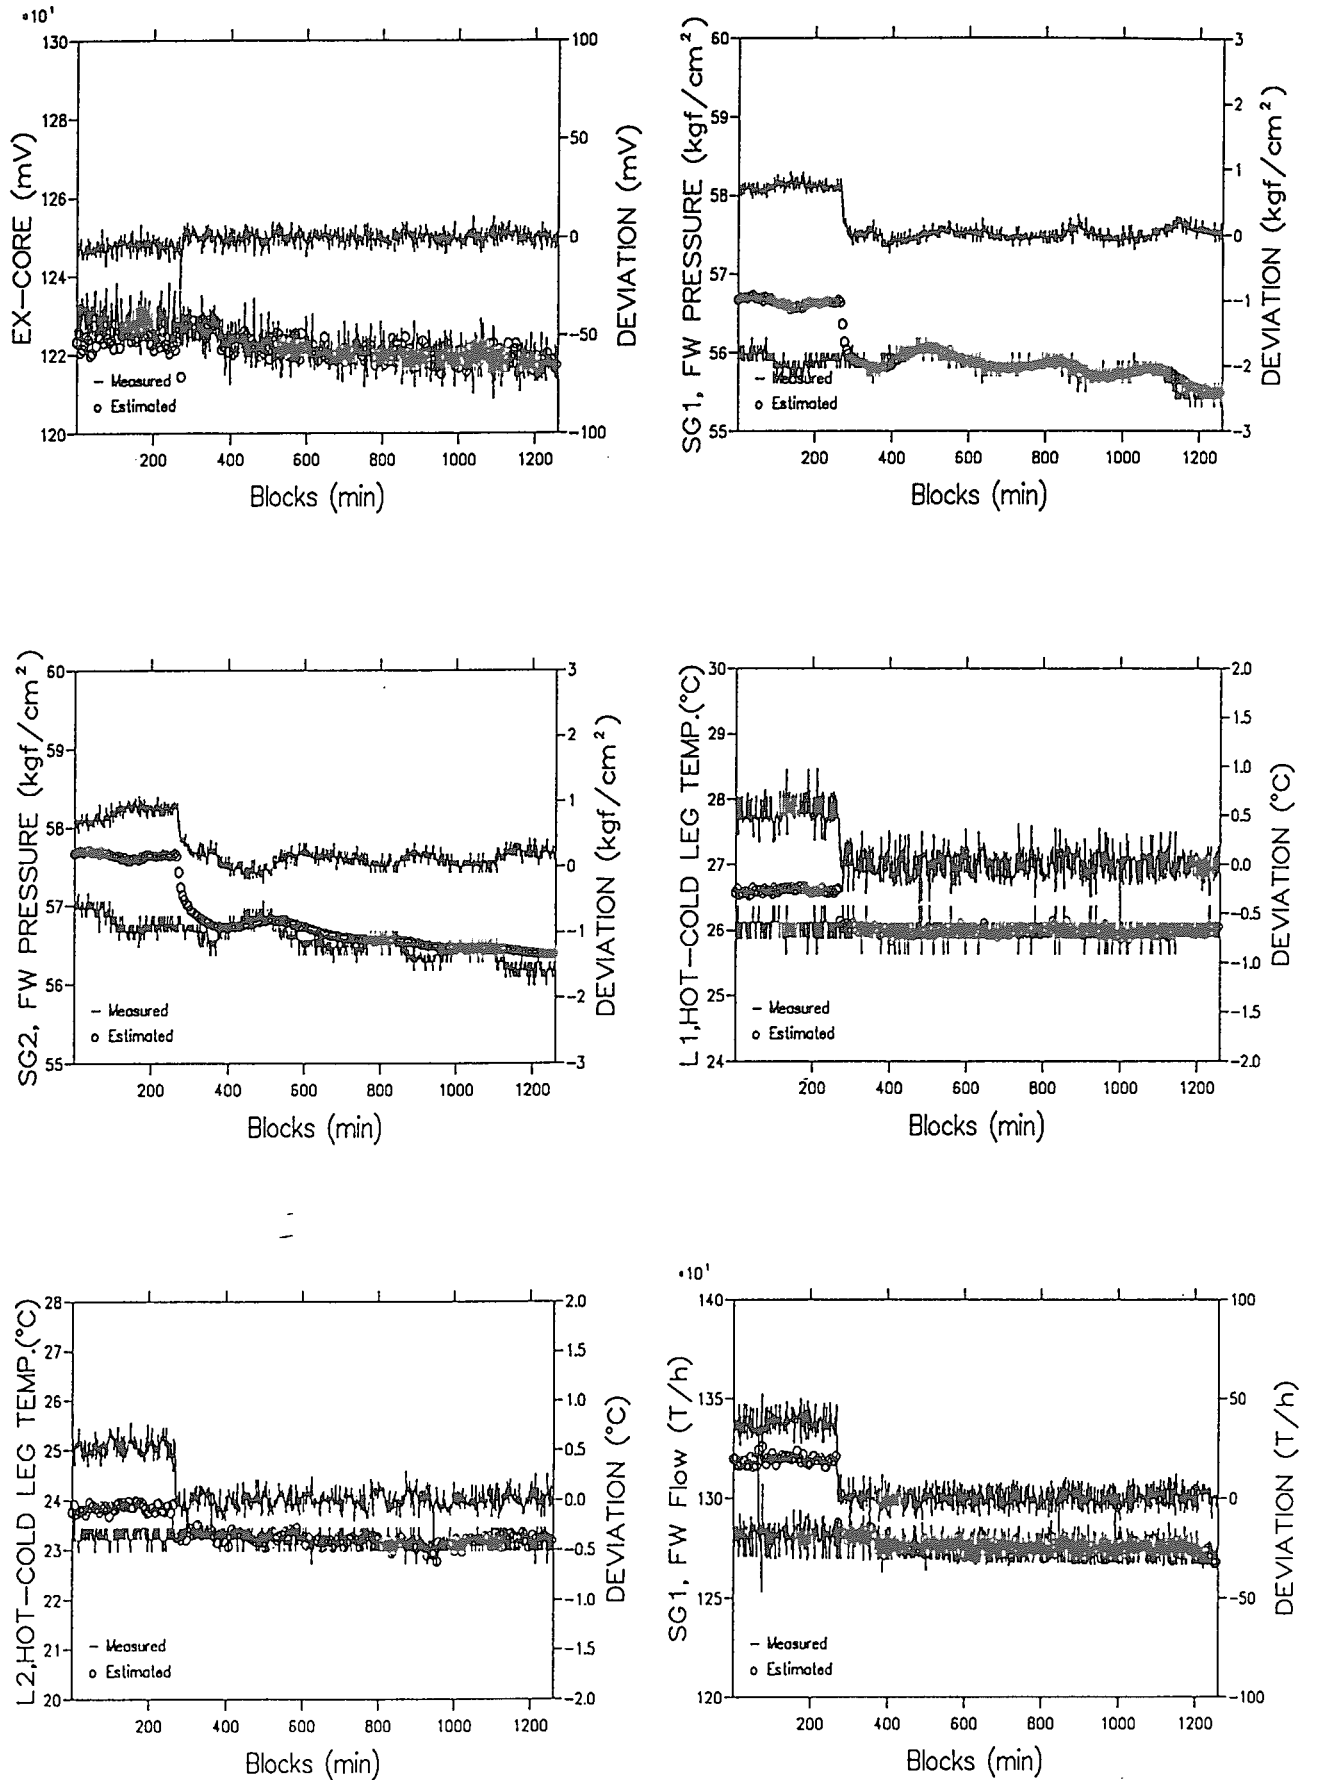


図 4-13 (a) ストレッチアウト運転時(B19393S1)の監視結果

