



JAEA-Technology

2008-082

JAEA-Technology

ニューラルネットワークに基づく HTTR850°C 30 日間運転時の運転監視

HTTR Operation Monitoring with Neural Network in 30 Days Operation at 850°C

清水 厚志 鍋島 邦彦 中川 繁昭

Atsushi SHIMIZU, Kunihiko NABESHIMA and Shigeaki NAKAGAWA

大洗研究開発センター
高温工学試験研究炉部

Department of HTTR
Oarai Research and Development Center

January 2009

Japan Atomic Energy Agency

日本原子力研究開発機構

本レポートは独立行政法人日本原子力研究開発機構が不定期に発行する成果報告書です。
本レポートの入手並びに著作権利用に関するお問い合わせは、下記あてにお問い合わせ下さい。
なお、本レポートの全文は日本原子力研究開発機構ホームページ (<http://www.jaea.go.jp>)
より発信されています。

独立行政法人日本原子力研究開発機構 研究技術情報部 研究技術情報課
〒319-1195 茨城県那珂郡東海村白方白根 2 番地 4
電話 029-282-6387, Fax 029-282-5920, E-mail:ird-support@jaea.go.jp

This report is issued irregularly by Japan Atomic Energy Agency
Inquiries about availability and/or copyright of this report should be addressed to
Intellectual Resources Section, Intellectual Resources Department,
Japan Atomic Energy Agency
2-4 Shirakata Shirane, Tokai-mura, Naka-gun, Ibaraki-ken 319-1195 Japan
Tel +81-29-282-6387, Fax +81-29-282-5920, E-mail:ird-support@jaea.go.jp

ニューラルネットワークに基づく HTTR850°C 30 日間運転時の運転監視

日本原子力研究開発機構
大洗研究開発センター 高温工学試験研究炉部
清水 厚志・鍋島 邦彦⁺・中川 繁昭⁺

(2008年 11月 6日受理)

高温工学試験研究炉（HTTR）は、初めて 30 日間の定格運転（原子炉出口冷却材温度 850°C）を平成 19 年 3 月 27 日から 4 月 26 日にかけて実施した。本運転において、ニューラルネットワークを用いた運転監視モデルにより HTTR の監視を行い、定格出力時における状態量の微少な変動の検知性能について検証した。運転監視に用いたニューラルネットワークは、3 層構造の階層型で 31 入力 31 出力、隠れ層が 20 ユニットから形成されるオートアソシアティブネットワークで、学習則には誤差逆伝播法を用いた。運転監視モデルについては、原子炉出力 30%～定格運転間の出力上昇中のデータをランダムに学習させて初期学習モデルを構築し、定格運転時の原子炉の燃焼等に伴う状態量の変化に合わせて、初期学習モデルの内部構造を変えていく適応学習を行なながら運転監視を行った。その結果、制御系動作による微少な状態量の変動等を検知し、原子炉施設の早期異常診断に適用できる見通しを得た。

大洗研究開発センター：〒311-1393 茨城県東茨城郡大洗町成田町 4002

+原子力基礎工学研究部門 核熱応用工学ユニット

HTTR Operation Monitoring with Neural Network in 30 Days Operation at 850°C

Atsushi SHIMIZU, Kunihiro NABESHIMA⁺ and Shigeaki NAKAGAWA⁺

Department of HTTR
Oarai Research and Development Center
Japan Atomic Energy Agency
Oarai-machi,Higashiibaraki-gun,Ibaraki-ken

(Received November 6 , 2008)

The High temperature engineering test reactor (HTTR) executed the rated power operation for 30days of the first time (850°C in temperature of the nuclear reactor outlet coolant) until March, 27th through April, 26th, 2007. In this operation, HTTR was observed according to the operation monitoring model with the neural network, and the detection performance of neural network was verified during slight changes of reactor state at rated power. The neural network used for the operation monitoring was an auto-associative network, where 31 input 31 outputs and the hidden layers were connected with 20 units by the hierarchy of three layer structure. Back-propagation algorithm was used for study rule. The operation monitoring model in initial study was constructed by using the power up data between 30% and rated power, which were randomly studied. The adjustment study during the operation monitoring changes the internal structure of the initial study model to follow the changes of reactor status, such as the burn-up of the nuclear fuel for the rated power operation. As a monitoring result, slight changes of reactor state by the control system operation were correctly detected, and the on-line application to an early anomaly diagnosis for HTTR facilities will be expected.

Keywords: HTTR , Neural Network , Operation Monitoring , Auto-associative Network ,
Early Anomaly Diagnosis

+Nuclear Applied Heat Technology Division, Nuclear Science and Engineering Directorate

目 次

1. はじめに-----	1
2. HTTRの概要-----	2
2.1 設備の概要-----	2
2.2 30日間連続運転の概要-----	2
3. ニューラルネットワークの概要-----	5
3.1 概要-----	5
3.2 ニューロンの動作モデル-----	5
3.3 ネットワーク構造-----	6
3.4 学習アルゴリズム-----	6
3.4.1 誤差逆伝播法アルゴリズム-----	6
3.4.2 適応学習アルゴリズム-----	7
3.5 データの規格化-----	8
3.6 ネットワーク初期値の設定-----	9
4. ニューラルネットワークによる30日間連続運転の監視-----	12
4.1 HTTRのモデル化-----	12
4.1.1 プラント監視信号の選択-----	12
4.1.2 初期学習-----	12
4.1.3 中間層のユニット数-----	13
4.1.4 学習パラメータの設定-----	13
4.1.5 異常判定しきい値の設定-----	13
4.2 運転監視結果-----	14
4.2.1 適応学習の効果-----	14
4.2.2 制御系動作の検知-----	14
4.3 再モデル化後の運転監視結果-----	15
5. まとめ-----	43
謝辞-----	44
参考文献-----	44

Contents

1. Introduction -----	1
2. The Outline of the HTTR -----	2
2.1 The Outline of the HTTR-----	2
2.2 The Outline of the Operation for 30days running -----	2
3. The Outline of the Neural Network -----	5
3.1 The Outline the Neural Network -----	5
3.2 Dynamic Model of Neuron -----	5
3.3 Network structure-----	6
3.4 Learning Algorithm-----	6
3.4.1 Back-Propagation Algorithm -----	6
3.4.2 Adaptive Learning Algorithm -----	7
3.5 Input and Output Data Normalization -----	8
3.6 Initial Setting of Network Parameter -----	9
4. Monitor of HTTR Running Operation with Neural Network-----	12
4.1 HTTR Modeling by Neural Network -----	12
4.1.1 Signal Selection for Plant Monitoring-----	12
4.1.2 Initial Learning-----	12
4.1.3 Number of Units at Hidden Layer-----	13
4.1.4 Learning Parameter Setting-----	13
4.1.5 Fault Judge Level Setting-----	13
4.2 Monitoring Result of Operation-----	14
4.2.1 Effect of Adapting Learning-----	14
4.2.2 Detection of Control Device action-----	14
4.3 Monitoring Result of Operation at Re-Modeling-----	15
5. Conclusion-----	43
Acknowledgments-----	44
Reference-----	44

1. はじめに

日本原子力研究開発機構（原子力機構）大洗研究開発センターに設置されている高温工学試験研究炉（HTTR : High Temperature Engineering Test Reactor）は、高温ガス炉の技術基盤を確立するとともに、将来の実用化に向けた高温ガス炉技術の高度化及び高温工学に関する先端的基礎研究を実施することを主目的とした黒鉛減速ヘリウム冷却型の原子炉である^{1),2)}。

HTTRは1998年11月10日に初臨界に達した後、1999年9月から出力上昇試験を開始し、2001年12月7日に定格熱出力30MW及び原子炉出口冷却材温度850°Cを達成し^{3),4)}、2002年3月6日に実施した定格熱出力30MWからの商用電源喪失試験をもって定格運転における全ての試験検査を終了し使用前検査合格証を取得した。その後、2004年4月19日には原子炉出力30MW及び原子炉出口冷却材温度950°Cを達成し^{5),6)}、2004年6月24日に高温試験運転に係る使用前検査合格証を受領した。これまでの高温ガス炉の歴史において、950°Cという高温の冷却材を原子炉圧力容器外部に取り出すことに成功したのはHTTRが世界で初めてである。

原子炉の警報機能は、プラントの設備又はプロセスに異常が生じた場合、運転員に告知し、運転員の適切な運転対応操作を可能することが目的であり、原子炉を安全に運転するためには、設計段階において十分な配慮がなされている。しかし、一方では運転中に異常事象の兆候を早い段階で発見することも事故や故障を未然に防ぐ上で重要である。

HTTRでは、異常が発生する際の微少なプラント信号の変動を検知して運転員に告知し、監視及び操作を支援することを目的として、2002年からニューラルネットワークを用いたオンライン運転支援システムの開発を行っている⁷⁾。これまでの研究では、制御棒の誤引抜きのような検知すべき異常事象に対して、監視するパラメータ（信号）を限定して、ニューラルネットワークによる異常検知の有効性を示してきた^{7),8)}。本研究では、プラント全体で発生する様々な異常事象の検知を目指して、監視パラメータを15chから32chに増やし、HTTRの通常運転時に警報レベルに達しないような小さな状態量の変化を検知できるかどうか調べた。ニューラルネットワークは、物理的知識を必要とせず、正常運転データを繰り返し学習することで複雑な非線形の原子炉を精度良くモデル化することが可能であり、学習には比較的長い時間を要するが、一旦学習を終えた後は、高速な処理が可能であるという特徴がある。そこで、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偏差を監視することにより、出力変動時においても異常事象の発見が可能となり、プラント状態の把握を支援することができる。原子炉の出力上昇に一週間以上を要するHTTRにおいて、定格出力時のみならず出力変動中でもきめ細やかにプラントの状態を把握できることは、運転員の負担軽減につながると考えられる。

本報は、HTTR実機による30日間連続運転のデータを使用した、ニューラルネットワークによる原子炉モデルの構築及びリアルタイム運転監視の結果についての報告である。

2. HTTR の概要

2.1 設備の概要

HTTRの基本仕様を第2.1表に示す。HTTRは燃料に被覆粒子燃料、減速材に黒鉛、冷却材にヘリウムガスを使用する定格熱出力30MW、原子炉入口冷却材温度395°C、原子炉出口冷却材温度最高950°Cの高温ガス炉である。HTTRの冷却設備系統を第2.1図に示す。HTTRの原子炉冷却設備は、通常運転時に原子炉を冷却する主冷却設備（1次冷却設備・2次ヘリウム冷却設備・加圧水冷却設備）、原子炉停止後に原子炉の崩壊熱及びその他の残留熱を除去する補助冷却設備、原子炉圧力容器の周囲に設置した水冷管により1次遮へい体を冷却する炉容器冷却設備の大きく3系統の冷却設備で構成されている。補助冷却設備及び炉容器冷却設備は、工学的安全施設であり原子炉施設の異常時に炉心を冷却する機能を有している。

主冷却設備には、中間熱交換器（IHX : Intermediate Heat Exchanger）及び1次加圧水冷却器（PPWC : Primary Pressurized Water Cooler）の2つの熱交換器があり、IHXの2次側に2次加圧水冷却器（SPWC : Secondary Pressurized Water Cooler）がある。通常運転時に原子炉内から発生した熱の大部分は、これらの熱交換器を経由後、加圧水冷却設備である加圧水空気冷却器（ACL : Air-cooler）より大気へ放散される。補助冷却設備は、主冷却設備と並列に構成されており、熱交換器として補助冷却器（AHX : Auxiliary Heat Exchanger）がある。原子炉スクラム時の崩壊熱等の残留熱は、補助冷却器を経由後、補助冷却水空気冷却器より大気に放散される。炉容器冷却設備には、原子炉圧力容器の外面から間接的に炉心を冷却するために設けられた水冷管パネルがある。1次遮へい体のコンクリートを冷却し昇温した水の熱は、熱交換器である炉容器冷却設備冷却器を経由した後、補機冷却水設備の冷却塔より大気へ放散される。HTTRの運転方法には、PPWCで20MW、IHX・SPWCで10MWの除熱を行う並列運転とIHX・SPWCは使用せずにPPWCのみで30MWの除熱を行う単独運転がある。さらに、原子炉出口温度が850°Cの定格運転及び950°Cの高温試験運転がある。

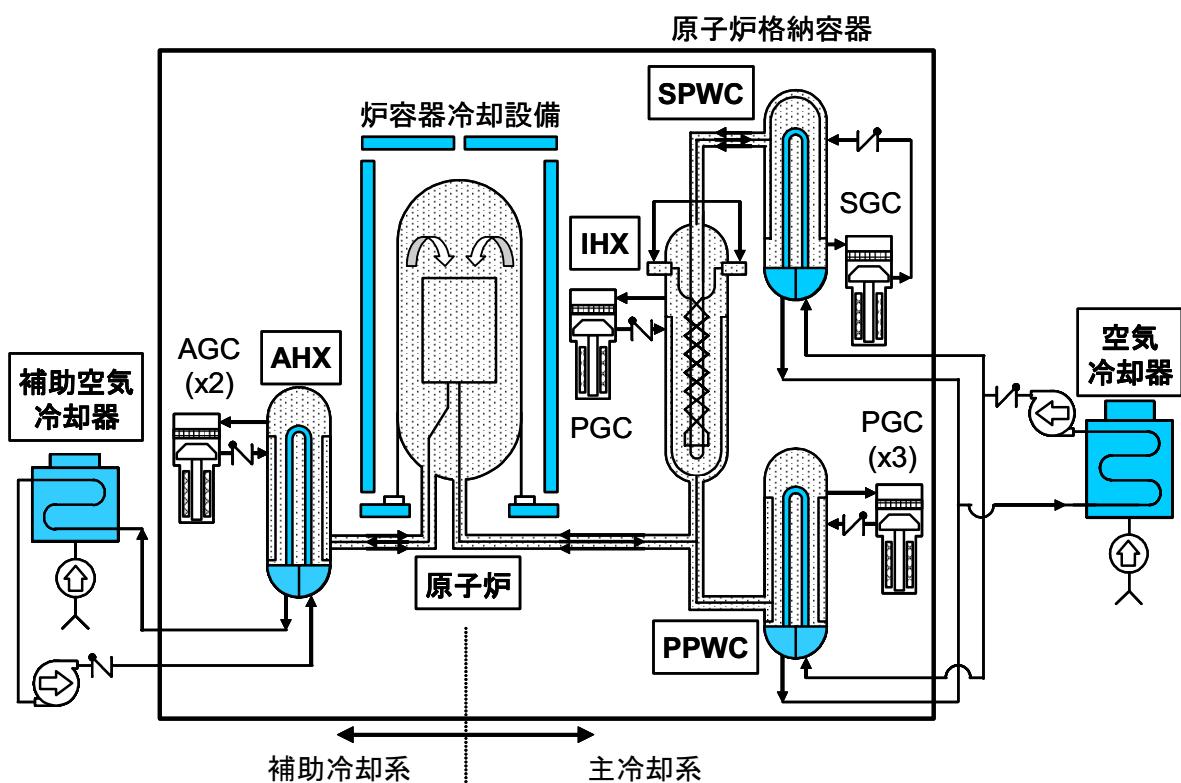
2.2 30日間連続運転の概要

HTTRでは、定格並列運転（RP : Rated Operation Parallel Loaded）サイクル RP-10において、高温ガス炉の技術基盤の確立のため、運転開始以来初めて連続30日間の定格運転（原子炉出口温度850°C）を行った。この運転は、炉心の燃焼特性、燃料の性能、ヘリウムの純度管理、高温機器の性能等に関するデータを取得・蓄積し、次世代高温ガス炉開発のための運転データを取得・蓄積するとともに、高温50日運転（平成21年度実施予定）に先立ち、長期の安定運転に係る機器性能の確認を行うことを目的としたものである。