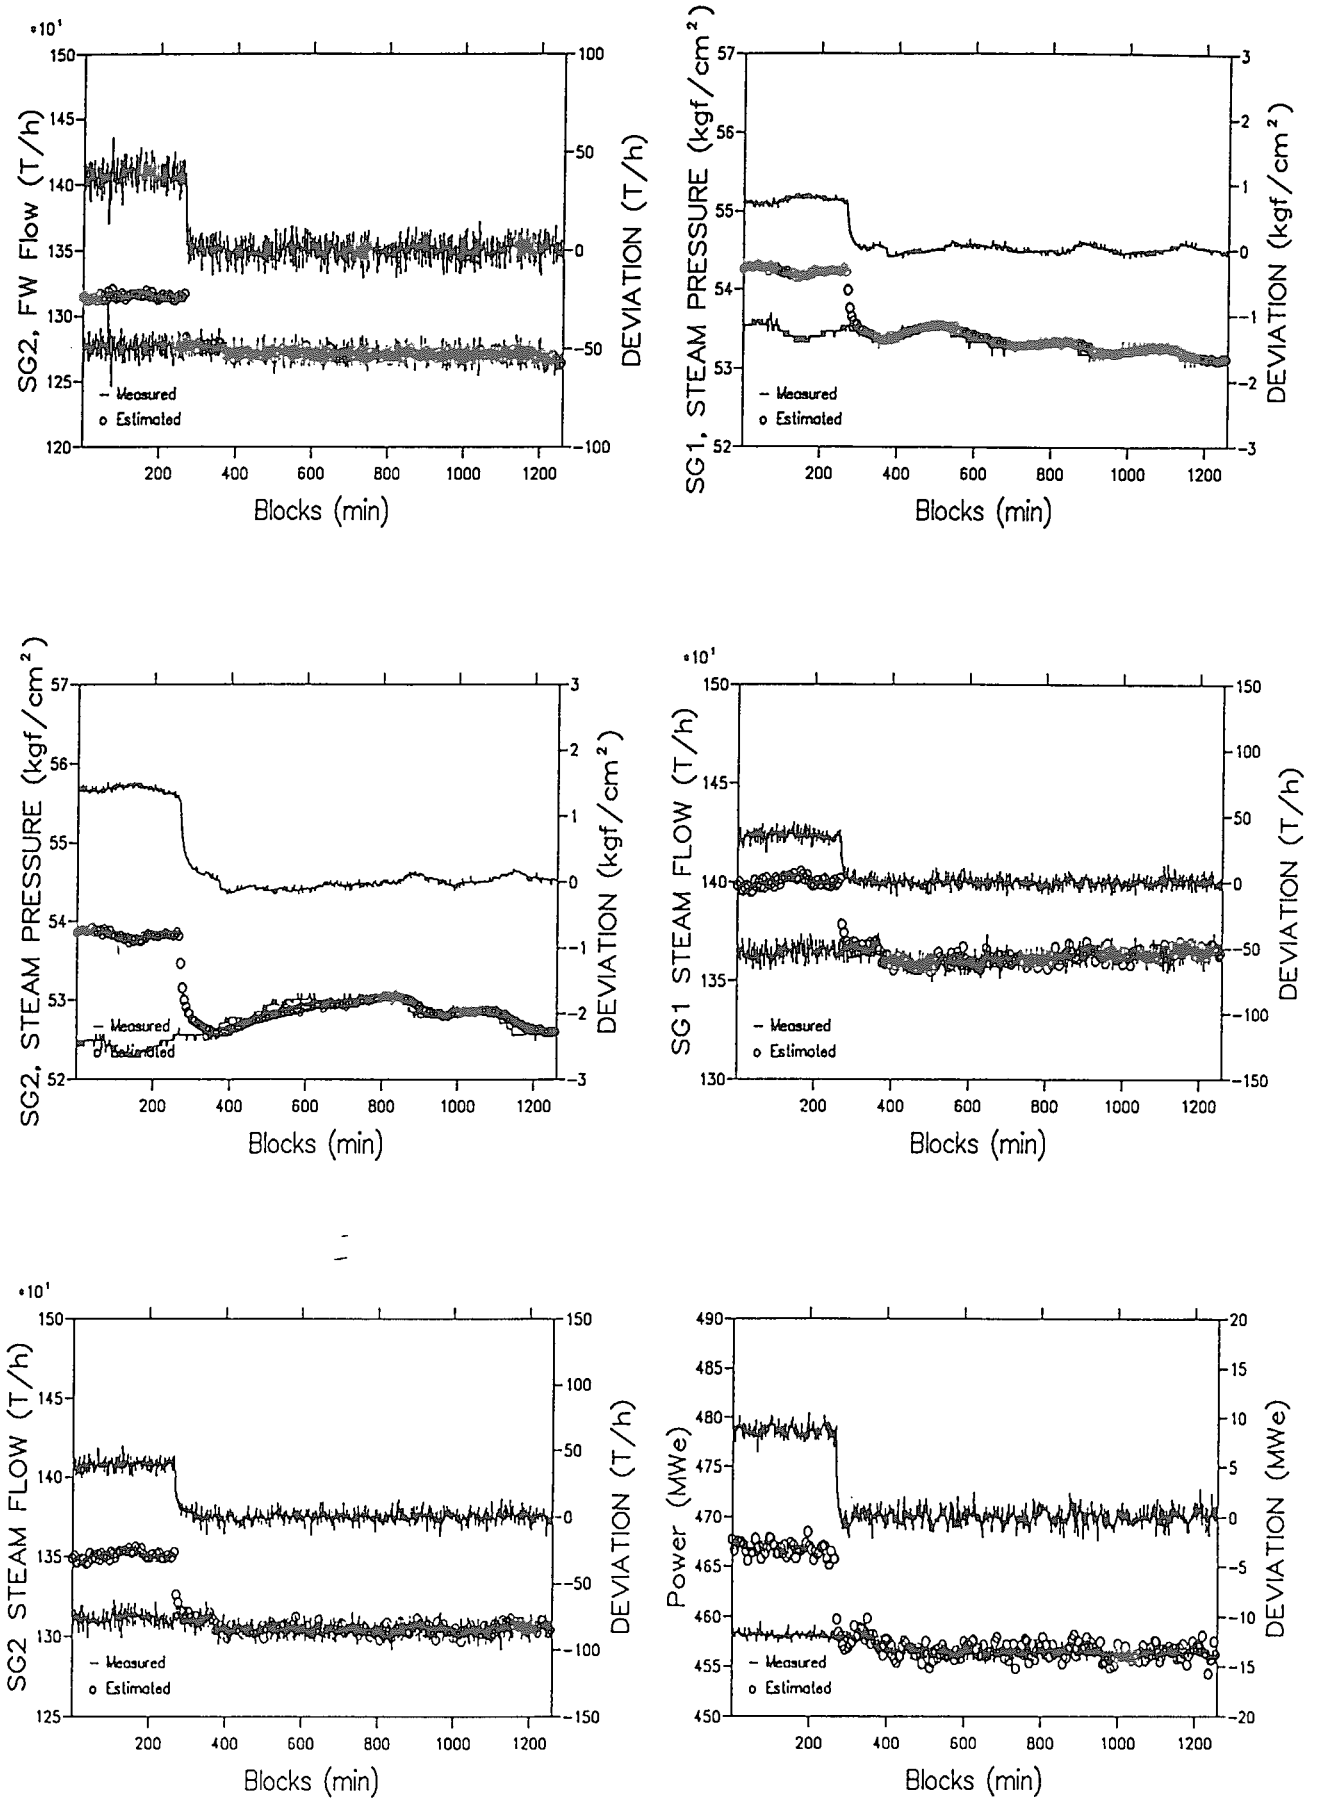


図4-13(b) ストレッチアウト運転時(B19393S1)の監視結果(続き)

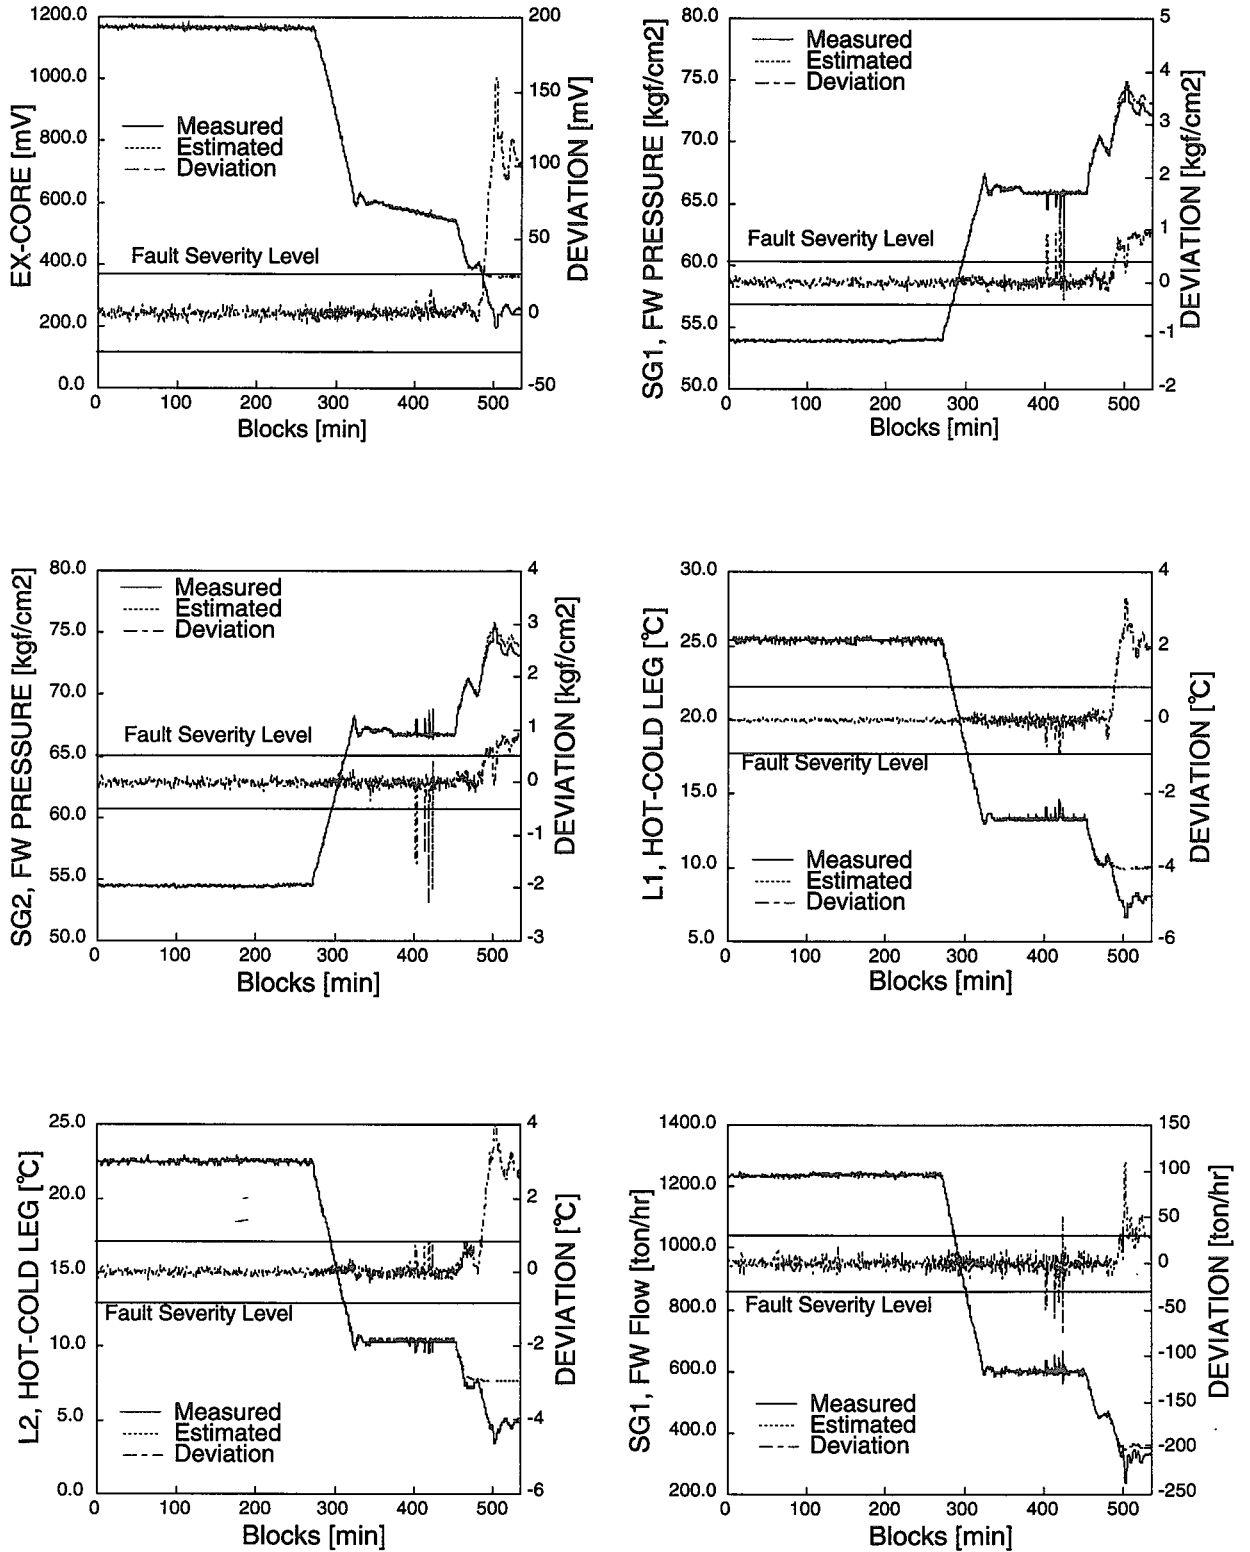


図 4 - 1 4 (a) 最終炉停止時(B19404A)の監視結果

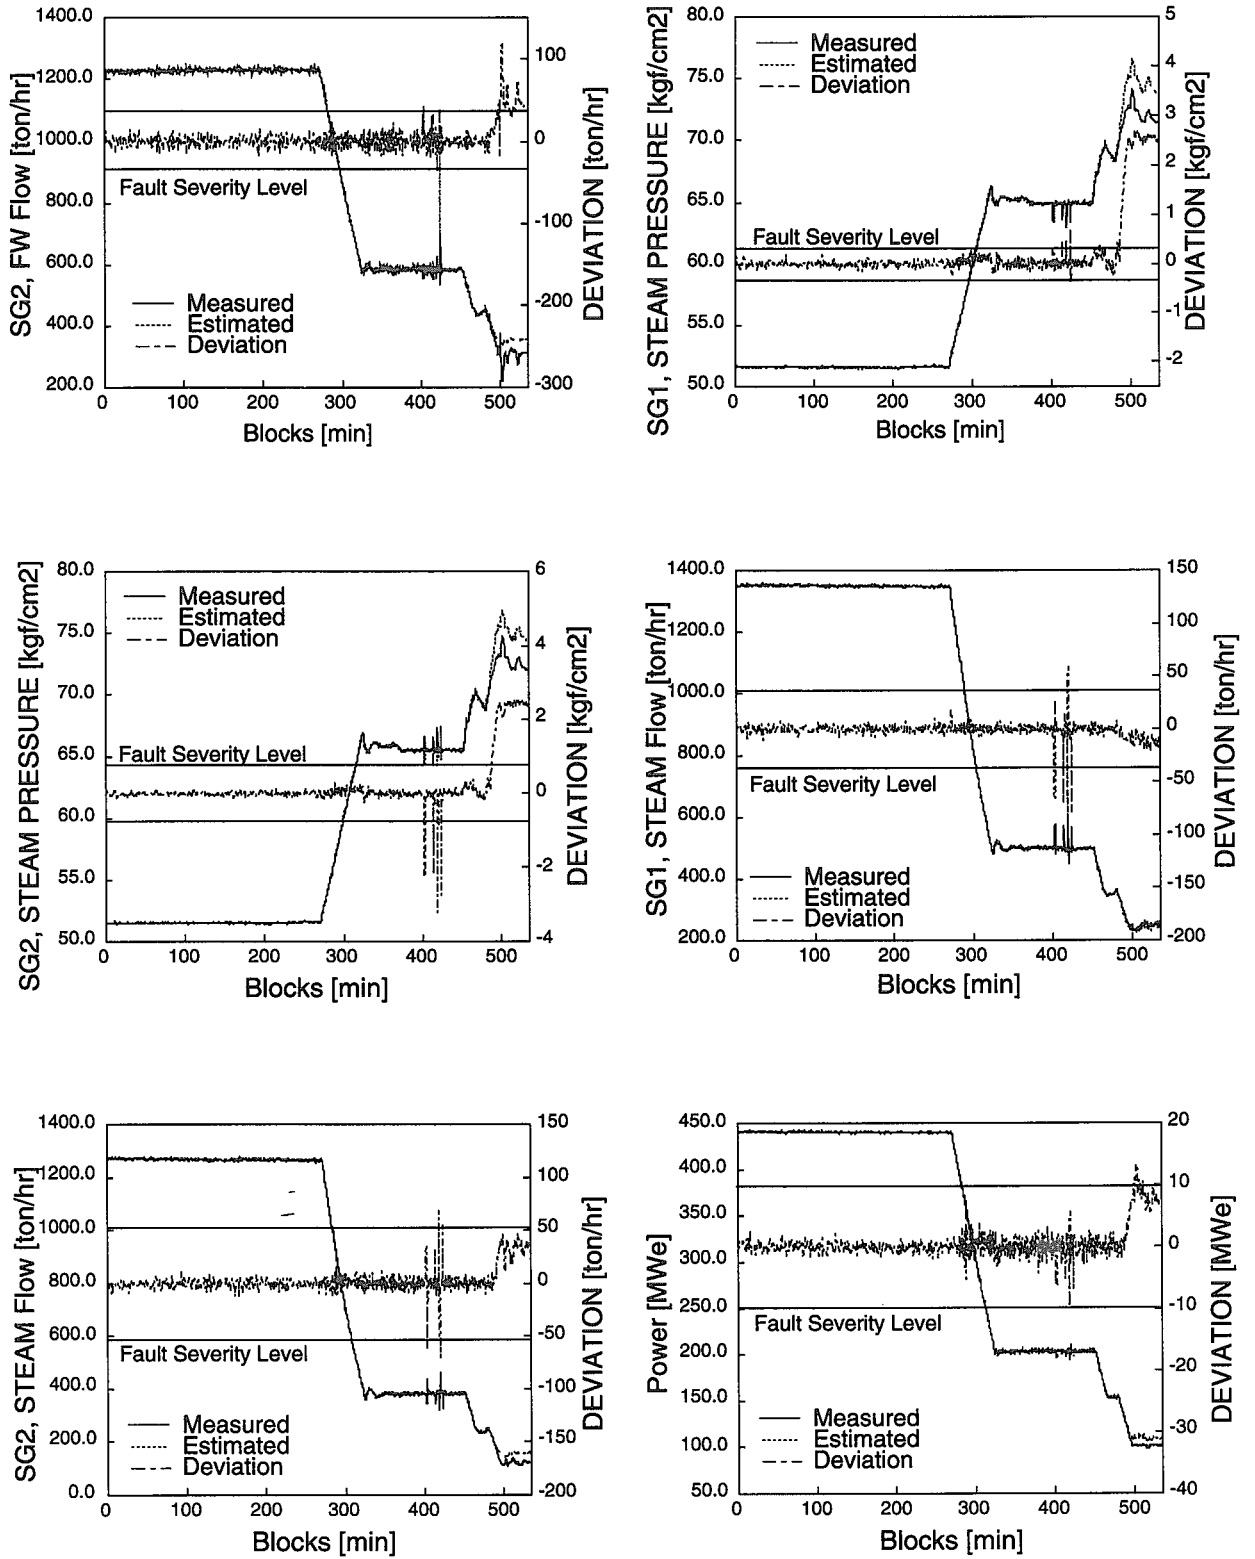


図4-14(b) 最終炉停止時(B19404A)の監視結果 (続き)





図4-15 最終炉停止時(リンシング部拡大)の監視結果

第5章 感度解析によるネットワーク内部の究明

現在、ニューラルネットワークはいろいろな分野において利用されつつあるが、その際もっとも問題となる点は、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ことである。ニューラルネットワークは、内部構造の不明な対象物のモデル化や識別を学習過程によって可能とする点が長所であるとともに、その理論的な裏づけを証明できない点が短所にもなっている。したがって、高度な信頼性・安全性が要求されるアプリケーションに利用することは躊躇されるのが現状である。

そこで本章では、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感度解析を試み、出力信号と入力信号の相関関係、ネットワークの動的な内部伝達特性を調べた。特に、本研究では入力信号と出力信号が同一のオートアソシアティブネットワークを使用しているため、各信号の自己寄与率を求めることは、モデル化の妥当性を検証する上でも重要な解析となる。