RP-10は、1次系の除熱に加圧水冷却器（PPWC）及び中間熱交換器（IHX・SPWC）を使用する並列モードで実施した。原子炉を平成19年3月19日に起動し、3月27日に熱出力29.6MWに到達した。その後、運転を継続し30日後の4月26日に出力降下を開始し、5月3日に原子炉を停止した。全運転日数は46日であった。

第 2.1 表 高温工学試験研究炉（HTTR）の基本仕様

原子炉熱出力	:	30MW
燃料	:	UO ₂ 被覆粒子
燃料体形式	:	ブロック型
炉心構造材	:	黒鉛
炉心冷却材	:	ヘリウムガス
主冷却ループ数	:	1 ループ（加圧水冷却器及び中間熱交換器）
1 次冷却材圧力	:	約 40 kg/cm ² G (定格出力時・ヘリウム冷却)
2 次冷却材圧力	:	約 41 kg/cm ² G (定格出力時・ヘリウム冷却) 約 35 kg/cm ² G (定格出力時・加圧水冷却)
		(定格運転時) (高温試験運転時)
原子炉入口冷却材温度	:	395°C
原子炉出口冷却材温度	:	850°C 950°C



IHX : 中間熱交換器
 PPWC : 1次加圧水冷却器
 PGC : 1次ヘリウム循環機
 SPWC : 2次加圧水冷却器
 SGC : 2次ヘリウム循環機
 AHX : 補助冷却器
 AGC : 補助ヘリウム循環機

第 2.1 図 HTTR の冷却系統

3. ニューラルネットワークの概要

3.1 概要

人工ニューラルネットワークとは、脳組織における神経細胞ネットワークの情報伝達構造をモデル化したソフトコンピューティング技術の一つであり、その特徴としてデータ学習による対象のモデル化や、モデルに基づいた類似状況への適応が挙げられる。また、多入力多出力構造による並列分散処理が可能であり、学習には比較的長い時間を要するが、一旦学習を終えた後は、高速な処理が可能であるという点が挙げられる⁹⁾。

この章では、本研究に用いたニューラルネットワークの概要として、神経細胞機能のモデル化手法の基本であるニューロンの動作モデル、ネットワーク構造、学習アルゴリズム等について記述する。

3.2 ニューロンの動作モデル^{9),10),11)}

ニューラルネットワークは、生物の脳の神経細胞（ニューロン）の結合及び構築の状態を単純化したモデルで表したもので、数学的には複数の入力から複数の出力への非解析的な非線形写像を与えるものである。元来、生物の脳の神経細胞は、第3.1(a)図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そうとし、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では、このような神経細胞の働きを第3.1(b)図のように単純化した工学的モデルで表したものである。ここで個々のニューロン（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番目のユニットに注目すると、このユニットへの入力 I_j^k は、k-1層にあるユニットからの出力 O_i^{k-1} に重みをかけたものの総和として表せる。

$$I_j^k = \sum_i W_{i,j}^{k-1,k} \cdot O_i^{k-1} \quad (3-1)$$

さらに、この入力は、入出力関数 $f(x)$ 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になる。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

$$f(x) = \begin{cases} 1 & (x \geq \theta) \\ 0 & (x < \theta) \end{cases} \quad (3-2)$$

で近似される。しかし、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には、入出力信号は連続的であることから、ここでは入出力関数として下式のようなシグモイド関数を使用した。

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

したがって、出力信号は

$$O_j^k = f(I_j^k) = \frac{1}{1+e^{-(I_j^k-\theta_j^k)}} \quad (3-4)$$

となる。

3.3 ネットワーク構造^{9),10),11)}

ニューラルネットワークの構造には、大きく分けて第3.2図に示すように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。入力層と出力層の中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。階層型ニューラルネットワークは、通常各層間の結合のみで、同一層内でのユニットの結合は考えていない。また、この種のネットワークでは、情報がネットワーク中を1方向へ1度流れて状態変化が終了する。最もよく用いられている階層型は、誤差逆伝播アルゴリズムを用いたネットワークで、フィードバック結合がなく、教師信号を必要とする。

一方、相互結合型ニューラルネットワークは、階層構造を作らず、近傍にあるユニット間の相互結合によって構成されており、入力ユニットと出力ユニットが区別されていない。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。

今回の運転監視にあたっては、階層型を採用し、なかでも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ネットワーク（自己連想型）を用いた。従って、出力層の各ユニットの信号は、入力層の各ユニットの信号と全く同じになる。このネットワークは基本的に多入力1出力のネットワークを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とされている。

3.4 学習アルゴリズム^{9),10),11)}

3.4.1 誤差逆伝播法（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法（バックプロパゲーション）アルゴリズムを採用した。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とするようにユニット間の重みを変えていく方法である。誤差逆伝播法では、第3.3図のk-1層のi番目とk層のj番目のユニット間の重みの変化 $\Delta W_{i,j}^{k-1,k}$ は、学習回数t回目において以下のように求められる。

$$W_{i,j}^{k-1,t}(t) = W_{i,j}^{k-1,k}(t-1) + \Delta W_{i,j}^{k-1,k}(t) \quad (3-5)$$

$$\Delta W_{i,j}^{k-1,t}(t) = \eta \cdot \delta_j^k \cdot O_i^{k-1} + \alpha \cdot \Delta W_{i,j}^{k-1,k}(t-1) \quad (3-6)$$

ここで、 η は学習率と呼ばれるもので、1 回の学習で修正される大きさを決めるパラメータである。 δ は k 層 j 番目ユニットにおける誤差信号で、出力層 M において

$$\delta_j^M = (Y_j - O_j^M) \cdot f'(I_j^M) = O_j^M \cdot (1 - O_j^M) \cdot (Y_j - O_j^M) \quad (3-7)$$

その他の中間層においては、

$$\delta_j^k = f'(I_j^k) \cdot \sum_p W_{j,p}^{k,k+1} \delta_p^{k+1} = O_j^k \cdot (1 - O_j^k) \cdot \sum_p W_{j,p}^{k,k+1} \delta_p^{k+1} \quad (k=M-1, \dots, 2) \quad (3-8)$$

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。(3-7)式の Y_j は教師信号、 f' は入出力関数の微分であり、(3-4) 式のようなシグモイド関数を用いているため(3-7)式のように簡単な形で表すことができる。また、(3-6)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、学習速度を速めるために用いられ、また、求めるべき最小値ではなく学習途中の極小値で学習が収束することを防ぐために加えられているものである。 α はモーンメンタム項の係数で正の小さい数が用いられる。

一般的には、学習率 η 及びモーメンタム項 α は、学習の初期段階においては大きいほうが、またある程度学習が進んで誤差が小さくなってくると小さい方が学習が早く収束するといわれている。そこで、実際の適用では、学習率 η とモーメンタム項 α を学習回数に応じて小さくなるように設定した。

3.4.2 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り、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、実際の原子炉の運転では定常運転中であっても燃料の燃焼等により日々に状態が変化するため、運転サイクル初期と末期では、同じモデルを使用することができない。そこで、典型的な運転パターンを学習する初期学習と、運転監視中の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による適応学習の2つ学習過程を考える必要がある。初期学習では、低出力状態から定格出力状態までの学習データを広範囲に渡って学習し、重み、しきい値等のネットワーク情報を決定し原子炉をモデル化する。学習が広範囲に渡るのは、ニューラルネットワークは、学習範囲外の適用が難しいからである。また、学習の際には、ランダムに学習するモードと決められた順序で学習するモードがあり、一般的にはランダムに学習したほうが学習の収束が早いとされる。初期学習で使用した学習データは以後使用することは無く、初期学習で得た、重み、しきい値等のネットワーク情報は、運転監視に用いる適用学習の初期値として与えられる。

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

トワークによる推定を行う。ニューラルネットワークに入力される運転パターンが、初期学習と同様な場合、ニューラルネットワークの推定値と実測値は同じような値を示し、学習されていない運転パターンが入力された場合には、推定値と実測値は異なるてくるはずなので、その誤差（偏差）を監視することにより、微少な異常兆候を検知できる。

推定値と実際の信号の誤差（偏差）が許容範囲（異常判定のしきい値）内にある場合には、プラントを正常とみなし、さらにその最新運転データを用いて適応学習を行う。このときの異常判定のしきい値は、初期学習時における最大誤差を参考にして設定される。実時間による適応学習では、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。適応学習の範囲（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、新しい時刻のデータほど、学習の回数の多くなるように考慮されている。（第3.4図参照）時刻tにおいて、最新データ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、…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

$$X(t-i); ((i=0, j-1), j=1, N)$$

と固定される。第3.4図に示されるように、適応学習データは、新しいデータがくるたびに1つづつ右にシフトしていく。また、このときの学習率η及びモーメンタム項αは、初期学習時に比べて小さい値に設定され、ネットワークの重みとしきい値が更新されていく。

適応学習中に、一つでも信号誤差が異常判定のしきい値を超えた場合には適応学習を行わずにどの信号が異常であるかのメッセージを出力し、次のデータがくるのを待つ。さらに、ここでは異常判定のしきい値による判定を二段階にわけて行う。つまり、ネットワークが原子炉の状態を正常とみなしても、適応学習後にもう一度推定を行い、偏差が新しい異常判定のしきい値（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、この偏差が新しい異常判定の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、次のデータがくるのを待つ。

3.5 データの規格化

入出力信号は、その種類によって値の大きさや変化の割合が変わってくるため、各信号の影響を平等にするために、学習に用いるデータを規格化する必要がある。入力信号は、最大値と最小値が0.5と-0.5になるよう線形に規格した。

$$X_i^{norm} = \frac{X_i^{original} - X_i^{min}}{X_i^{max} - X_i^{min}} - 0.5 \quad (3-9)$$

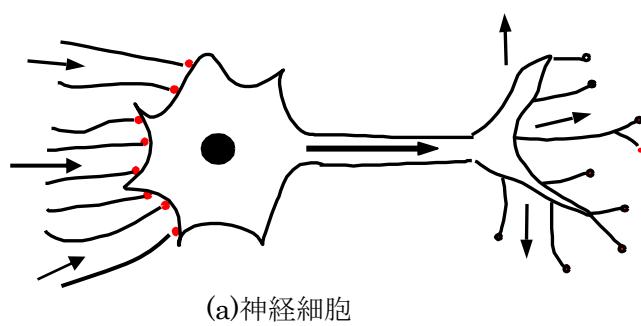
出力信号は、学習に用いるデータの最大値と最小値が0.9と0.1になるよう線形に規格した。

$$Y_i^{norm} = \frac{Y_i^{original} - Y_i^{min}}{Y_i^{max} - Y_i^{min}} \times 0.8 + 0.1 \quad (3-10)$$

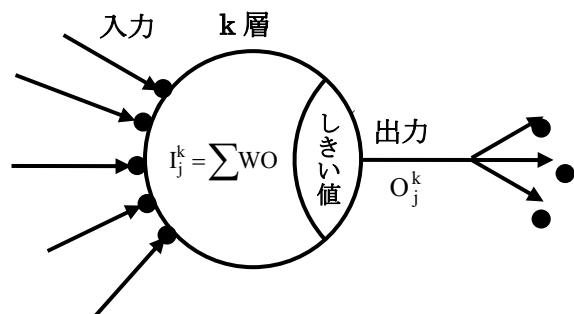
ここで、 $X_i^{original}$ 、 $Y_i^{original}$ は、物理単位の入力及び出力 X_i^{norm} 、 Y_i^{norm} は規格化された入力及び出力である。

3.6 ネットワーク初期値の設定

ユニット間の重み及びしきい値の初期値は、それぞれのユニットの機能分化を促すために、ランダムに設定されている。重みとしきい値の初期値は、それぞれ-0.5~0.5、-1.0~1.0の間の乱数を発生させて設定している。用いる乱数によって、初期のネットワーク構造は全く違ったものになり、学習が収束した後の重み等も大きく異なってくるが、原子炉のモデル化を行う場合には、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はなく、最終的な学習誤差にも大きな差がないことがわかっている。