今回は、感度解析と忘却付き学習法の2つの方法を用いて、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を明らかにし、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した。以下に、PWRシミュレータ及び実炉に適用したフィードフォワード型ネットワークを使用した解析結果について記述する。

5.1 感度解析

ここでは、感度解析及び忘却を取り入れた学習を用いて、入出力の相関を求め、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を明らかにする。

まず、ニューラルネットワークの入力 $\mathbf{x} = (x_1, x_2, \dots, x_n)$ と出力 $\mathbf{y} = (y_1, y_2, \dots, y_n)$ の関係を、次式で表わす。

$$y_j = f_j(x_1, x_2, \dots, x_n) \quad (5-1)$$

$f(\mathbf{x})$ はニューラルネットワークの学習によってモデル化された関数である。

ここで、 i 番目の入力 x_i に微小の変動 Δx を加えたときの j 番目の出力 y_j の感度を、

$$\frac{\Delta y_j}{\Delta x_i} = \frac{f_j(x_1, x_2, \dots, x_i + \Delta x_i, \dots, x_n) - f_j(x_1, x_2, \dots, x_i, \dots, x_n)}{\Delta x_i} \quad (5-2)$$

と定義すると、入力に対する出力の寄与度 P_{ji} は、

$$P_{ji} = \frac{\frac{\partial y_j}{\partial x_i}}{\sum_{k=1}^n \frac{\partial y_j}{\partial x_k}} \times 100 \quad (\%) \quad (5-3)$$

で表わされる。

5. 2 PWR シミュレーションデータによる感度解析結果

図5-1は、第3章の過渡運転データで初期学習を行ったニューラルネットワークのそれぞれの入力に、+5%の外乱 (Δx_i) を加えた場合の、入力信号に対する出力信号の寄与度の割合を示したものである。図中の横軸は各ネットワークの出力信号で、チャンネルNo.は表3-6に対応している。縦軸は各信号の寄与度を規格化したものである。なお、この感度解析に使用する運転データは、第3章で使用した定常・過渡運転学習データのなかの、100%定常出力の100点である²⁶⁾。

図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(自己寄与率)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、自身の寄与率が約50%と大きく、しかも他の信号への寄与度は非常に小さい。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困難である。しかし一方で、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。この解析結果を基に、第4章では、一次冷却材流量信号の代わりに加圧器水位信号を採用した。

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%出力データに±5%の外乱を加えた場合についての感度解析も行ったが、全てのケースについて同様の結果が得られた。

5. 3 実炉データによる感度解析結果

図5-2は、第4章の初期学習で得られたネットワークのそれぞれの入力に+5%の外乱(Δx_i)を加えた場合の、入力信号に対する出力信号の寄与度の割合を表示したものである。図中の横軸はネットワークの各出力信号で、チャンネル No.は表5-7に対応している。縦軸は各信号の寄与度を規格化したものである。なおこの解析に用いるデータは、第5章で使用した初期学習の全データである。この図から明らかなように、全般的に見て、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、No.2 ループ蒸気流量信号(Ch.11)を除いて20%程度に収まっている。したがって、ニューラルネットワークはうまくプラントをモデル化できていると考えてよい。また、二つのループ間での同種信号の相関は大きくなっている。蒸気発生器の給水圧力と蒸気圧力が互いに大きく依存しているのは、圧力信号の応答が他の信号とは逆位相になっていることが主な原因だと考えられる。

ここで、2つのループの蒸気流量信号(Ch.10,Ch.11)の初期学習データを図5-3に示す。100%出力近傍において、これらの2つの信号は、ほとんど同じ値で、かつ同様の挙動を示している。しかし、出力が80%以下になると、No.2 ループの挙動は運転状態に大きく左右され、同一出力においても大きく異なっているため、他の信号との相関が小さくなる。これが、No.2 ループ蒸気流量信号の自己寄与率が58%と大きい理由であると考えてよい。

そこで、100%定常運転時及び80%定常運転時のデータを用いた感度解析を行った。その結果を図5-4、5-5に示す。図5-4から明らかなように、100%出力時におけるNo.2 ループ蒸気流量自身の寄与率は23%と小さく、異常検知に十分なモデル化がなされていると考えて良い。ところが、図5-5の80%出力データの結果では、自身の寄与率が43%まで上昇している。以上のことから、ニューラルネットワークは、適用する全ての出力領域で考えるとあまり相関が見られないモデルでも、相関がある領域においては相関を考慮したモデル化を行えることがわかる。したがって、このニューラルネットワークを異常診断に用いる場合、出力90%以上では十分適用可能であり、それ以下の出力においてもNo.2 ループ蒸気流量を除けば、十分な信頼性が得られることが、実データへの適用から明らかになった。

次に、忘却項を入れて学習させたネットワークの感度解析の結果を図5-6に示す。この解析に用いるデータは、初期学習の全データである。忘却により不要な結合が強制的に消去されているため、数%の寄与率を持った信号の影響がほとんどゼロになっている。この図から、No.2 ループ蒸気流量信号以外に、炉外中性子束(Ch.1)も、自身の信号の寄与率が50%程度と大きくなっており、この2つの変数に対してはモデル化があまりうまくいっていないことを示唆している。忘却付きニューラルネットワークによる解析では、炉外中性子束信号は、全データだけでなく定常出力領域でも他の信号との相関が小さくなる

が、忘却項を入れない学習のネットワークを使用する場合の自己寄与率は25%程度なので、異常診断への適用に問題はないと考えてよい。

5. 4 まとめ

以上の結果から、この感度解析が、ブラックボックスとされるニューラルネットワーク内部構造の解明に役立てられることが明らかになった。特に、原子力プラントのモデル化にオートアソシアティブニューラルネットワークを用いた場合、自身の信号寄与率が20%前後と、他の信号の寄与率と比較してそれほど大きくないことから、モデル化がうまくいっていることが証明された。




図5-1 ネットワーク出力信号に対する入力信号の寄与率
(シミュレータ : 100%定常運転データ)

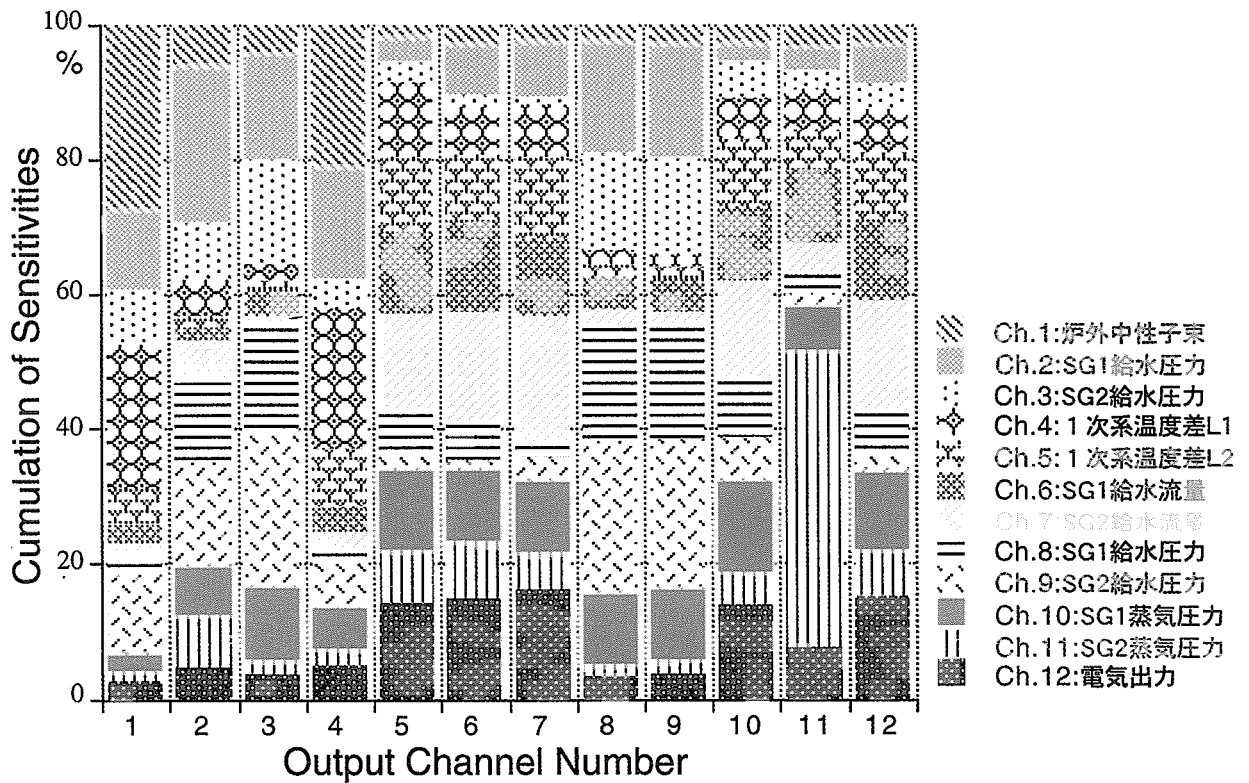


図5-2 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 全学習データ)




図5-3 蒸気流量初期学習データ (実炉)




図5-4 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 100%定常運転データ)