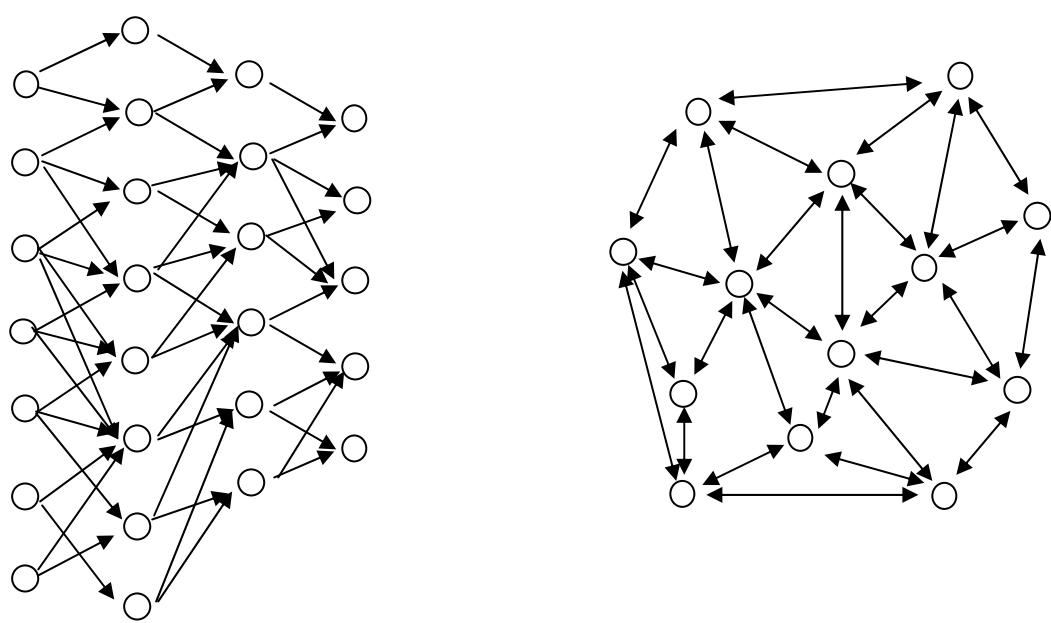


(a) 神経細胞



(b) 工学的モデル

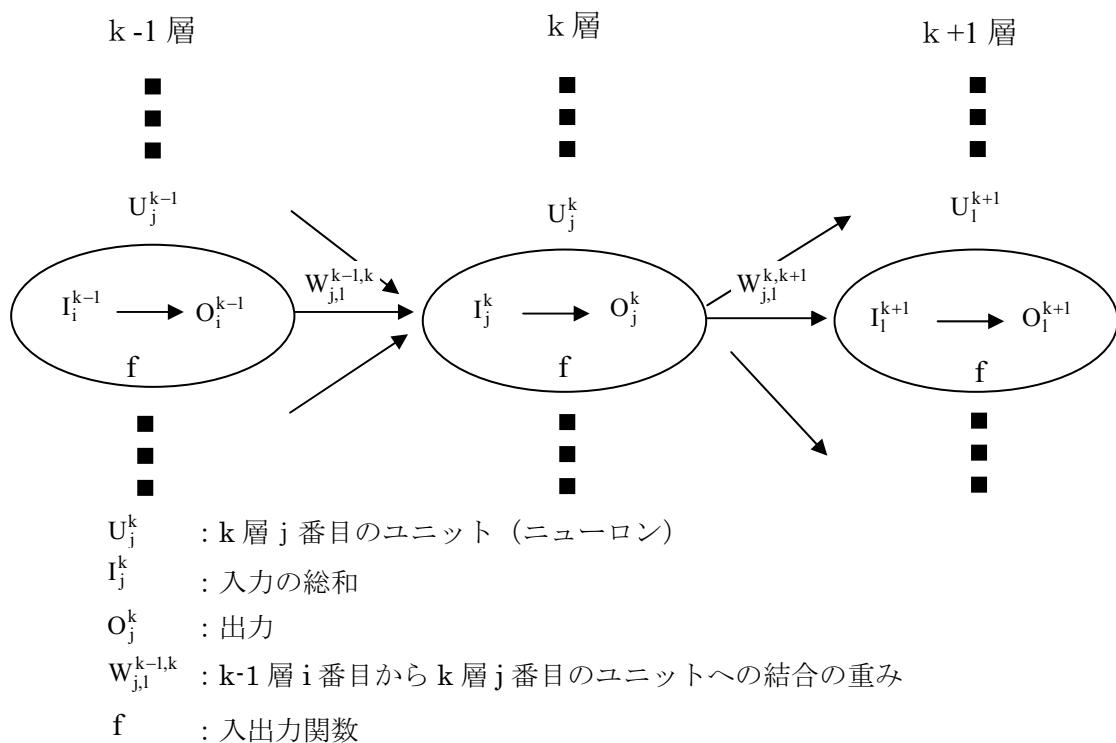
第 3.1 図 神経細胞のモデル



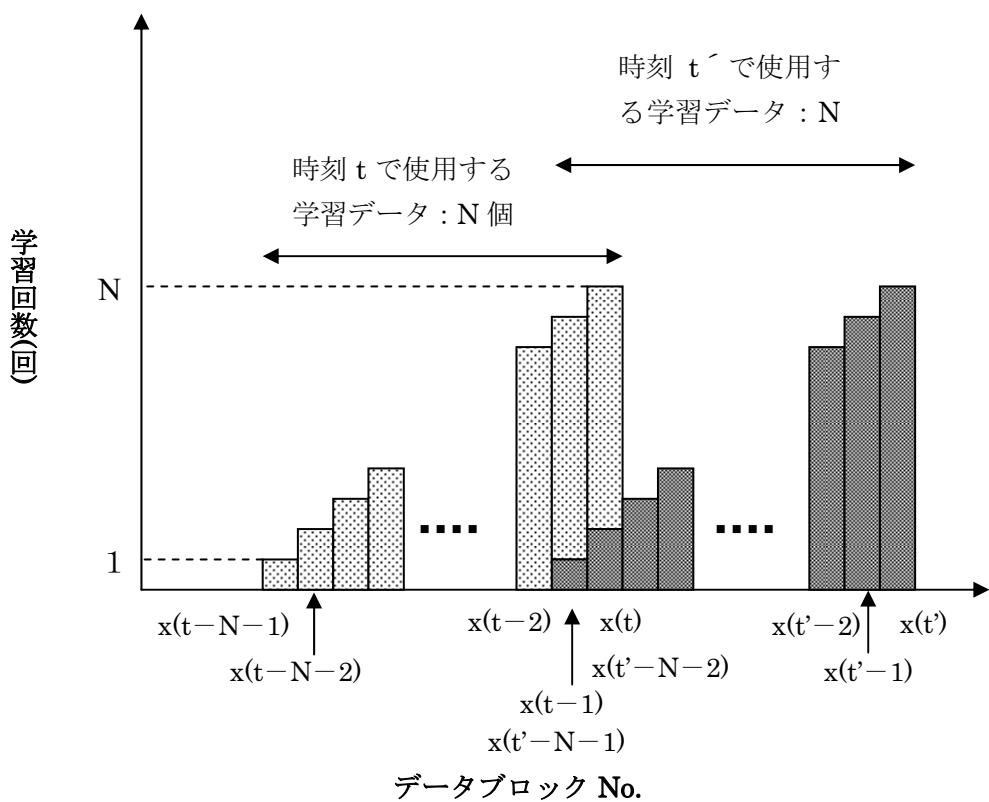
階層型

相互結合型

第 3.2 図 ニューラルネットワークの構造



第 3.3 図 ネットワーク内部のユニット(ニューロン)の結合



第 3.4 図 適応学習データと学習回数

4. ニューラルネットワークによる 30 日間連續運転の監視

4.1 HTTR のモデル化

HTTR 連續運転監視に用いたニューラルネットワークは、フィードバック結合のない 3 層構造の階層型で形成されるオートアソシティブネットワークである。(第 4.1 図 参照)

学習データには HTTR のデータ収集装置 TETRIS から主要な 31 チャンネルを抽出し、学習則には誤差逆伝播法を用いた。初期学習として原子炉出力 30%～定格出力間の出力上昇中及び定格出力中のデータを用いてランダムに学習させ、プラントの基本的なモデルを作成し、そのモデルを基に定格運転 30 日間中の 4/2～4/26 を対象として運転監視を行った。(第 4.2 図 参照) 運転監視に当たっては、定格出力運転中の緩やかな状態変化に合わせて初期学習モデルの内部構造を変えていく適応学習を行った。監視の際に行う異常検知の判定には、ニューラルネットワークの予測値と実測値の偏差がしきい値を超えた場合には、適応学習を行わず、異常として出力するものとした。ニューラルネットワークは原子炉出力 30%～定格出力までの出力上昇中の運転データを用いて初期学習しているので、定格運転中の入力データ 31 チャンネルが、初期学習時と同様なパターンにより入力された場合には、ニューラルネットワークの出力(予測値)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、学習されていないパターンで入力された場合には、各信号の予測値は測定値と異なることになる。従って、その偏差を監視していれば、微少な変化を検知することができる。なお、今回のモデル構築及び運転監視は、データ収集装置 TETRIS から送られてきた HTTR 実機の 30 日間連續運転のデータを使用して、オフライン作業により行った。

4.1.1 プラント監視信号の選択

プラント監視信号の選択については、原子炉運転中の総合的監視という観点から、HTTR のデータ収集装置 TETRIS より送られてくるデータの中から、原子炉の運転に主要と思われる 31 チャンネルを抽出した。本運転監視に用いたプラント信号を第 4.1 表に示す。

4.1.2 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。これは、ニューラルネットワークが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、外挿に関しては不得意とされるからである。従って、初期学習では、広範囲に渡って一様に学習する方が後の監視に有効である。今回、初期学習データには、原子炉出力 30%～定格出力までの出力上昇運転中の 100 秒置きデータ 3024 点と定格出力中の 100 秒置きと 50 秒置きデータ 1044 点を合わせた計 4068 点の 31 チャンネルデータをランダムに選択し、1 点につき 1000 回学習させ、HTTR のモデル化を行った。ここで、0～29%までのデータを学習に用いなかった理由は、0～30%までは、運転員が原子炉を手動で操作しており、運転操作による個々のバラつきが学習に影響を与えると考えたからである。また、ランダムに学習させたのは、一定の順序(時系列)で学習するより学習の収束が早く、誤差が小さいことが分かっているためである。第 4.2 表に初期学習に用いた学習データを示す。第 4.3 図は、初期学習結果を示しており、ここで点線は実測値、実線は推定値で、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。図中の▲は二つの値の偏差を表しており、後述する異常判定しきい値の基礎データの一つとなる。

4.1.3 中間層のユニット数

中間層のユニット数を決定することは、ニューラルネットワークの研究の中でも重要な課題の1つであるが、最適な中間層のユニット数というものは一意的に決まるものではなく、モデルを作成する場合には、試行錯誤的にユニット数を決める必要がある。一般的には、中間層のユニット数が多いほどパターン識別能力が高いが、学習時間を短縮する上では中間層のユニット数は少ない方が望ましいとされている。また、中間層が多すぎると誤差が増加する傾向にあることも指摘されている。初期学習で得られるモデルの良否は、最終的な各チャンネルの実測値とニューラルネットワークの出力値の誤差の二乗和として表すことができる。運転監視にあたっては、より最適な中間層を決定するために初期学習において中間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。第4.4図に示すように、ユニット数が15個未満では学習が収束せず、それ以降はユニット数の増加に応じて、誤差の二乗和が小さくなっている。次にユニット数15個以上の15、20、30個の3ケースについて、初期学習が収束する時間を比較した。(第4.5図参照)その結果、ユニット数の変化に対しては3ケースとも学習回数が300回以降では誤差がほぼ収束しており、学習の収束速度はあまり変わらなかった。以上のことから、今回のモデルでは、中間層ユニット数は最低15個以上は必要で、それ以上では、学習の計算時間にあまり影響ないと考えられることから、誤差が安定したところで多くのパターンを認識できるよう、運転監視に適用する中間層のユニット数は20個を採用した。

4.1.4 学習パラメータの設定

第3章でも述べたように、(3-6)式中の学習率(η)及びモーメンタム項の係数(α)も、学習速度と収束率に大きな影響を与えるパラメータであり、学習の初期段階においては大きいほうが、学習後期では小さい方が学習が早くなるといわれており、この η と α についても試行錯誤的に適当な数値を決定しなければならない。今回は、1000回の学習回数のうち、 η 、 α を一定値1.0で行ったもの(ケース1)、一定値0.5で行ったもの(ケース2)、学習回数が150回までは、 η を1.2、 α を1.5、151回から300回までは、 η を0.6、 α を1.0、301回から1000回までは、 η を0.3、 α を0.5と段階的に小さくしていったもの(ケース3)として比較した。その結果、第4.3表に示すとおり、 η 、 α を一定で行うより、段階的に小さくしていったものの方が最終的な誤差は小さくなった。そこで運転監視では、同表のケース3を運転監視に採用した。

4.1.5 異常判定しきい値の設定

運転監視時に用いる異常診断の判定基準となるしきい値の設定には、初期学習の結果を基にして行う。しきい値には、各信号における初期学習時のモデルの予測値と実測値の偏差の最大値と定格出力運転時の実測値の標準偏差の2倍を比較して、大きい方の値を1.15倍したものをしきい値として定義した。最大誤差のみでなく、標準偏差も参照しているのは、信号の種類によっては、過渡運転時よりも、定格出力時の揺らぎが大きいものが存在するためである。実際に、加圧水冷却器の冷却水流量制御等の一定制御をするものなどは、標準偏差の2倍の値の方が大きくなりやすい傾向にあった。第4.4表に運転監視に用いたしきい値を示す。

なお、しきい値に掛けられる係数は、異常を見逃す確立と誤報の確立から経験的に得られる値

であり、1.15倍以下にした場合には、今回の運転監視で誤報を発生した。

4.2 運転監視結果

4.2.1 適応学習の効果

ニューラルネットワークを軽水炉に適用した場合では、燃料の燃焼等に伴い炉内動特性が変化し、運転サイクル初期と末期では同じモデルを使用することができないため、炉内の動特性の変化に伴ってネットワーク値を更新していく適応学習が不可欠であった。そこで、軽水炉と比較すると緩やかな動特性である HTTRにおいても、適応学習が必要かどうかを検証するために、適応学習 ($\eta : 0.05$ 、 $\alpha : 0.05$) を行ったものと、初期学習モデルのみ ($\eta : 0$ 、 $\alpha : 0$) で運転監視を行ったものの 2 ケースで結果を比較した。その結果、適応学習を行わないと、運転日数の経過と共に生じるプラントの状態変化にニューラルネットワークのモデルが追従できなくなり、正常運転時においても異常として検知した。従って、HTTR でニューラルネットワークを適用する際にも、適応学習が不可欠であることが分かった。第 4.6 図に、例として原子炉出口温度の監視結果を示す。

ここで、適応学習に用いる η と α の値は、誤報の発生しない範囲で初期学習に使用した値に対し十分小さい値に設定することが必要で、この値が大きすぎると異常が発生しても偏差がしきい値を超える前に学習してしまい、結果異常を見逃す可能性がある。運転監視時に用いた η と α の値 0.05 は経験的に得られた値であり、初期学習時に対し、一桁小さい値に設定した。なお、これより小さくした場合には誤報を発報した。

4.2.2 制御系動作の検知

適応学習 ($\eta : 0.05$ 、 $\alpha : 0.05$) での運転監視中、ニューラルネットワークが異常として検知したものに、1 次冷却材・加圧水差圧制御系の異常があった。HTTR では、加圧水冷却設備は、1 次加圧水冷却器において加圧水が 1 次冷却材中へ侵入するのを抑制するために、加圧水加圧器内の窒素ガス圧力を調整することにより、通常運転時の加圧水圧力を 1 次冷却材圧力より約 0.5MPa 低い圧力で制御する。第 4.5 表に示すように 1 次冷却材・加圧水差圧制御系は、制御目標値に対し差圧が大きくなり差圧制御系の制御設定値 0.5488MPa になると、加圧水冷却設備の加圧器に設置されている加圧水加圧器窒素ガス入口弁が開となり窒素ガスが供給される（以下、加圧水加圧動作という。）。逆に制御目標値に対し差圧が小さくなり差圧制御系の制御設定値 0.4312MPa になると、加圧水加圧器窒素ガス出口弁が開となり、窒素ガスが排出される（以下、加圧水減圧動作という。）。この制御系の動作は、出力上昇時や、定格出力時の外気温の変動等による 1 次冷却材の圧力変動にともない、運転中何回か繰り返される。RP-10 では、運転監視中の 4/2 から 4/26 の間に、加圧水加圧動作が 3 回あり、加圧水減圧動作が 3 回あったが、運転監視モデルでは、加圧水減圧動作のみをすべての場合において異常として検知した。第 4.7 図(a) に示すように、加圧水加圧動作の場合には、差圧の変動にニューラルネットワークの予測値が追従しているのに対し、第 4.7 図(b) の加圧水減圧動作の場合には、差圧変動にニューラルネットワークの予測値が追従できなく、差圧制御開始後約 5 秒で偏差がしきい値を超えて異常として検知している。この制御系による動作は、定格運転中には、外気温の変動等により通常的に行われており、運転上の異常を示すものではないことから、ニューラルネットワークが何らかの理由により異常と判断し、

検知した可能性がある。この加圧水加圧動作は検知せず、加圧水減圧動作は検知したという2つの事象について、以下のように考察した。

ニューラルネットワークは一般的に、内挿は得意だが、外挿は不得意とされている。このことから、制御動作が起こったときの各信号のプロセス値が初期学習時の学習範囲に無かった場合には、ニューラルネットワークが実際のプロセス値まで推定することができず異常として検知する可能性があると考えられる。また、経験に基づくモデル構築をしているため、学習していないパターンについては、各信号の相関が崩れるため、異常として検知する可能性があると考えられる。

まず、制御動作が起こったときの31チャンネル信号のプロセス値について、初期学習時の学習範囲と比較した結果、制御動作時に初期学習時のプロセス範囲を超えている信号は無いことがわかった。

次に、学習パターンの経験であるが、初期学習時には加圧水加圧動作が学習パターンとして含まれているが、加圧水減圧動作については学習パターンに含まれていないことが分かった。これはニューラルネットワークでモデルを構築する時に、出力上昇中のデータのみを取り込みモデルを構築しているため、出力上昇中に1次冷却材の圧力上昇に伴い頻繁に行われる加圧水加圧動作は学習できても、出力上昇中には行われない加圧水減圧動作は学習できないためであることがわかった。

また、同じような制御をしている1次冷却材と2次冷却材の差圧制御についても、モデルは異常として検知しなかった。1次冷却材と2次冷却材の差圧は、2次冷却材を2次貯蔵供給設備より供給又は回収することにより一定範囲内に制御している。2次冷却材の供給動作については、初期学習期間である出力上昇中の学習パターンに含まれており、ニューラルネットワークモデルが経験していた。回収動作については、出力上昇中のデータには含まれていなかったが、運転監視期間中に回収動作が無かったため、今回の監視では関係しなかった。

以上のことから、1次冷却材・加圧水差圧制御系の加圧水減圧動作のみを異常として検知した監視モデルについて、初期学習に学習していないパターンによる異常検知と想定し、初期学習データ4068点に定格出力運転中の加圧水減圧動作パターンの1秒置きデータ1101点を加えの計5169点でニューラルネットワークを再モデル化することにした。