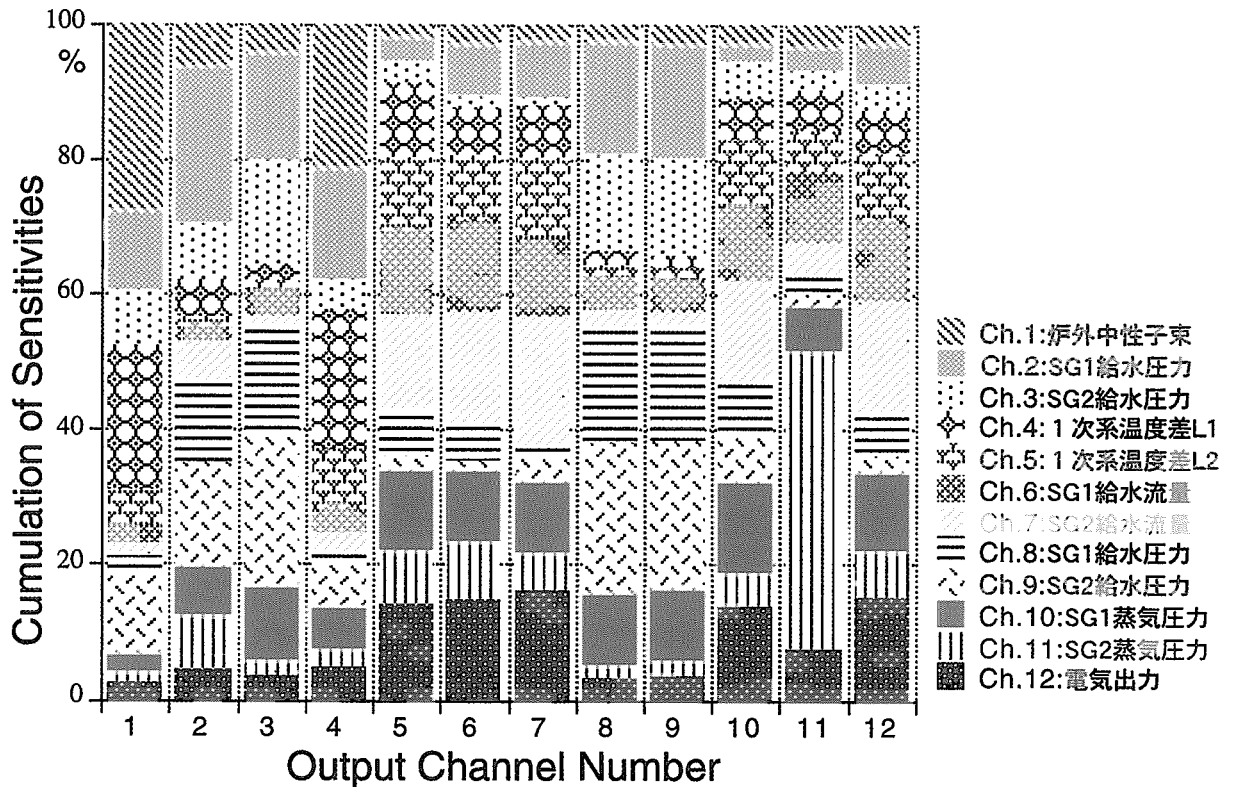


図5-5 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 80%定常運転データ)




図5-6 ネットワーク出力信号に対する入力信号の寄与率
(実炉 : 全学習データ; 忘却付)

第6章 リカレントニューラルネットワークによる異常検知手法の 検証

—PWR プラントシミュレータへの適用—

第3, 4章では、適応学習付フィードフォワード型ニューラルネットワークを用いて過去の運転データを学習し、原子炉のモデル化を行うことによって異常検知に適用した。ニューラルネットワークは、初期学習においてプラントの基本的なモデルを構築し、適応学習においてプラント動特性や緩やかな状態の変化にモデルを追従させる。この学習方法により、定常運転時だけでなく過渡運転時においても微少な異常兆候を早期検知できることがPWRプラントシミュレータ及び実炉に適用した結果から、明らかになった。しかし一方では、適応学習を行うことによって、非常にゆっくりと進行する異常事象データを学習し、その結果として異常を検知できない危険性も無視できない。したがって、毎回ごとに行ってきた適応学習の頻度をできるだけ減らす必要がある。

そこで本章では、フィードバック結合を持つリカレントニューラルネットワークを採用することにより、原子力プラントの動特性をモデル化し、適応学習なしでどの程度までモデルの変化に追従できるかを検証する。また、フィードフォワード型ネットワークとの異常検知性能についての比較も行う。

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層フィードフォワード型オートアソシアティブネットワーク及びリカレントネットワークでモデル化される。ニューラルネットワークの入力及び出力信号は、12個のプラント信号であるが、フィードフォワード型及びリカレントネットワークの出力は、入力信号の1秒後の予測値とする。いわゆる1点先予測計算である。

6.1 ニューラルネットワークによる原子炉のモデル化

ここでは、いろいろな異常事象を容易に模擬できるPWRプラントシミュレータを使用して、2つのニューラルネットワークの異常検知性能の比較・検証を行う。ここで使用する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も、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、フィードフォワード型及びリカレント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。

監視信号に用いるプラント変数として、炉心からは炉外中性子束が、一次系からは加圧

器水位と B、C ループにおけるホットレグ温度が、また二次系からは給水圧力（全ループの代表値）と 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（図 4-1 参照）。前章では 1 次冷却材流量を選択したが、低出力から 100% 出力までの正常運転時においてほぼ一定な値を示すため、ニューラルネットワークによるモデル化の必要がないと考えられる。したがって、今回は加圧器水位信号に変更した。なお、比較のために、フィードフォワード型ネットワークとリカレントネットワークの出力は、共に入力信号の 1 ステップ（1 秒）後の予測値である。

6. 2 適応学習付フィードフォワード型ネットワーク

本章でもリカレントネットワークとの比較のために、3 層の階層構造を持つフィードフォワード型ネットワークを使用し、学習則としてバックプロパゲーションアルゴリズムを採用した。入力及び出力層のユニットは前述のように 12 個であり、隠れ層のユニットは 20 個とした。

フィードフォワード型ネットワークの学習は、第 2 章で述べたように、典型的な運転パターンを学習する初期学習と、時間とともに変化する対象にあわせてネットワークの内部構造を変えていく適応学習の 2 つのモードに分けられる。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 つの正常運転パターンを広い出力範囲にわたって学習する。初期学習の際のデータの学習順序は、ランダムに行った。

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予測を行う。予測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、正常と判断、さらにその最新のデータを使って適応学習を行う。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。今回の計算では、過去 20 秒間のデータを適応学習に使用した。一方、どれか一つでも信号偏差がしきい値を超えた場合は適応学習を行わず、次のデータ診断に進む。

6. 3 リカレントネットワーク

ここで使用するリカレントネットワークは図 4-2 に示されるような 3 層の階層構造を持ち、入力層 $X(t)$ と出力層 $X(t+1)$ のユニットが一对一に対応し、出力層から中間層へのフィードバック結合を持つ Jordan 型ネットワークである¹²⁾。リカレントネットワークは、このフィードバック結合を有することによって、複雑な非線形ダイナミクスを持ち、動的な情報処理（時間パターンの記憶や認識、時系列データの予測等）が可能になると考えられている。したがって、リカレントネットワークを使用する場合には、適応学習はおこなわず、初期学習のみでプラント動特性モデルを作成することになる。

入力及び出力層のユニット数は前述のように12個であり、隠れ層のユニット数はフィードフォワード型との比較のために、同じ20個とした。また、PWRプラントの動特性モデル化に使用する場合には、中性子束などの一部信号の応答が比較的速いので、時間遅れは1タイムステップに相当する1秒に設定した。学習則は、フィードバックされる出力ユニットの1タイムステップ前の信号も入力ユニットの一部と見なすことにより、バックプロパゲーションアルゴリズムを用いることができる¹³⁾。

6. 4 初期学習

初期学習において、2つの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う。今回は表6-1に示されるように、100%定常出力運転データ20パターンと、出力変動幅が異なる100%定常時から50%への出力減少運転データ2ケースを使用した。学習データ数は、出力減少幅が2.5%/minのデータ1500パターンと、3.5%/minのデータ1050パターンを加えた、合計2570パターンである。フィードフォワード型ネットワークの場合には、各パターンをランダムな順序で3000回ずつ学習させた。一方、リカレントネットワークでは時系列データをモデル化するため、学習データは1パターンにつき8000回ずつ時間とともに順序よく学習され、Sun-Sparc20 計算機で約90分を要した。ここで、フィードフォワード型ネットワークの学習が、比較的容易に収束したのに対し、リカレントネットワークの場合はより複雑な構造になっているため、学習率等のパラメータを慎重に選択しないとなかなか収束が進まないことが明らかになった^{27), 28)}。

表6-2は、リカレントネットワークの初期学習の結果得られた、12のプラント信号の異常判定時のしきい値を示している。ここでしきい値は、学習時の最大誤差の1.25倍として経験的に設定されている。

6. 5 定常及び過渡出力運転時の解析結果

PWRシミュレータを使用して、定常運転時及び過渡運転時に発生するいろいろな異常事象のデータを作成し、フィードフォワード型及びリカレントネットワークで異常検知を試みた。表6-3及び以下に、その中の異常事象3例についての検知結果を示す。これら以外の異常事象については、ゆっくり推移する事象であっても、2つのネットワークの異常検知時間にほとんど差が見られなかった。

6. 5. 1 出力減少運転時の一次冷却材小破断

この異常事象は、100%定常運転から、過渡運転学習データとは異なる毎分3%の割合でタービン出力を減少させ、10分後にBループ冷却管に取り付けた测温抵抗体検出器の冷