4.3 再モデル化後の運転監視結果

再モデル化することにより初期学習でのネットワーク値は初めのモデルと異なり、異常判定しきい値も変更されるが、この再モデル化は制御系動作を1回加えただけなので第4.6表に示すように、しきい値には大きな変化は無かった。しかし、第4.8図に示すように同じ制御系の動作でも再モデル化後は、差圧の変動に対し、実測値とニューラルネットワークの予測値が良く追従しており偏差はしきい値を超えておらず、正常動作として認識するモデルを構築できた。このことから、4.2.2項の制御系動作の検知は、初期学習時に学習していないパターンによる異常検知であることがわかった。このようにニューラルネットワークでは、初期学習時に学習させた正常パターンについては、初期学習と適応学習モデルによるネットワーク情報内で動特性の変化に対応することができる。言い換れば、同じような状態変化量であっても、学習していないパターンに対しては異常として敏感に検知することから、この特性を利用して、運転員に早期に注意を促すような運用方法も可能であると考えられる。また、この制御系動作の検知は、HTTRの運転監

視からは誤報であるが、ニューラルネットワークからは、学習していない事象を的確に検知したという点においては、その性能を十分に発揮したということができる。今後は不必要的異常検知については排除していく検討が必要であるが、具体的には、出力上昇中だけでなく定常運転データについても初期学習に含めることや、次回以降の運転データを蓄積することで安定したモデル構築ができると考えている。

第 4.1 表 プラント信号リスト

No.	プラント信号	単位
1	1 次 PWCH _e 流量(Ch2)	t/h
2	IHX 出口 1 次冷却材流量(Ch2)	t/h
3	1 次冷却材・加圧水差圧(Ch2)	MPa
4	1 次・2 次 He 差圧(Ch2)	MPa
5	原子炉入口 He(D) ワイドレンジ温度	°C
6	原子炉出口冷却材(D) ワイドレンジ温度	°C
7	1 次 PWC He 温度(Ch2)	°C
8	IHX 出口 1 次冷却材温度(Ch2)	°C
9	2 次 He 流量(Ch2)	t/h
10	1 次 PWC 加圧水流量(Ch2)	t/h
11	2 次 PWC 加圧水流量(Ch2)	t/h
12	1 次 PWC 加圧水入口圧力	MPa
13	2 次 PWC 加圧水入口圧力	MPa
14	1 次 PWC 加圧水入口温度	°C
15	1 次 PWC 加圧水出口(D) 温度	°C
16	出力領域中性子束(Ch2)	%
17	反応度	%dk/k
18	炉心差圧(Ch2)	kPa
19	C 制御棒位置	Mm
20	原子炉出力設定値	%
21	2 次 PWC 加圧水入口(B) 温度	°C
22	2 次 PWC 加圧水出口(B) 温度	°C
23	1 次 PWC HGC(B) 回転数	min ⁻¹
24	IHX HGC(B) 回転数	min ⁻¹
25	2 次 HGC HGC(B) 回転数	min ⁻¹
26	2 次 PWC 出口 He 温度	°C
27	2 次 PWC 出口 He 流量	t/h
28	1 次 PWC 出口 He 圧力(Ch2)	MPa
29	2 次 PWC 出口 He 圧力	MPa
30	IHX 出口 He 圧力(Ch2)	MPa
31	2 次 He 循環機出口温度	°C

第 4.2 表 初期学習 学習データ

学習データ		期間	Δt [s]	データ数	
1	30~40%出力上昇	3/20 9:00:00~20:59:59	100	414	
2	40~50%出力上昇	3/22 9:30:00~21:59:59	100	450	
3	50~60%出力上昇	3/23 9:30:00~21:29:59	100	432	
4	60~70%出力上昇	3/24 9:30:00~21:29:59	100	432	
5	70~80%出力上昇	3/25 9:30:00~21:29:59	100	432	
6	80~90%出力上昇	3/26 9:30:00~21:29:59	100	432	
7	90~96.5%出力上昇	3/27 9:30:00~21:29:59	100	432	
8	96.5%出力	3/28 8:30:00~20:29:59	100	432	
9		3/29 8:30:00~20:29:59	100	432	
10		3/30 17:00:00~19:29:59	50	180	
合 計				4068	
学習回数				1000	

第 4.3 表 学習パラメータによる学習収束度

ケース	学習パラメータ		誤差の 2 乗和
	η	α	
ケース 1	1.0	1.0	0.14426
ケース 2	0.5	0.5	0.08747
ケース 3*	1.2,0.6,0.3	1.5,1.0,0.5	0.0725

* $\eta = 1.2, \alpha = 1.5$ (1-150 回) , $\eta = 0.6, \alpha = 1.0$ (151-300 回) , $\eta = 0.3, \alpha = 0.5$ (301-1000 回)

第 4.4 表 初期学習後の異常判定しきい値

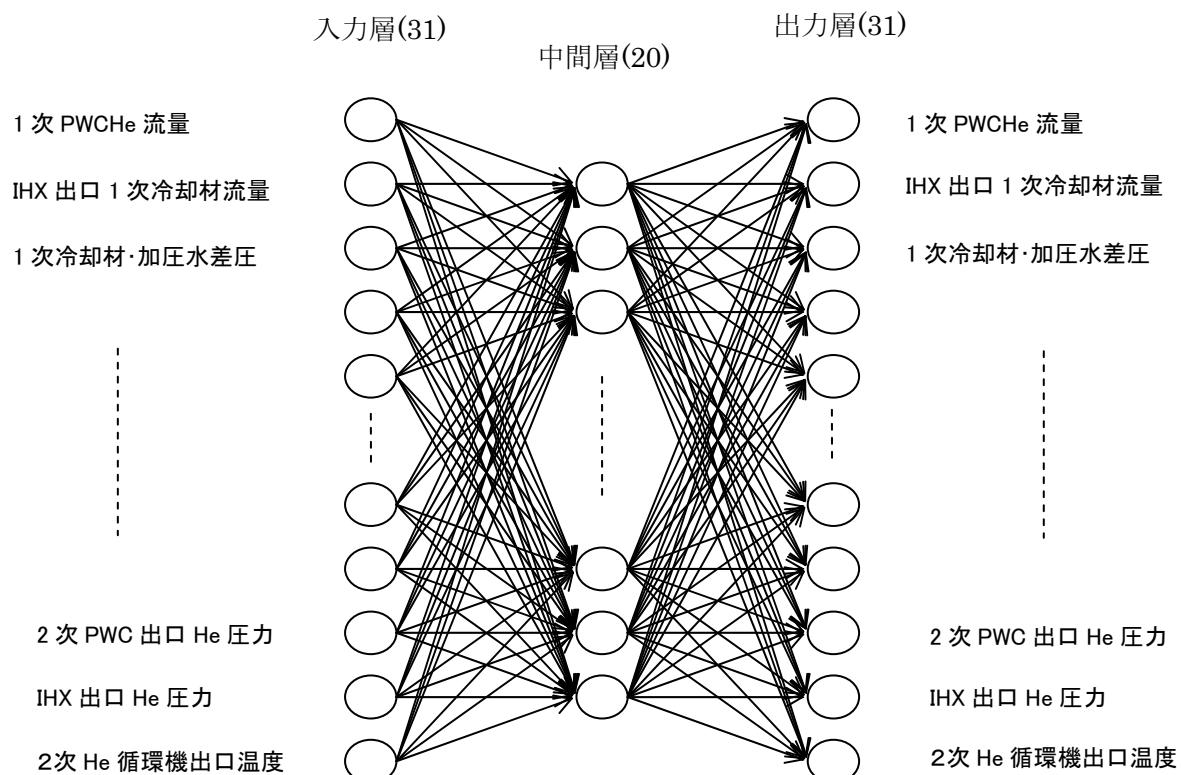
Ch	信号名	初期学習時最大誤差(ε_{\max})	標準偏差 × 2 (ε_{sd})	異常判定しきい値(ε_f)
1	1 次 PWC He 流量[t/h]	0.0367	0.1236	0.1421
2	IHX 出口 1 次冷却材流量[t/h]	0.0240	0.0762	0.0877
3	1 次冷却材・加圧水差圧[MPa]	0.0074	0.0051	0.0085
4	1 次・2 次 He 差圧[MPa]	0.0034	0.0012	0.0039
5	原子炉入口 He WR 温度[°C]	1.9504	0.0692	2.2430
6	原子炉出口冷却材 WR 温度[°C]	4.1165	0.1148	4.7340
7	1 次 PWC He 温度[°C]	1.4617	0.3429	1.6810
8	IHX 出口 1 次冷却材温度[°C]	1.8862	0.0791	2.1691
9	2 次 He 流量[t/h]	0.0427	0.1691	0.1945
10	1 次 PWC 加圧水流量[t/h]	0.5174	1.0559	1.2143
11	2 次 PWC 加圧水流量[t/h]	0.2067	0.5694	0.6548
12	1 次 PWC 加圧水入口圧力[MPa]	0.0238	0.0055	0.0274
13	2 次 PWC 加圧水入口圧力[MPa]	0.0228	0.0056	0.0262
14	1 次 PWC 加圧水入口温度[°C]	0.8152	0.1846	0.9375
15	1 次 PWC 加圧水出口(D)温度[°C]	0.9977	0.1289	1.1474
16	出力領域中性子束[%]	0.6414	0.2531	0.7376
17	反応度[%dk/k]	0.0004	0.0009	0.0011
18	炉心差圧[kPa]	0.0570	0.0285	0.0655
19	C 制御棒位置[mm]	6.2335	0.3887	7.1685
20	原子炉出力 設定値[%]	0.6863	0.3887	0.7892
21	2 次 PWC 加圧水入口(B)温度[°C]	0.8395	0.1932	0.9654
22	2 次 PWC 加圧水出口(B)温度[°C]	0.9501	0.1617	1.0926
23	1 次 PWC HGC(B) 回転数[min ⁻¹]	31.0112	24.5290	35.6629
24	IHX HGC(B) 回転数[min ⁻¹]	35.4361	7.0409	40.7515
25	2 次 HGC HGC(B) 回転数[min ⁻¹]	23.3701	18.7830	26.8756
26	2 次 PWC 出口 He 温度[°C]	1.0802	0.1988	1.2422
27	2 次 PWC 出口 He 流量[t/h]	0.0130	0.0534	0.0614
28	1 次 PWC 出口 He 圧力[MPa]	0.0264	0.0010	0.0304
29	2 次 PWC 出口 He 圧力[MPa]	0.0282	0.0016	0.0324
30	IHX 出口 He 圧力[MPa]	0.0258	0.0008	0.0296
31	2 次 He 循環機出口温度[°C]	1.2147	0.4965	1.3970

第 4.5 表 一次冷却材・加圧水差圧制御系の動作

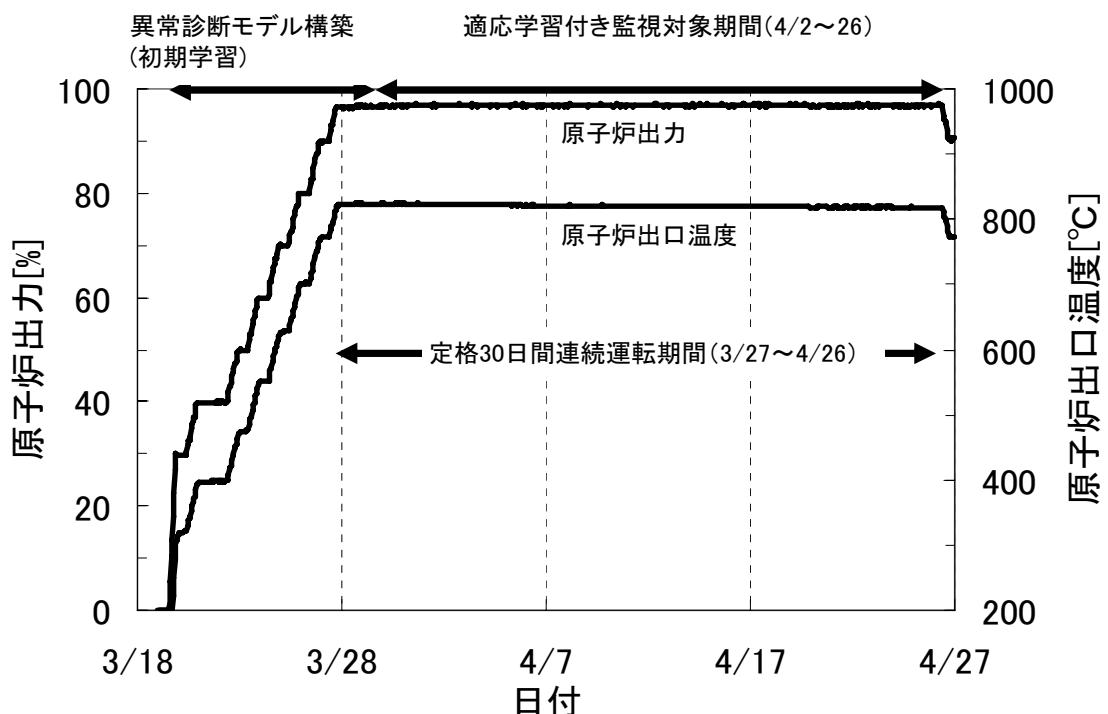
1 次冷却材・加圧水差圧 制御目標値	加圧水加圧器窒素ガス 入口弁開 (加圧水加圧動 作)	加圧水加圧器窒素ガス 出口弁開 (加圧水減圧 動作)
0.49MPa	0.5488MPa	0.4312MPa