却材に接した挿入管の破損が原因で、毎分約 110 リットルの冷却材が喪失するものである。冷却材の喪失は、加圧器水位及び加圧器圧力の減少を引き起こすが、漏洩量が小さいことと原子炉制御系が働いて冷却材を補充することにより、従来の警報システムは作動しない。これに対し、フィードフォワード型は異常発生 ($t=600$ 秒) から 126 秒後に、またリカレントネットワークは 38 秒後にそれぞれ加圧器水位信号の偏差がしきい値を越え、異常を検知した。図 4-3 の中の実線は測定値、破線はリカレントネットワークによる予測値、点線はフィードフォワード型による予測値を表しており、異常が発生する 600 秒までは、3 つの値はほとんど一致している。図中の◆は実測値とリカレントネットワークによる予測値との偏差を表しており、この偏差がしきい値を超えた場合、異常事象を検知する。図 4-3 から明らかのように、異常発生までの正常な出力減少運転中は偏差がしきい値よりも小さいことから、リカレントネットワークはこれまで学習したことの無い出力減少幅の過渡運転データについても、適応学習なしに正確にモデル化できていることがわかる。しかも、異常発生後は、フィードフォワード型よりも、早く異常を検知した。

6. 5. 2 復水器循環水部分喪失

100%定常運転から毎分 2.5%の割合でタービン出力を減少させている時、10分後に復水器冷却用の2区画のうちの1区画の循環水量が喪失して、50%の循環水流量で運転をするマルファンクションである。循環水流量は約20秒で半減し、冷却効果の低下で復水器内気相部温度はステップ状に40%上昇し、圧力も上昇する。低圧タービン流入蒸気流量は、低圧タービン入口圧力と復水器内圧力差で決まるため、真空度の低下により減少し、結果として蒸気流入を抑制するため、タービン発電器出力は16分で7%程度低下する。しかし、蒸気発生器への給水流量は不足分を復水貯蔵タンクより補充されるため、凝縮効果が落ちて二次系及び一次系に影響は現れない。したがって、シミュレータの警報システムは作動しない。

2つのニューラルネットワークによる検知結果を図4-4に示す。図中の実線は測定値、破線はリカレントネットワークによる予測値、点線はフィードフォワード型による予測値を表している。また、◆は実測値とリカレントネットワークによる予測値との偏差を、○は実測値とフィードフォワード型ネットワークによる予測値との偏差を表している。このように一次系及び二次系への影響がほとんどない異常事象の場合には、フィードフォワード型ネットワークは100%定常運転では異常を検知できたが、過渡運転時では異常データを学習してしまい、異常を検知することができなかった。これに対し、リカレントネットワークの場合は、過渡運転時も異常発生 ($t=600$ 秒) から 102 秒後に電気出力信号の偏差がしきい値を越え、異常を検知することができた。

6. 5. 3 大気放出弁の漏洩

100%定常運転中に、大気放出弁座の吹き抜けによる弁容量3%の蒸気漏洩が発生する。異常発生時($t=20$ 秒)から、蒸気流量及び蒸気圧力は減少し、さらに蒸気温度と出力の低下を引き起こす。この出力減少を補うために、原子炉制御系が作動し、制御棒が引き抜かれるが、出力バランスがわずかにシフトするだけで、異常発生から10分経っても従来の警報システムは鳴らない。一方、フィードフォワード型及びリカレントネットワークは異常発生からわずか2秒後に、蒸気流量、給水流量等の複数の信号で偏差がしきい値を超えて、異常を検知した。その中でもっとも早く異常を検知した蒸気流量の場合を図4-5に示す。この異常事象を検知するまでに要する時間に関しては、2つのネットワークに差は見られない。しかし、偏差がしきい値の境界付近にあるため、フィードフォワード型では、いったん偏差が正常範囲内に戻る。その結果、この異常事象データを適応学習してしまうため、その後は異常と認識しなくなってしまう。このように、適応学習付きフィードフォワード型ネットワークでは、非常にゆっくりと進行する異常事象データを学習してしまい、異常を見逃す危険性のあることが明らかになった。これに対し、リカレントネットワークは異常発生後も継続して異常を識別している。

6. 6 まとめ

リカレント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することにより、原子炉のモデル化を行い、異常事象の検知に適用した。リカレントネットワークでは、初期学習の収束が学習率等のパラメータに大きく依存するため、フィードフォワード型に比べて学習パラメータの選択には注意が必要である。しかし、リカレントネットワークは、初期学習データのみでプラント動特性がモデル化できるため、適応学習の必要性のないことが明らかになった。もちろん、燃料の燃焼に伴う緩やかな原子炉特性の変化にネットワークモデルを追従させる上で、適応学習は不可欠であるが、リカレントネットワークはその頻度を大幅に減らすことができるため、ゆっくりした異常を見逃す確率も小さくなる。

PWRシミュレータを利用した異常診断の結果、微小でゆっくりした異常事象の場合には、リカレントネットワークは、従来の監視システムやフィードフォワード型に比べて早い段階で異常事象を検知できることがわかった。しかしながら、それ以外のほとんどの異常事象に対しては、フィードフォワード型とリカレントネットワークで異常検知性能に大きな差は見られなかった。これは、軽水炉の場合、プラントの動特性が比較的速いため2つのネットワークの違いが顕著に現れなかったためだと考えられる。一方、高温ガス炉のように原子炉の挙動がゆっくりしたプラントに適用した場合、リカレントネットワークの利点が明確になる²⁹⁾。

今後、PWR実プラントに適用する場合は、リカレントネットワークを採用して適応学習頻度を週1回程度に減らすことがベストな選択であると考えられる。

表6-1 ネットワーク学習データ

Total Learning Pattern		2570
1)	100% Steady State Operation	20
2)	2.5%/min Power Decrease Operation (100%-50%)	1500
3)	3.5%/min Power Decrease Operation (100%-50%)	1050
Learning Cycle [Recurrent]		8000
Learning Time [Recurrent] (Sparc20)		90 min

表6-2 初期学習後のリカレントネットワークのしきい値

Ch	signal	symbol	fault level; ϵ_f
1	ex-core neutron flux	EX-CORE	1.026 [%]
2	feedwater pressure	FWP	0.203 [kgf/cm ²]
3	hot-leg temperature (I-B)	HLTL1	0.274 [°C]
4	hot-leg temperature (I-C)	HLTL2	0.555 [°C]
5	feedwater flow (loop-B)	SG1FWF	6.259 [t/h]
6	feedwater flow (loop-C)	SG2FWF	7.233 [t/h]
7	steam pressure (loop-B)	SG1SP	0.147 [kgf/cm ²]
8	steam pressure (loop-C)	SG2SP	0.158 [kgf/cm ²]
9	steam flow (loop-B)	SG1SF	8.072 [t/h]
10	steam flow (loop-C)	SG2SF	8.055 [t/h]
11	generated electric power	GEP	9.710 [MWe]
12	pressurizer level	PRZL	0.401 [%]

表6-3 異常事象の検知時間

異常事象	運転状態	従来の 警報システム	フィード フォワード型	リカレント ネットワーク
一次冷却材 小破断	100%出力 定常運転	No Alarm	38 s (ch.12)	30 s (ch.12)
	出力減少 運転	No Alarm	126 s (ch.12)	38 s (ch.12)
復水器循環水 部分喪失	100%出力 定常運転	No Alarm	25 s (ch.11)	24 s (ch.11)
	出力減少 運転	No Alarm	No Alarm	102 s (ch.11)
大気放出弁の 漏洩	100%出力 定常運転	No Alarm	2 s (ch.5,6,9,10)	2 s (ch.5,9,10)
	出力減少 運転	No Alarm	3 s (ch.5,6,9)	2 s (ch.6,9)