第 4.6 表 再モデル化後の異常判定しきい値

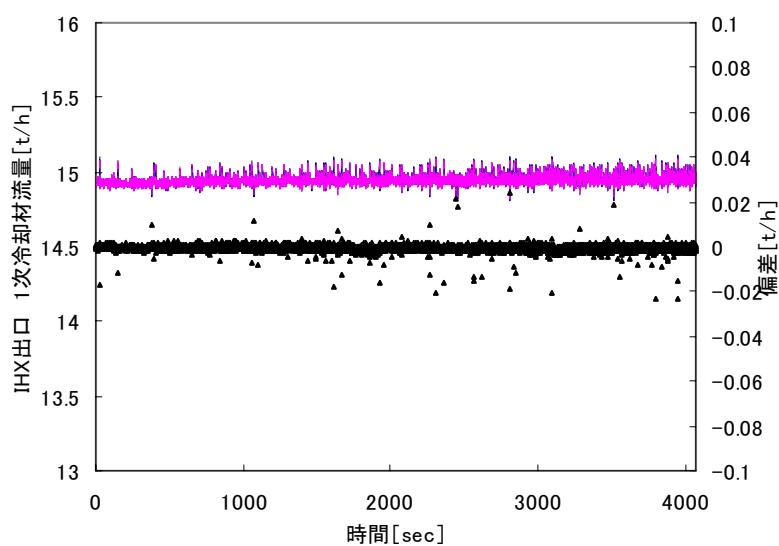
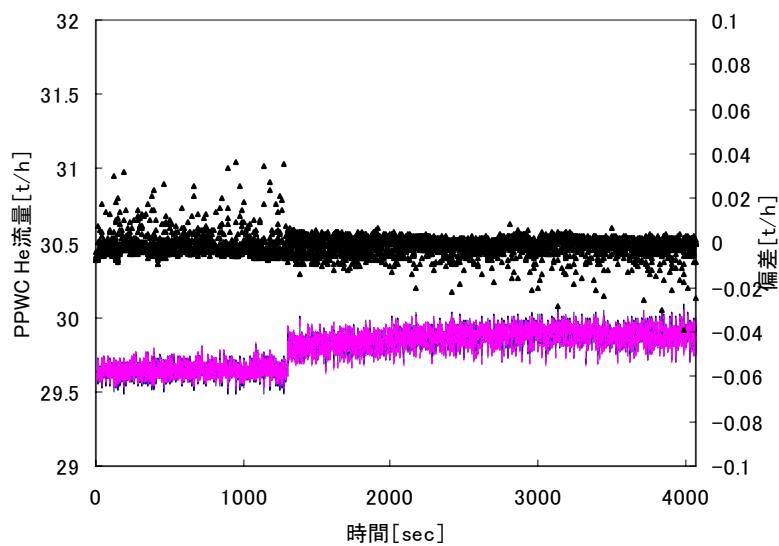
Ch	信号名	初期学習時最大誤差(ε_{\max})	標準偏差 × 2 (ε_{sd})	異常判定しきい値(ε_f)
1	1 次 PWC He 流量[t/h]	0.0441	0.1236	0.1421
2	IHX 出口 1 次冷却材流量[t/h]	0.0236	0.0762	0.0877
3	1 次冷却材・加圧水差圧[MPa]	0.0090	0.0051	0.0104
4	1 次・2 次 He 差圧[MPa]	0.0037	0.0012	0.0042
5	原子炉入口 He WR 温度[°C]	2.0654	0.0692	2.3752
6	原子炉出口冷却材 WR 温度[°C]	3.1797	0.1148	3.6567
7	1 次 PWC He 温度[°C]	1.3140	0.3429	1.5111
8	IHX 出口 1 次冷却材温度[°C]	1.6395	0.0791	1.8854
9	2 次 He 流量[t/h]	0.0393	0.1691	0.1945
10	1 次 PWC 加圧水流量[t/h]	0.5077	1.0559	1.2143
11	2 次 PWC 加圧水流量[t/h]	0.2093	0.5694	0.6548
12	1 次 PWC 加圧水入口圧力[MPa]	0.0178	0.0055	0.0205
13	2 次 PWC 加圧水入口圧力[MPa]	0.0193	0.0056	0.0222
14	1 次 PWC 加圧水入口温度[°C]	1.1206	0.1846	1.2886
15	1 次 PWC 加圧水出口(D)温度[°C]	1.0327	0.1289	1.1876
16	出力領域中性子束[%]	0.7609	0.2531	0.8750
17	反応度[%dk/k]	0.0004	0.0009	0.0011
18	炉心差圧[kPa]	0.0611	0.0285	0.0702
19	C 制御棒位置[mm]	10.8999	0.3887	12.5349
20	原子炉出力 設定値[%]	0.6688	0.3887	0.7691
21	2 次 PWC 加圧水入口(B)温度[°C]	1.1087	0.1932	1.2751
22	2 次 PWC 加圧水出口(B)温度[°C]	0.9192	0.1617	1.0570
23	1 次 PWC HGC(B) 回転数[min ⁻¹]	25.6084	24.5290	29.4496
24	IHX HGC(B) 回転数[min ⁻¹]	21.8904	7.0409	25.1739
25	2 次 HGC HGC(B) 回転数[min ⁻¹]	21.7597	18.7830	25.0237
26	2 次 PWC 出口 He 温度[°C]	1.1912	0.1988	1.3699
27	2 次 PWC 出口 He 流量[t/h]	0.0125	0.0534	0.0614
28	1 次 PWC 出口 He 圧力[MPa]	0.0112	0.0010	0.0129
29	2 次 PWC 出口 He 圧力[MPa]	0.0134	0.0016	0.0154
30	IHX 出口 He 圧力[MPa]	0.0105	0.0008	0.0121
31	2 次 He 循環機出口温度[°C]	1.1947	0.4965	1.3738



第 4.1 図 オートアソシエイティブニューラルネットワーク

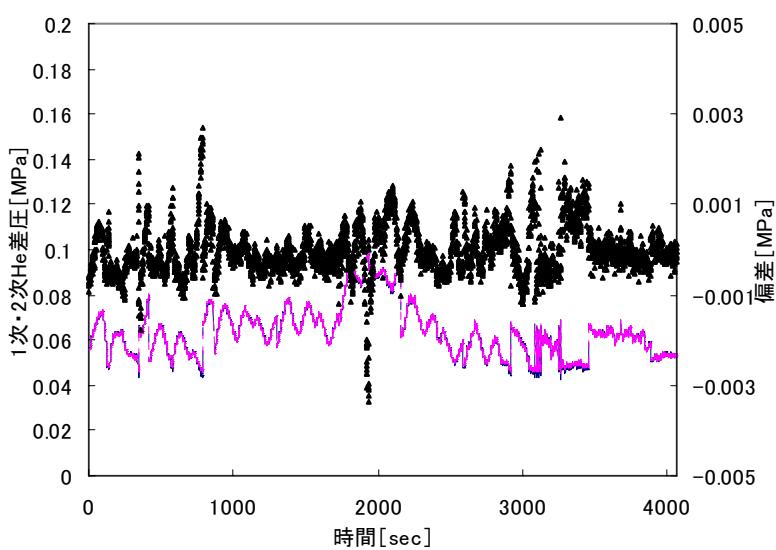
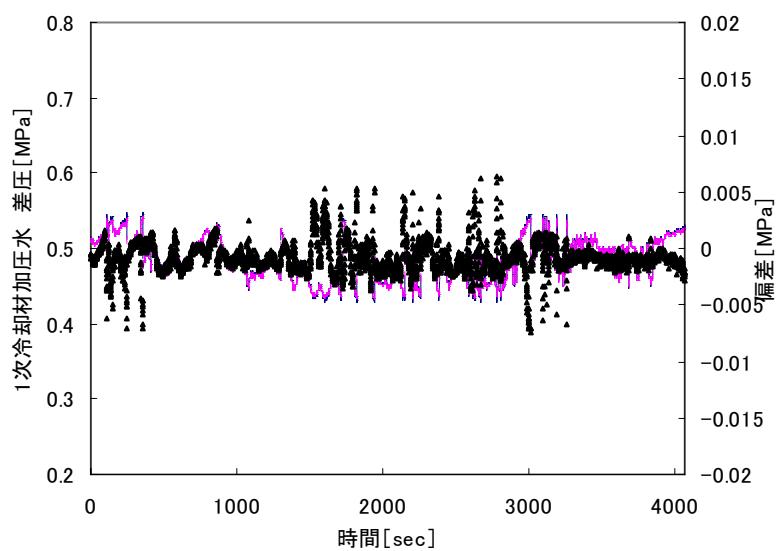


第 4.2 図 HTTR 運転監視における初期学習と運転監視対象期間



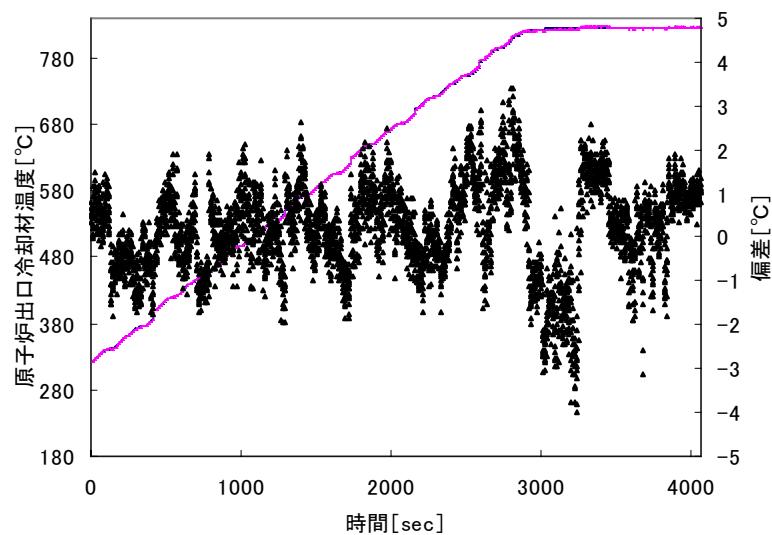
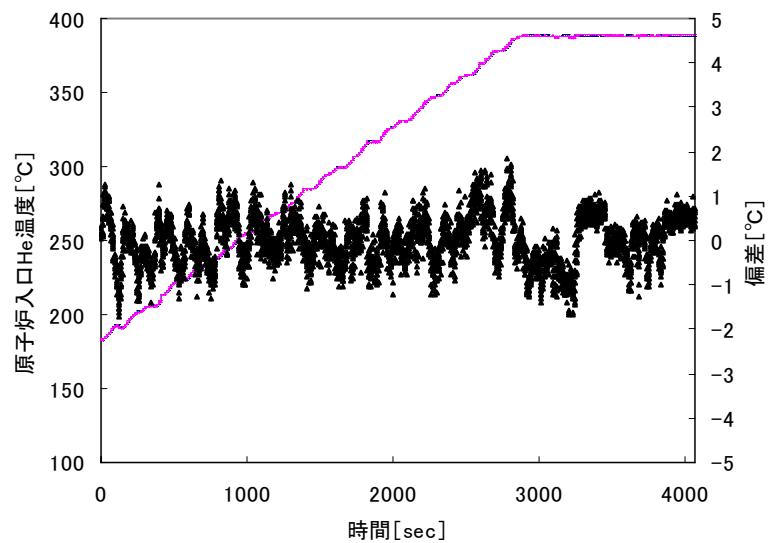
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (1/16) 初期学習結果



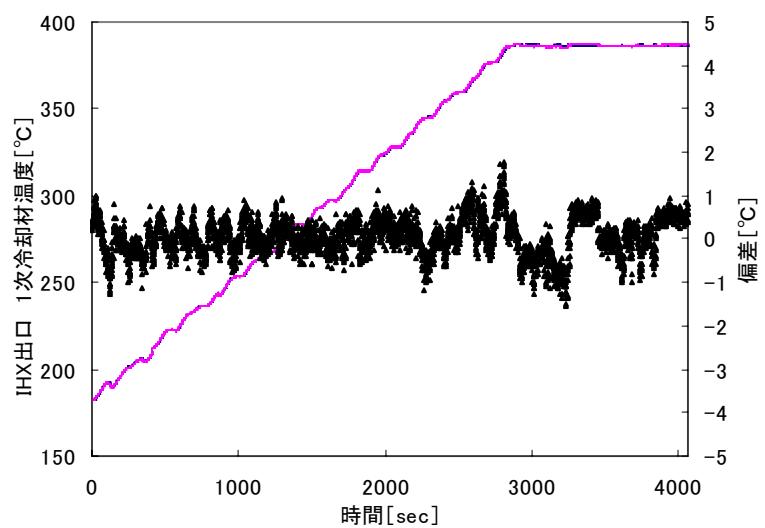
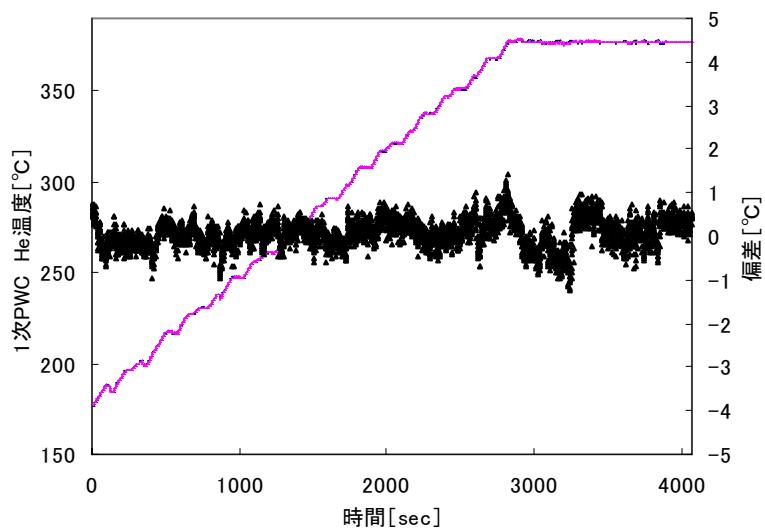
— · · · — 実測値
—— 推定値
▲ 偏差

第 4.3 図 (2/16) 初期学習結果



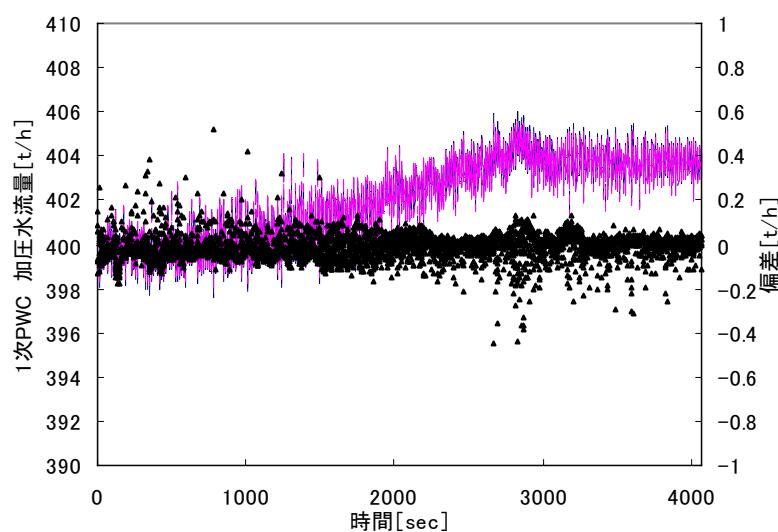
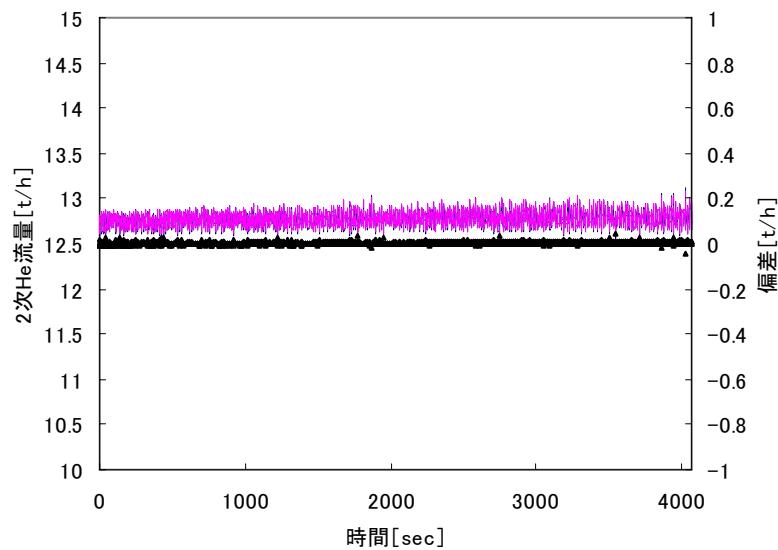
----- 実測値
——— 推定値
▲ 偏差

第 4.3 図 (3/16) 初期学習結果



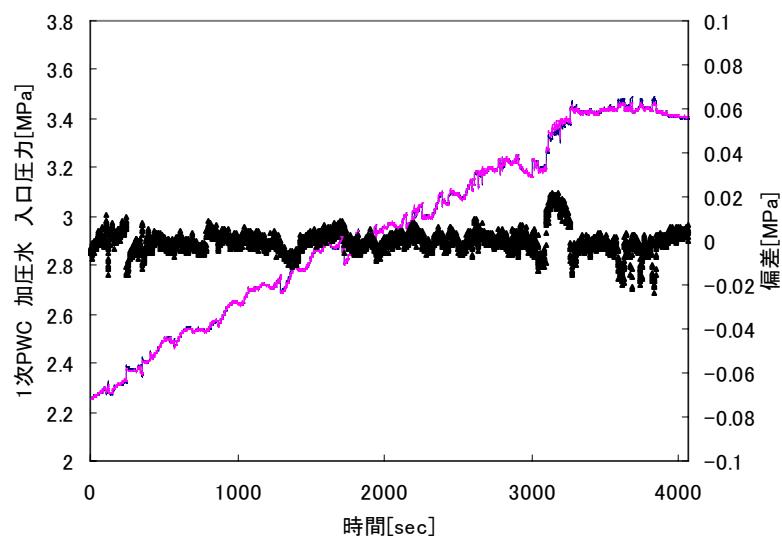
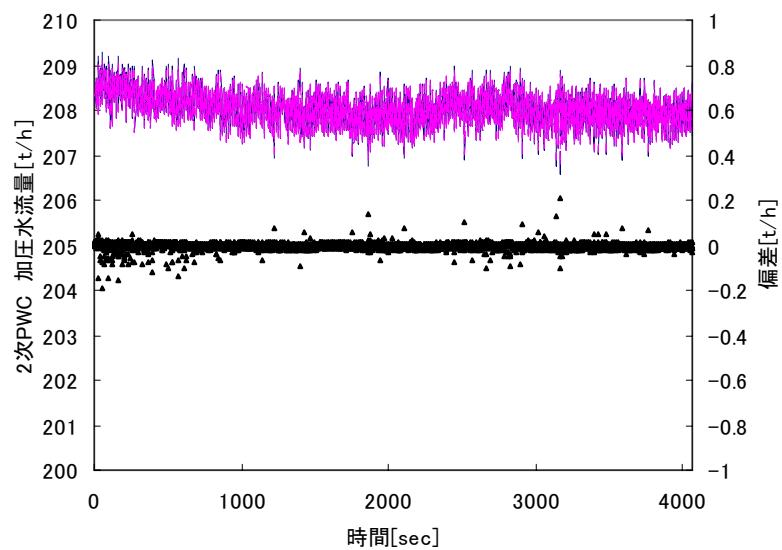
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (4/16) 初期学習結果



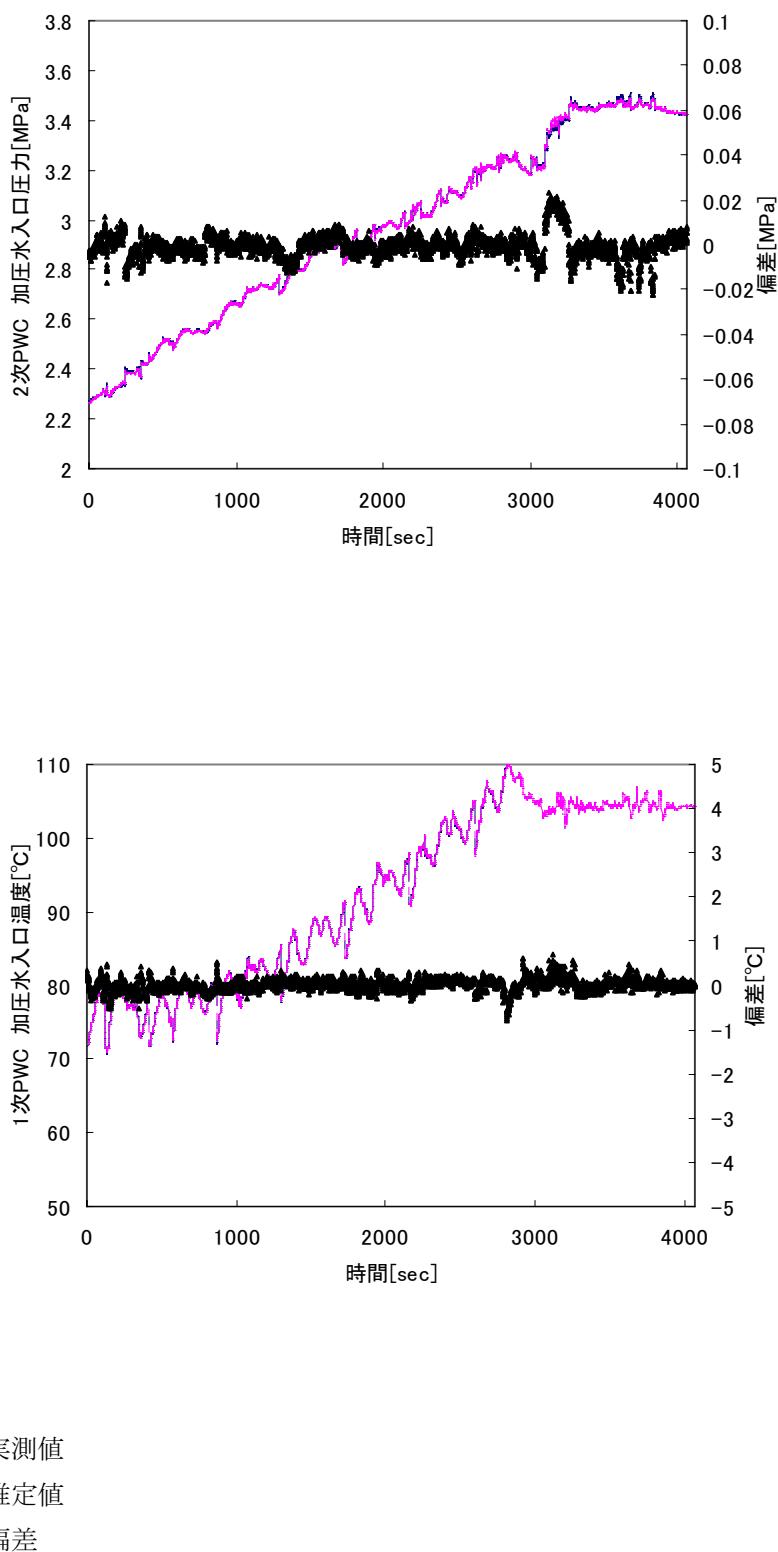
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (5/16) 初期学習結果

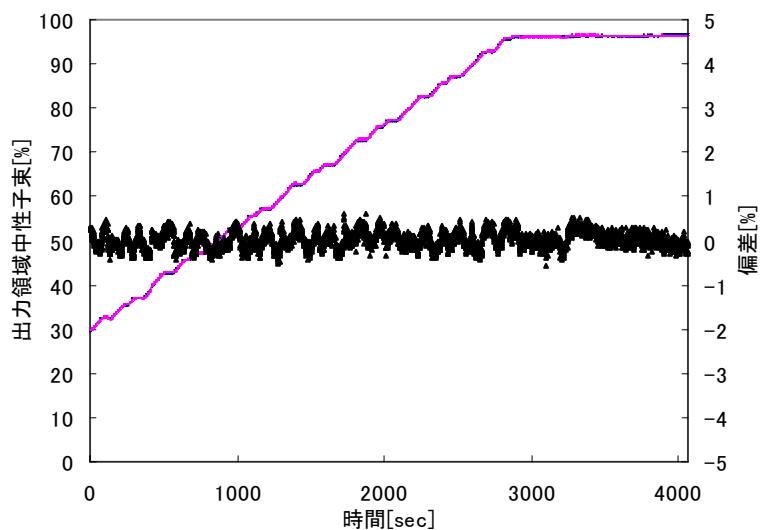
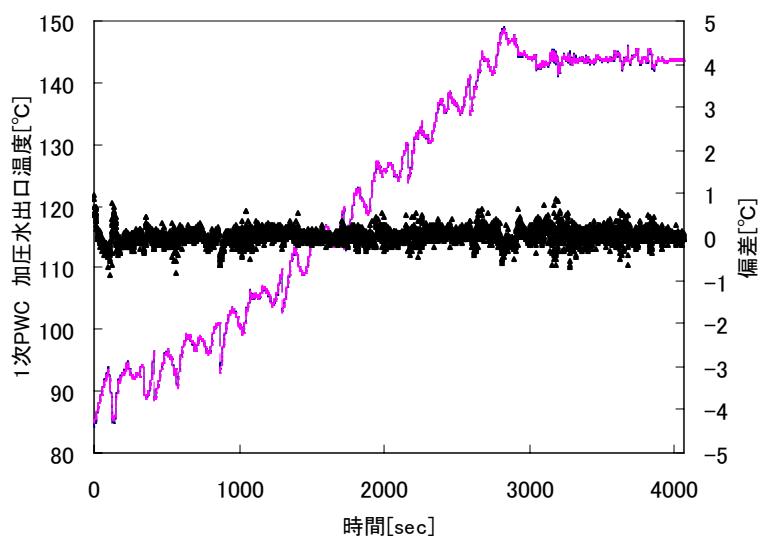


— · · · — 実測値
 ————— 推定値
 ▲ 偏差

第 4.3 図 (6/16) 初期学習結果

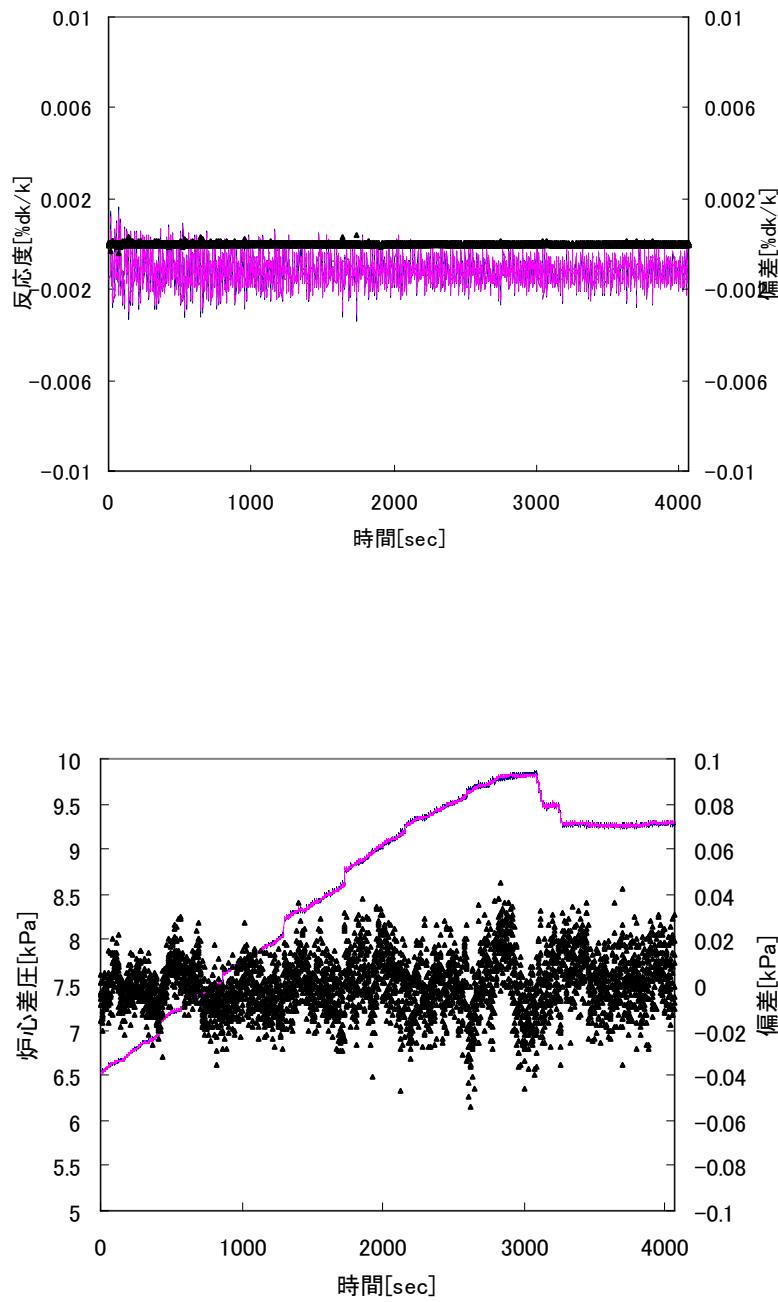


第 4.3 図 (7/16) 初期学習結果



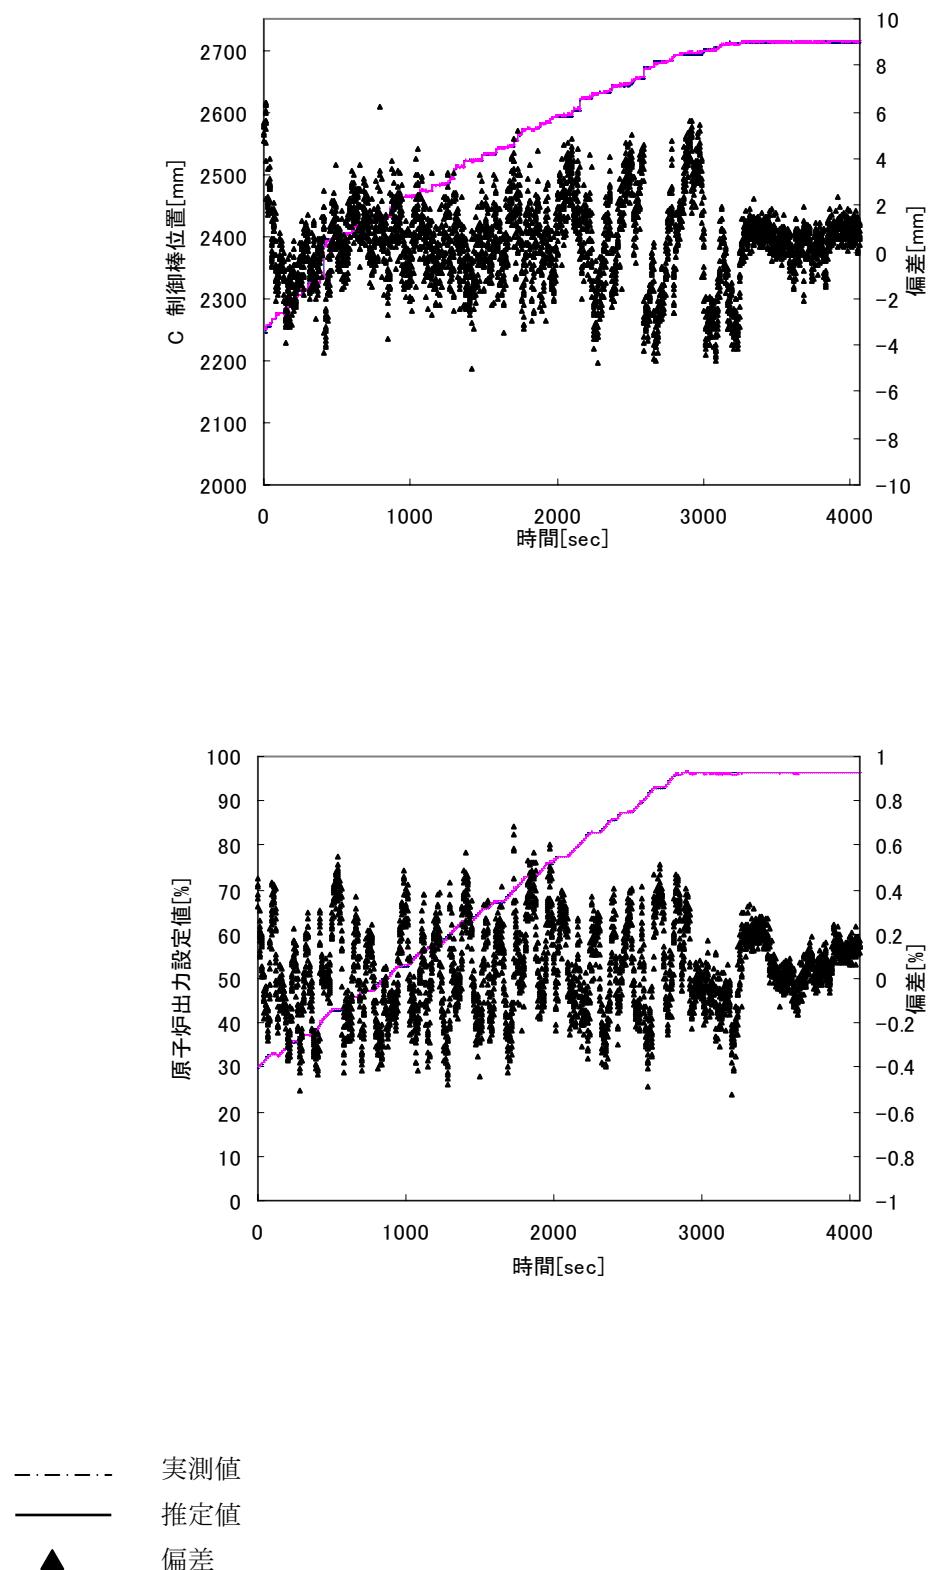
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (8/16) 初期学習結果