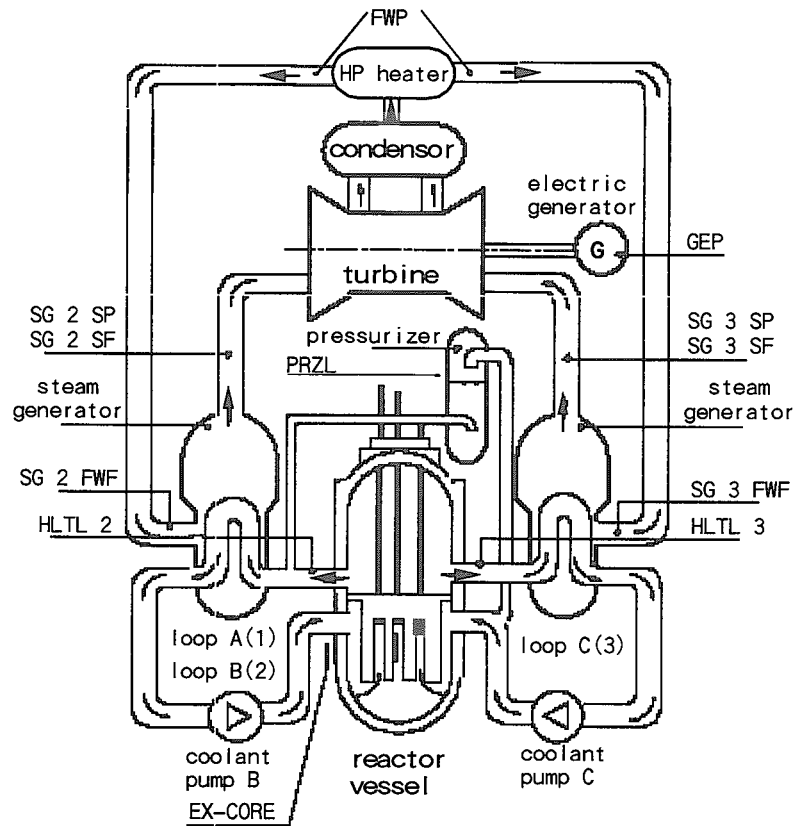


図 6-1 PWR プラントシミュレータの概略図

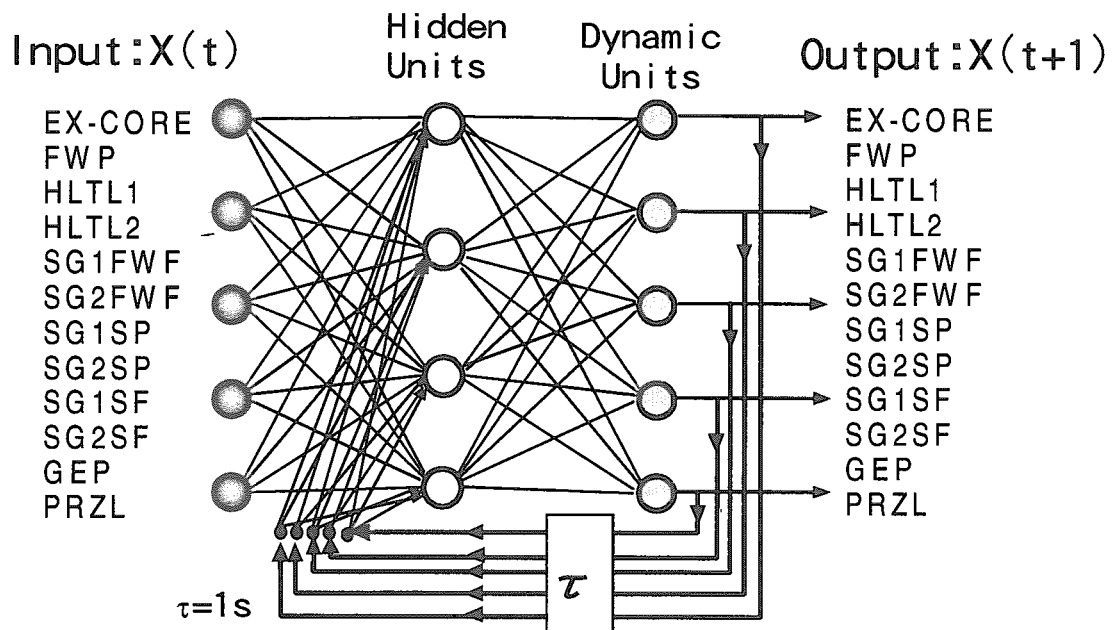


図 6-2 リカレントネットワークモデル図




図 6-3 一次冷却材小破断時の異常検知結果




図 6-4 復水器循環水部分喪失時の異常検知結果




図 6-5 大気放出弁の漏洩時の異常検知結果

第7章 結論

本研究では、ニューラルネットワークに過去の正常な運転データを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た。実際のプラント信号とニューラルネットワーク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検知する事が可能となる。

PWRプラントシミュレータ及び実プラントを用いて、原子炉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の異常事象を的確に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た。さらに、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切に行われているかどうかを検証した。以下に本研究で得られた結果を要約する。

7. 1 適応学習付フィードフォワード型ニューラルネットワークによる異常検知 (PWRプラントシミュレータへの適用)

様々な異常事象を容易に模擬できるPWRプラントシミュレータを使用して、適応学習付フィードフォワード型ニューラルネットワークの異常検知性能の評価を行った。運転員訓練用に作成されたPWRコンパクトシミュレータは、実際の原子炉の運転状況に近いように設計されているため、自動制御系と監視システムが常時作動しており、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。

このPWRシミュレータを用いて、定常運転時及び過渡運転時のシミュレーションデータを作成し、正常な運転データのみを学習させたフィードフォワード型ネットワークでモデル化を行った。12の主要なプラント信号を入力及び出力とした3層のオートアソシエイティブネットワークは、学習則としてバックプロパゲーションアルゴリズムを採用した。ニューラルネットワークは、その初期学習においてプラントの基本的なモデルを構築し、その後の適応学習においてプラント動特性や緩やかな状態の変化にモデルを追従させることができた。

定常運転データのみを初期学習させたネットワークは、定常運転時に発生した異常事象を、従来の警報システムよりもはるかに早い段階で検知することに成功した。次に、定常運転と過渡運転データの両方を学習させたネットワークで、定常運転時及び過渡運転時に発生した異常事象の検知を行った。その結果、定常運転時に起こった異常は、定常運転データのみを学習させたネットワークとほぼ同じ時間で検知された。また、過渡運転時の異常に関しても、定常時と同程度の短い時間で異常を検知できることが明らかになった。特に、従来の警報システムによるアラームが鳴らないような微小な異常兆候に対しても有効

であった。

さらに、適応学習を行うことによって、本来動特性のモデル化が困難なフィードフォワード型ネットワークでも、プラントの特性の変化にネットワークモデルを追従させることが可能であることが証明され、しかも的確に異常を検知できることも示された。

7. 2 適応学習付フィードフォワード型ニューラルネットワークによる異常検知 (実炉への適用)

オランダにあるPWR実プラント **Borssele** 原子力発電所のために、ニューラルネットワークを利用した実時間プラント監視システムを開発し、異常検知に適用した。原子炉のモデル化には、12の主要なプラント信号を入力と出力にした適応学習付フィードフォワード型オートアソシアティブネットワークを使用した。隠れ層のユニット数は、実時間での監視及び適応学習時間を考慮して8個に設定した。実際の初期学習では、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を低出力から100%出力までの広範囲にわたってランダムに学習させ、ネットワークによるモデル化を行った。また、監視の際にプラントが異常であるかどうかの判定基準となるしきい値の設定は、初期学習の際に得られた各チャンネル毎の最大誤差の1.25倍と定義した。この係数は、経験的に得られた値であり、1.25より小さく設定した場合には、正常運転時においても頻繁に異常を誤検知した。

このニューラルネットワークを使用して、1年間にわたる第19期燃料サイクルの期間中、オフライン及びオンラインでの原子炉異常監視を行った。ニューラルネットワークで実際のプラント診断を開始した場合、適応学習を行わないと1週間以内にプラントの状態変化にネットワークモデルが追従できなくなり、正常運転時においても誤警報を発することが明らかになった。したがって、実際の原子炉に適用する場合には、適応学習が不可欠であり、しかも有効に動作することが示された。

オフライン及びオンライン監視の結果、ニューラルネットワークが従来の監視システムや運転員が気づかないようないくつかの微小な異常兆候を検知できることが明らかになった。この監視システムは、1997年2月の原子炉の大幅な改造工事のため長期間炉が停止するまでの数年間、原子力プラント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常時稼働しており、原子炉の異常予知診断に大きく役立った。2000年10月より原子炉の運転が再開されており、データ収録システムの再構築後に本監視システムの再起動が期待される。

7. 3 感度解析

ニューラルネットワークで原子力プラントのモデル化を行い異常監視に利用する際、も

っとも大きな問題点は、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ため、異常監視システムの信頼性が保証されないことであった。そこで、PWR シミュレータ及び実炉に適用したフィードフォワード型ネットワークを使用して、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の感度解析を試み、入力信号に対する出力信号の寄与度を計算した。特に、入力と出力信号が同一のオートアソシアティブネットワークを使用している場合、各信号の自己寄与率を求めることは、モデル化の妥当性を検証する上で重要な解析である。これらの解析によって、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、20%程度に収まっていることが明らかになった。また、ニューラルネットワーク内部の結合状態を簡素化する忘却付き学習則でも、ほぼ同様な結果が得られた。したがって、感度解析がネットワーク内部構造の解明に有効であること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力プラントをモデル化できていることが証明された。

7.4 リカレントネットワークによる異常検知（PWRプラントシミュレータへの適用）

適応学習を行ったフィードフォワード型ニューラルネットワークを用いると、定常運転時だけでなく過渡運転時においても微少な異常兆候を早期検知できることが明らかになった。しかし一方では、適応学習を行うことにより、非常にゆっくりと進行する異常事象データを学習し、その結果として異常を検知できない危険性も無視できない。そこで、出力層から中間層へのフィードバック結合を持つリカレントニューラルネットワークを採用することにより、原子力プラントの動特性をモデル化し、適応学習なしでどの程度までモデルの変化に追従できるかを調べた。また、従来の警報システム及びフィードフォワード型ネットワークとの異常検知性能の比較も行った。

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リカレントネットワークでモデル化された。ニューラルネットワークの入力及び出力信号は、12個のプラント信号であるが、ネットワーク出力は、入力信号の1秒後の予測値とした。リカレントネットワークは、より複雑な内部構造を有するため、初期学習の収束が学習率等のパラメータに大きく依存し、フィードフォワード型に比べて学習パラメータの選択には十分な注意が必要であった。

PWRシミュレータを利用した異常診断の結果、微小でゆっくりした異常事象の場合には、リカレントネットワークは、従来の警報システムやフィードフォワード型ネットワークに比べて早い段階で異常事象を検知できることが示された。しかしながら、それ以外のほとんどの異常事象に対しては、フィードフォワード型とリカレントネットワークで異常検知性能に大きな差は見られなかった。これは、軽水炉の場合、プラントの動特性が比較的速いため2つのネットワークの違いが顕著に現れなかったためだと考えられる。

7. 5 高温ガス炉への応用

これまで研究を進めてきたニューラルネットワークによる異常検知手法に、エキスパートシステムを組み合わせて、より信頼性の高い、高温ガス炉用ハイブリット監視システムの開発を進めている。高温ガス炉は、原子炉から高温のガスを取り出すことにより、発電のみならず化学工業の分野にも原子力を利用する事を目的とした、将来型原子炉の一つである。高温工学試験研究炉（HTTR）は、そのための試験炉として日本原子力研究所で建設され、現在は各種試験が行われている段階である³¹⁾。HTTR用のプラント監視システムは、プラントのモデル化にリカレントネットワークを採用し、ネットワークの出力結果を基にルールベースのエキスパートシステムを構築することによって、異常事象の特定・診断を行うものである。高温ガス炉の動特性は、PWRのような軽水炉に比べて緩やかであるため、フィードフォワード型ネットワークではモデル化学習を収束させることができなかった。