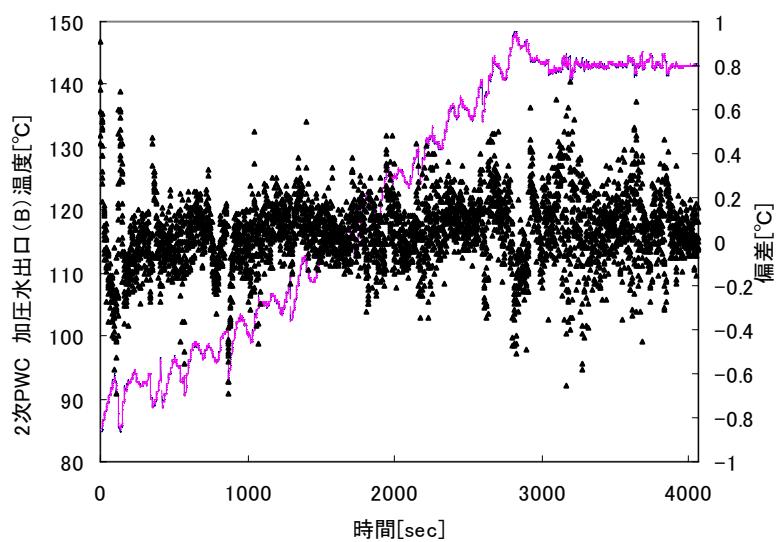
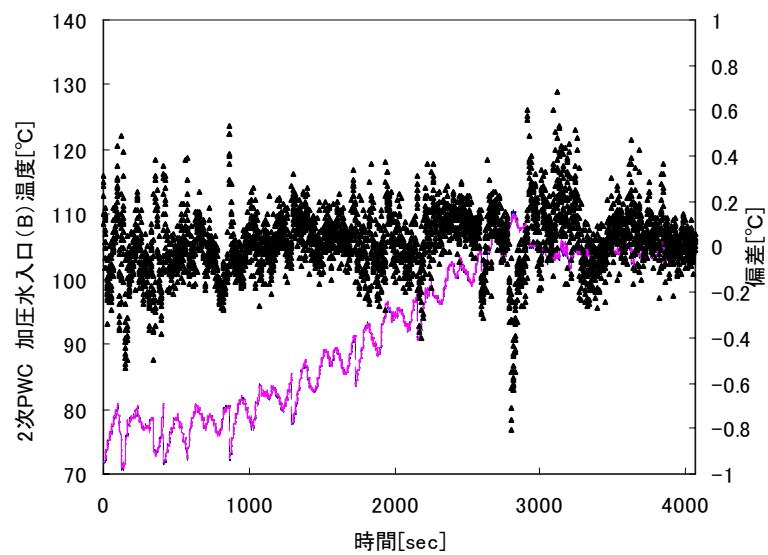


----- 実測値
 ————— 推定値
 ▲ 偏差

第 4.3 図 (9/16) 初期学習結果

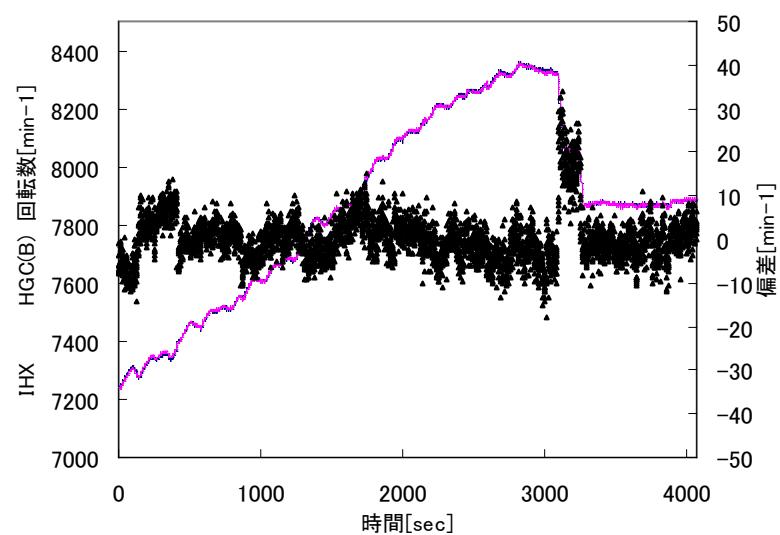
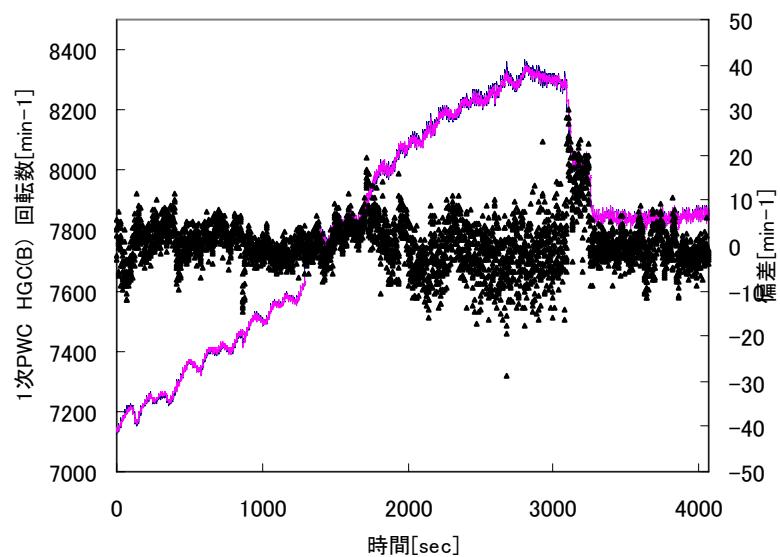


第 4.3 図 (10/16) 初期学習結果



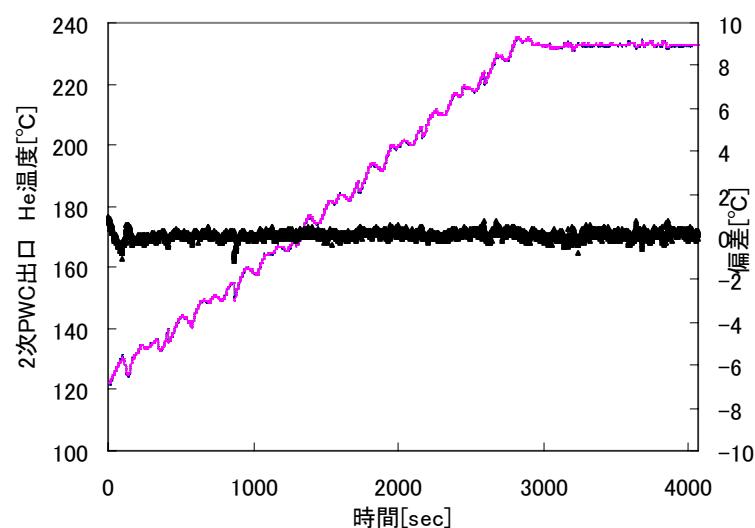
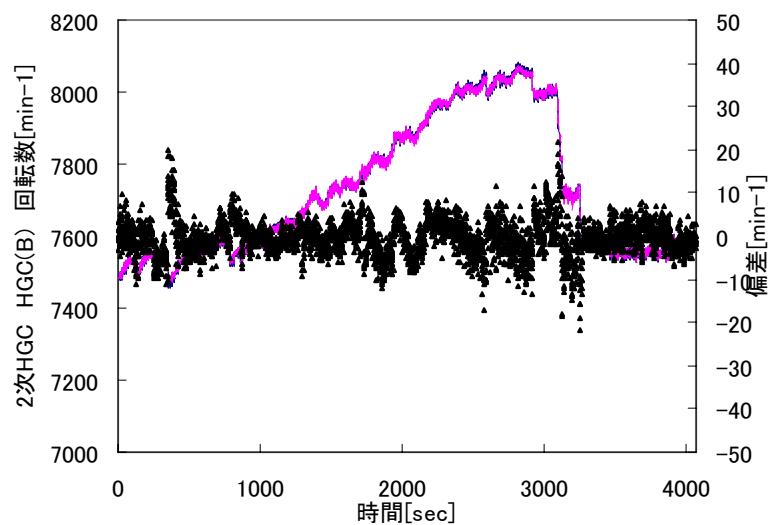
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (11/16) 初期学習結果



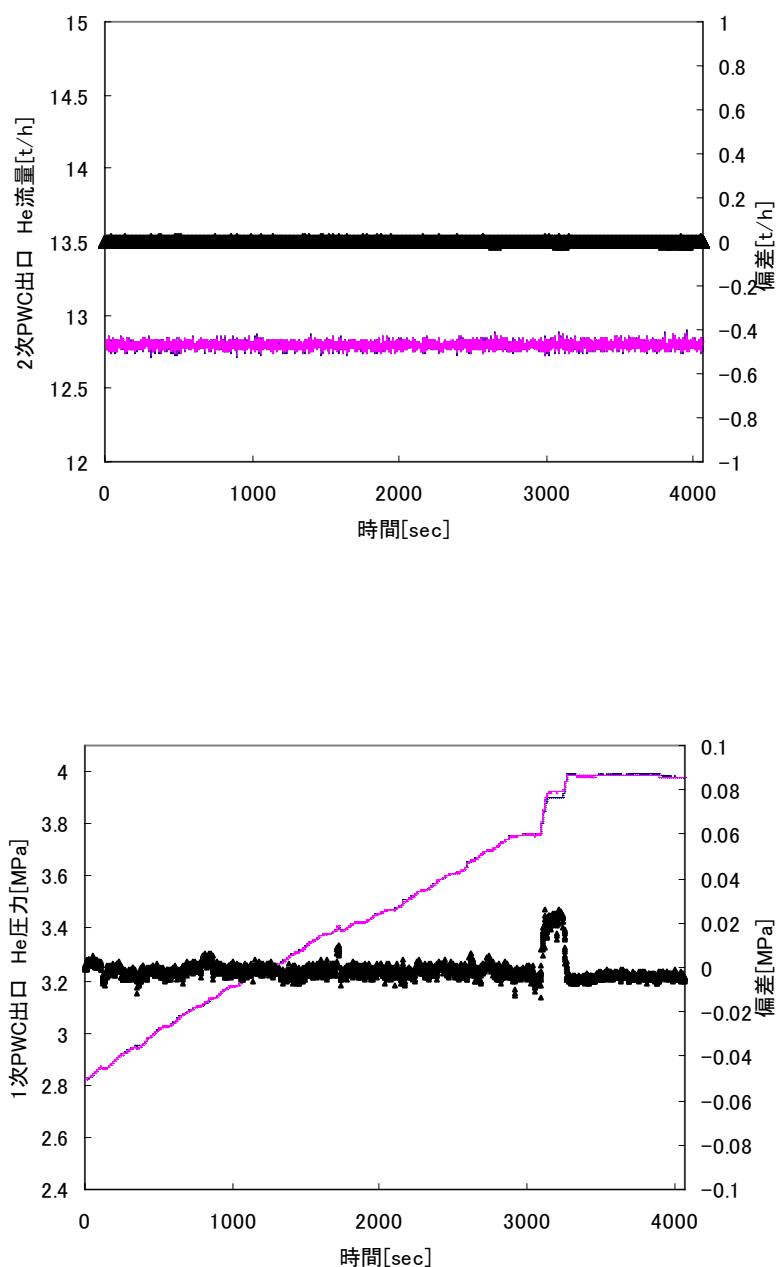
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (12/16) 初期学習結果



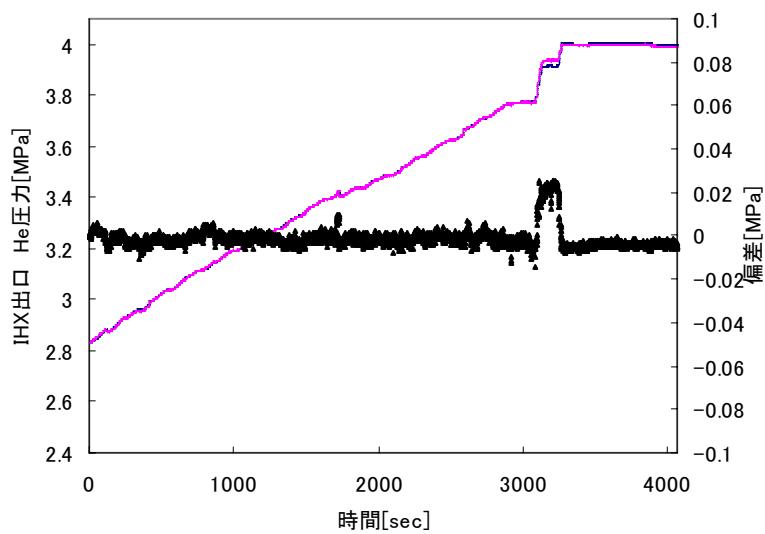
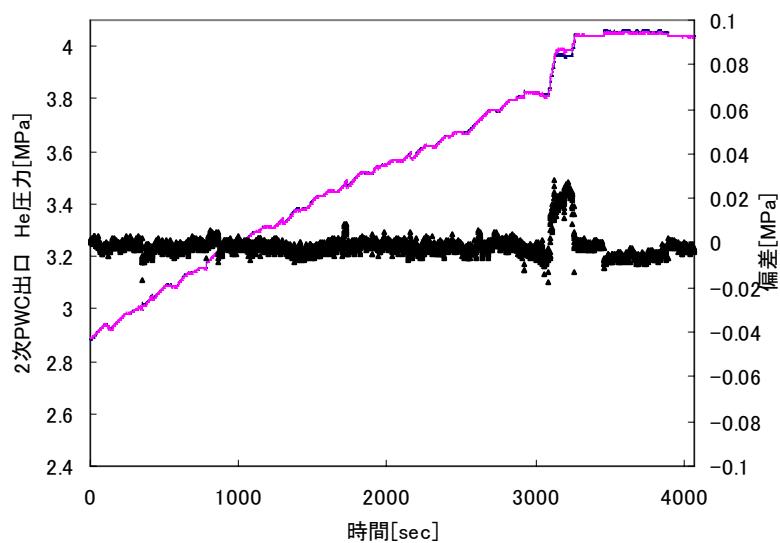
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (13/16) 初期学習結果