最初のステップとして、高温ガス炉用プラント動特性解析コードACCORD³²⁾を使用して異常事象を発生させ、リカレントネットワークによる異常検知を行った結果、リカレントネットワークを利用した監視システムが、HTTRの早期異常検知に有効であることが明らかになった³³⁾。しかし一方では、今回の解析から、現在の1タイムステップフィードバック結合では、HTTRの緩やかな動特性にネットワークモデルが追従できなくなる場合が出てくることも判明した。

現在、リカレントネットワークのアルゴリズムを改良して、より正確な原子炉動特性モデルの作成と、異常検知性能の向上を目指している。また、エキスパートシステム部は、シミュレーションによる異常事象データベースの作成と、運転員をサポートするためのマンマシン・インターフェースを考えた監視画面の作成を進め、近い将来、HTTRに適用することが望まれる。

7. 6 今後の課題

ニューラルネットワークを原子炉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、知識ベースや推論エキスパートシステムと組み合わせた多重手法統合方式が望ましいと考えられる。

次の段階では、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予測値の偏差の時系列パターンをデータベース化し、現在原研で開発を進めている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が可能となる。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。

- 15) 鍋島邦彦、野瀬 正一、工藤 和彦、鈴木 勝男, 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, JAERI-Research 96-051 (1996)
- 16) 村上喜光、内藤彰、横林正雄：“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)”, JAERI-M 83-048 (1983)
- 17) 内藤彰、村上喜光、横林正雄：“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)”, JAERI-M 83-081 (1983)
- 18) 花山育志：“ニューラルネットワークを用いた原子力プラント監視システムの研究”,九州大学工学部応用原子核工学科卒業研究論文 (1996)
- 19) Türkcan, 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)
- 20) Nabeshima, K., Türkcan, E. and Ciftcioglu, Ö. : “Real-time Nuclear Power Plant Monitoring with Adaptively Trained Neural Network”, Proceedings of the International Conference on Artificial Neural Networks, p.863 (Amsterdam, 1993)
- 21) Nabeshima, K., Türkcan, E. and Ciftcioglu, Ö. : “Nuclear Power Plant Monitoring using Real-time Learning Neural Network”, Proceedings of Specialists' Meeting on Application of Artificial Intelligence and Robotics to Nuclear Plants (AIR'94), pp.313-322 (Tokai, 1994)
- 22) 鍋島邦彦、鈴木 勝男、篠原 慶邦、Türkcan, E. :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, JAERI-Research 95-076 (1995)
- 23) Nabeshima, K., Suzudo, T., Suzuki, K. and Türkcan, E. : “Real-time Nuclear Power Plant Monitoring with Neural Network”, Journal of Nuclear Science and Technology, Vol.35, No.2, pp.93-100 (1998)
- 24) Nabeshima, K., Suzuki, K. and Türkcan, E. : “Real-time Nuclear Power Plant Monitoring with Hybrid Artificial Intelligence System”, Proceedings of 9th Power Plant Dynamics, Control & Testing Symposium, Vol.2., pp.51.01-09 (Knoxville, 1995)
- 25) Nabeshima, K., Suzuki, K. and Türkcan, E. : “Neural Network with an Expert System for Real-time Nuclear Power Plant Monitoring”, Proceedings of a Symposium on Nuclear Reactor Surveillance and Diagnostics VII (SMORN-VII), Vol. 1., pp.269-277 (Avignon, 1995)
- 26) Nabeshima, K., Suzuki, K., Türkcan, E. and Ciftcioglu, Ö. : “On-line Nuclear Power Plant Monitoring with Neural Network”, Proceedings of Third International Conference on Nuclear Engineering (ICONE-3), Vol.3, pp.1551-1556 (Kyoto, 1995)
- 27) Nabeshima, K., Inoue, K., Kudo, K. and Suzuki, K. : “Nuclear Power Plant Monitoring with Recurrent Neural Network”, Proceedings of the Fourth International Conference on Engineering Applications of Neural Networks, pp.257-260 (Gibraltar, 1998)
- 28) Nabeshima, K., Inoue, K., Kudo, K. and Suzuki, K. : “Early Fault Detection for Nuclear Power Plant using Recurrent Neural Network”, Proceedings of the Fifth International Conference on Neural Information Processing, Vol.2, pp.1102-1105 (Kitakyushu, 1998)

- 29) Nabeshima, K., et al., "Plant Monitoring With the Combination of Recurrent Neural Network and Real-Time Expert System", ANS/ENS International Meeting; Nuclear Plant Instrumentation, Control and Human-Machine Interface, (Washington D.C., 2000)
- 30) Saito, S., et al. : "Design of High Temperature Engineering Test Reactor (HTTR)", *JAERI 1332*. (1994)
- 31) 竹田武司、橘幸男、國富一彦、板倉洋文：“高温ガス炉用プラント動特性解析コード 'ACCORD' の開発” , JAERI-Data/Code 96-032 (1996)
- 32) Nabeshima, K., et al., "Hybrid Monitoring System for High Temperature Gas Cooling Reactor", Proceedings of 8th International Conference on Human-Computer Interaction, Vol. 2, pp.1187-1191 (Munich, 1999)

This is a blank page.

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
物質質量	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

$1 \text{ eV} = 1.60218 \times 10^{-19} \text{ J}$
 $1 \text{ u} = 1.66054 \times 10^{-27} \text{ kg}$

表5 SI接頭語

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

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^{-1}
力	ニュートン	N	$\text{m} \cdot \text{kg} / \text{s}^2$
圧力, 応力	パスカル	Pa	N / m^2
エネルギー, 仕事, 熱量	ジュール	J	$\text{N} \cdot \text{m}$
工率, 放射束	ワット	W	J / s
電気量, 電荷	クーロン	C	$\text{A} \cdot \text{s}$
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	S	A / V
磁束密度	ウェーバ	Wb	$\text{V} \cdot \text{s}$
インダクタンス	テスラ	T	Wb / m^2
セルシウス温度	セルシウス度	$^{\circ}\text{C}$	
光束度	ルーメン	lm	$\text{cd} \cdot \text{sr}$
照射度	ルクス	lx	lm / m^2
放射能	ベクレル	Bq	s^{-1}
吸収線量	グレイ	Gy	J / kg
線量等量	シーベルト	Sv	J / 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	\AA
バーン	b
バル	bar
ガリ	Gal
キュリー	Ci
レントゲン	R
ラド	rad
レム	rem

$1 \text{ \AA} = 0.1 \text{ nm} = 10^{-10} \text{ m}$
 $1 \text{ b} = 100 \text{ fm}^2 = 10^{-28} \text{ m}^2$
 $1 \text{ bar} = 0.1 \text{ MPa} = 10^5 \text{ Pa}$
 $1 \text{ Gal} = 1 \text{ cm} / \text{s}^2 = 10^{-2} \text{ m} / \text{s}^2$
 $1 \text{ Ci} = 3.7 \times 10^{10} \text{ Bq}$
 $1 \text{ R} = 2.58 \times 10^{-4} \text{ C} / \text{kg}$
 $1 \text{ rad} = 1 \text{ cGy} = 10^{-2} \text{ Gy}$
 $1 \text{ rem} = 1 \text{ cSv} = 10^{-2} \text{ Sv}$

(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, ヘクタ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のカテゴリーに分類されている。
- E C閣僚理事会指令では bar, barnおよび「血圧の単位」mmHgを表2のカテゴリーに入れている。

換算表

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

粘度 $1 \text{ Pa} \cdot \text{s} (\text{N} \cdot \text{s} / \text{m}^2) = 10 \text{ P (ポアズ)} (\text{g} / (\text{cm} \cdot \text{s}))$

動粘度 $1 \text{ m}^2 / \text{s} = 10^4 \text{ St (ストークス)} (\text{cm}^2 / \text{s})$

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

エネルギー・仕事・熱量	J (=10 ⁷ erg)	kgf·m	kW·h	cal (計量法)	Btu	ft·lbf	eV
	1	0.101972	2.77778×10^{-7}	0.238889	9.47813×10^{-4}	0.737562	6.24150×10^{18}
	9.80665	1	2.72407×10^{-6}	2.34270	9.29487×10^{-3}	7.23301	6.12082×10^{19}
	3.6×10^6	3.67098×10^5	1	8.59999×10^5	3412.13	2.65522×10^6	2.24694×10^{25}
	4.18605	0.426858	1.16279×10^{-6}	1	3.96759×10^{-3}	3.08747	2.61272×10^{19}
	1055.06	107.586	2.93072×10^{-4}	252.042	1	778.172	6.58515×10^{21}
	1.35582	0.138255	3.76616×10^{-7}	0.323890	1.28506×10^{-3}	1	8.46233×10^{18}
	1.60218×10^{-19}	1.63377×10^{-20}	4.45050×10^{-26}	3.82743×10^{-20}	1.51857×10^{-22}	1.18171×10^{-19}	1

$1 \text{ cal} = 4.18605 \text{ J}$ (計量法)
 $= 4.184 \text{ J}$ (熱化学)
 $= 4.1855 \text{ J}$ (15 $^{\circ}\text{C}$)
 $= 4.1868 \text{ J}$ (国際蒸気表)
 仕事率 1 PS (仏馬力)
 $= 75 \text{ kgf} \cdot \text{m} / \text{s}$
 $= 735.499 \text{ W}$

放射能	Bq	Ci
	1	2.70270×10^{-11}
	3.7×10^{10}	1

吸収線量	Gy	rad
	1	100
	0.01	1

照射線量	C/kg	R
	1	3876
	2.58×10^{-4}	1

線量当量	Sv	rem
	1	100
	0.01	1