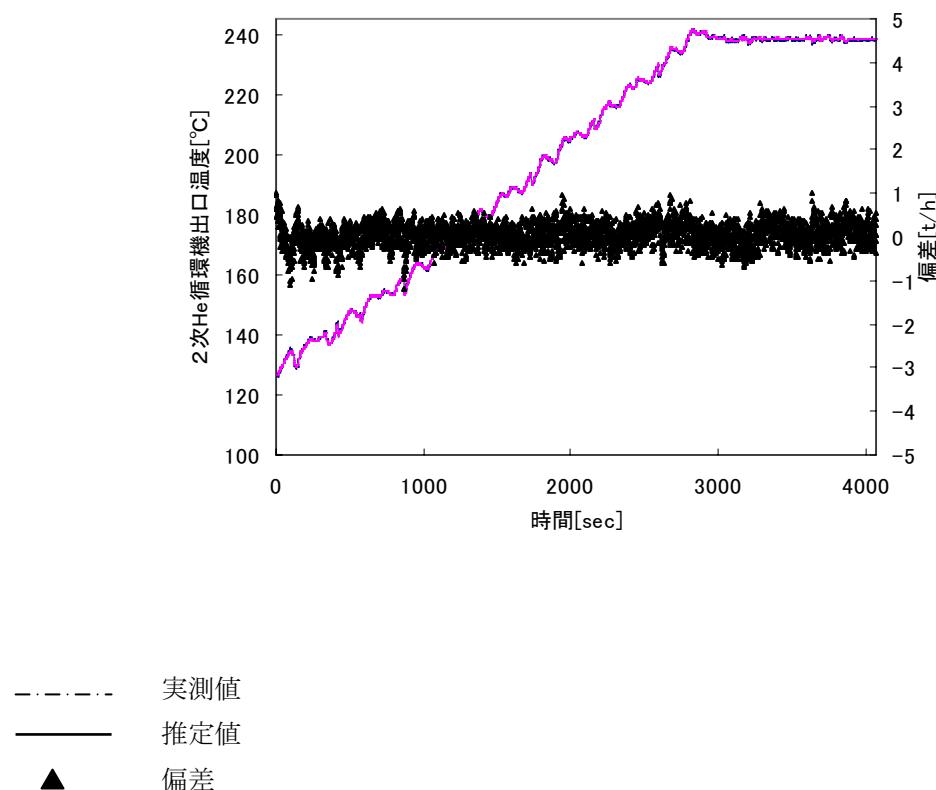
— 実測値
— 推定値
▲ 偏差

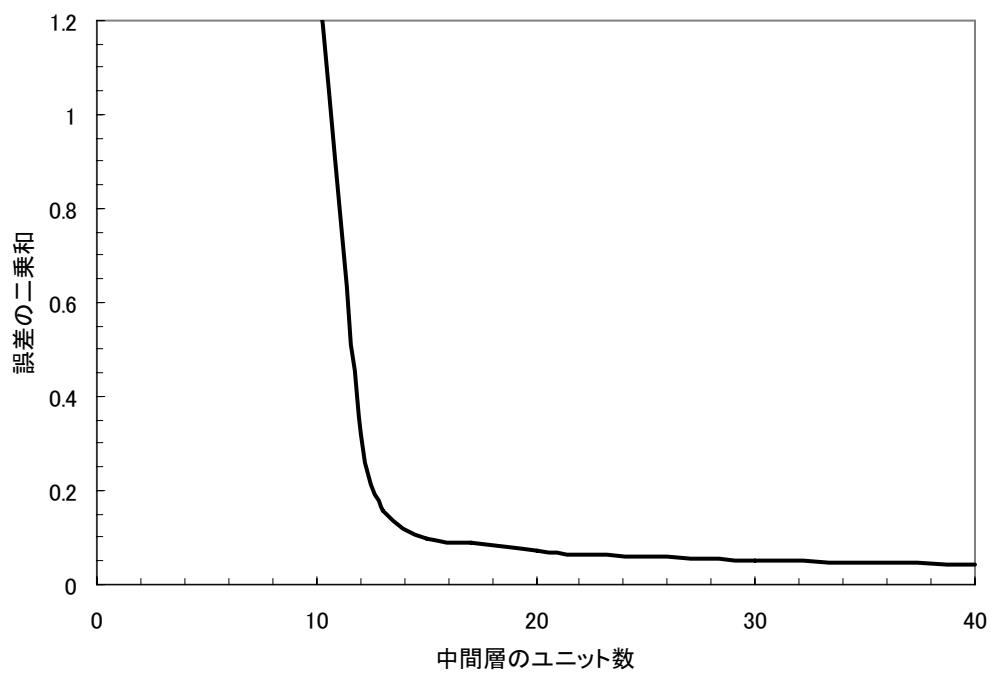
第 4.3 図 (14/16) 初期学習結果



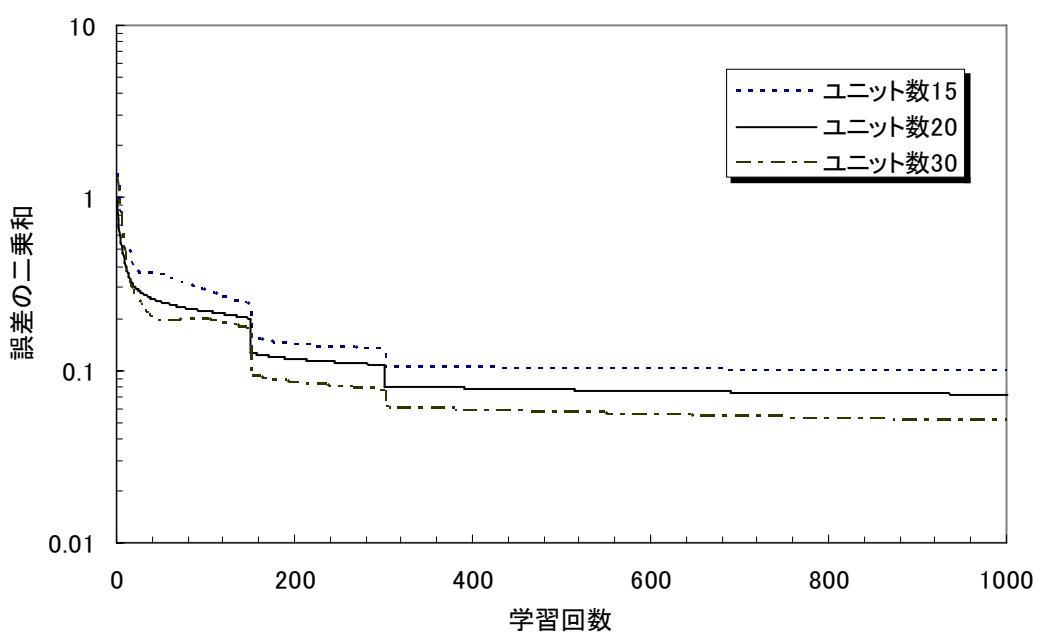
----- 実測値
—— 推定値
▲ 偏差

第 4.3 図 (15/16) 初期学習結果

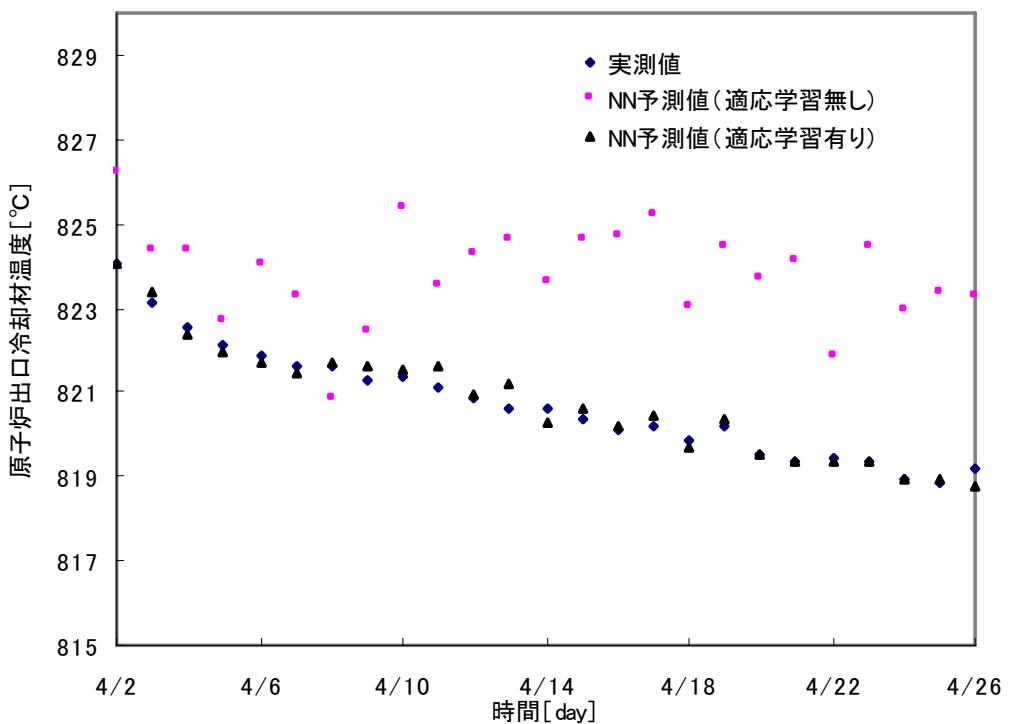




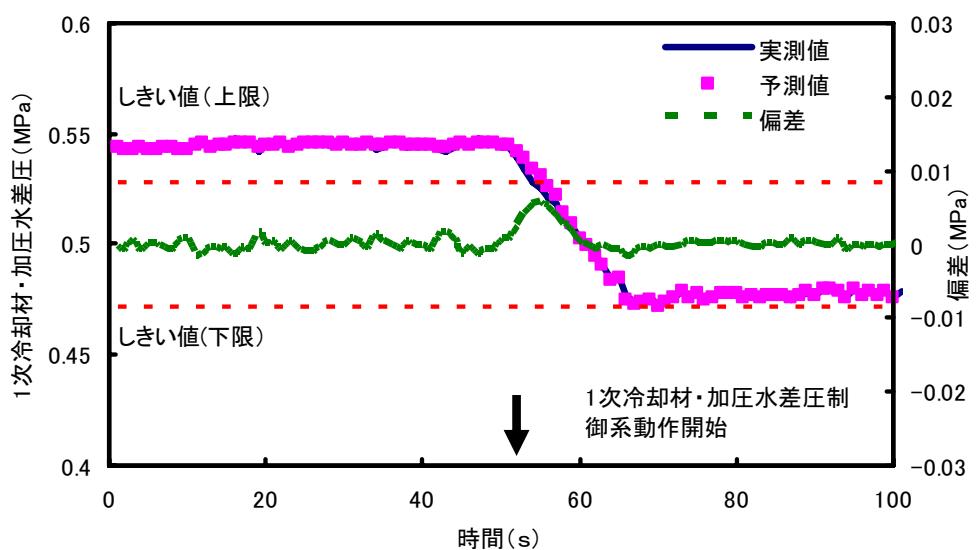
第 4.4 図 中間層のユニット数による初期学習の収束誤差



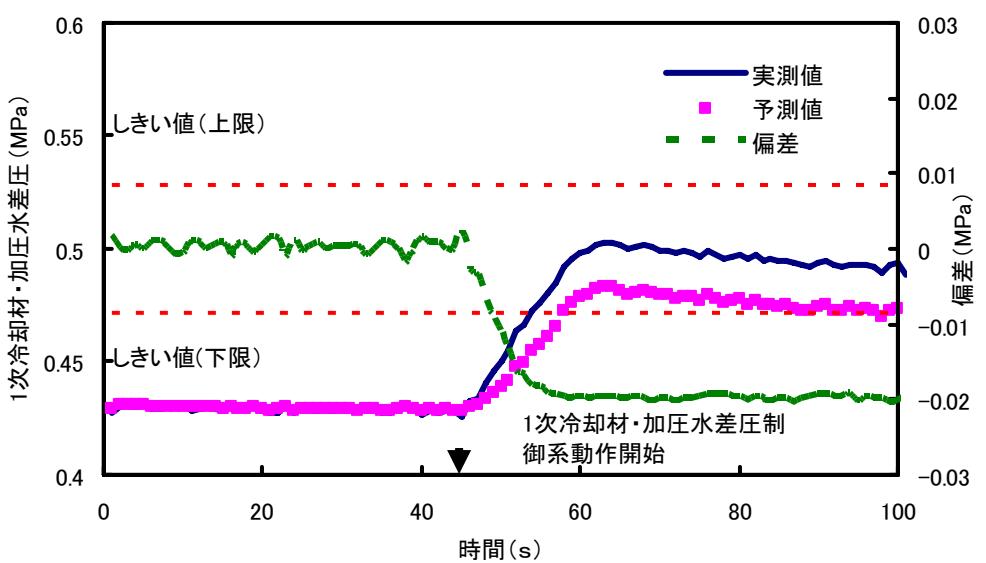
第 4.5 図 中間層ユニット数による初期学習の学習誤差の推移



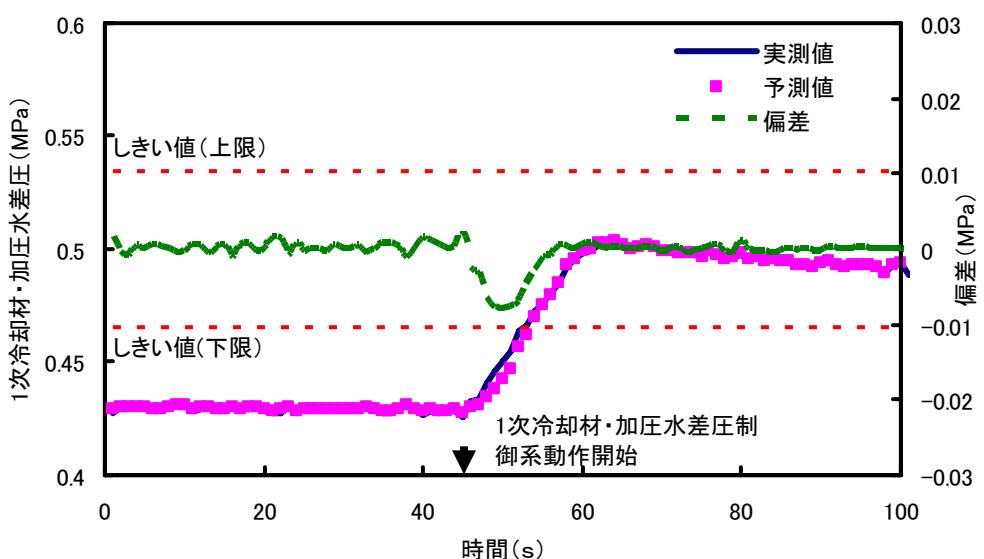
第 4.6 図 適応学習による効果



第 4.7 図(a) 制御系動作時のニューラルネットワーク挙動 (加圧水加圧動作)



第 4.7 図(b) 制御系動作時のニューラルネットワーク挙動 (加圧水排出動作)



第 4.8 図 再モデル化後の制御系動作時のニューラルネットワーク挙動（加圧水排出動作）

5.まとめ

HTTR 実機による 30 日間連續運転データを用いて、ニューラルネットワークによる運転監視モデルを構築し、オフラインによる運転監視を行った。運転監視モデルの構築にあたっては、中間層のユニット数、学習率 η 及びモーメンタム項の係数 α の各種パラメータを変化させることにより、運転監視に適当な値を決定することができた。運転監視にあたっては、プラントの緩やかな変化に追従するために、適応学習が不可欠であることがわかった。ニューラルネットワークは初期学習で学習していないパターンへの応答が早く、微少な変動を検知し、運転員に告知することができ、HTTR の異常診断として適用できる見通しを得た。今後は、ニューラルネットワークモデルの信頼性を向上させる検討及び異常の原因を特定するための、異常診断モデルの検討を行っていく予定である。

謝辞

本報告書をまとめるにあたり、小森芳廣 高温工学試験研究炉部長、中澤利雄 同部次長、伊与久達夫 研究主席、江森恒一 HTTR運転管理課長並びにHTTR運転管理課の方々から御指導、御助言頂きました。ここに深く感謝の意を表します。

参考文献

- (1) 日本原子力研究所：“日本原子力研究所大洗研究所設置変更許可申請書(完本)[別冊3 HTTR]”(2001)
- (2) 斎藤伸三 他：“高温工学試験研究炉の設計と研究開発”，日本原子力学会誌, 32, p.847(1990)
- (3) 藤川正剛 他：“HTTR(高温工学試験研究炉)の出力上昇試験”，原子力誌, 1, p.361(2002)
- (4) 中川繁昭 他：“高温工学試験研究炉の出力上昇試験－試験経過及び結果の概要－” JAERI-Tech 2002-069 (2002)
- (5) 高松邦吉 他：“高温工学試験研究炉の出力上昇試験(高温試験運転)－試験方法及び結果の概要－” JAERI-Tech 2004-063 (2004).
- (6) S.Fujikawa et al.:“Achievement of Reactor-Outlet Coolant Temperature of 950°C in HTTR”, Nucl.Sci.Tech., 41, 12, pp.1245-1254(2004).
- (7) K. Nabeshima, T. Matsuishi, J. Makino, M. Subekti, T. Ohno, K. Kudo, and S. Nakagawa :“Integrated On-line Plant Monitoring System for HTTR Using Neural Networks”, JSME Journal of Power and Energy Systems, Vol.2, No.1, pp.92-103, (2008)
- (8) 大野富生 他：“ニューラルネットワークを用いた HTTR 制御棒引抜き試験の事前解析手法”，日本原子力学会和文論文誌, Vol.4, No.2(2005)
- (9) 鍋島邦彦：“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” JAERI 1342 (2001)
- (10) 鍋島邦彦 他：“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)
- (11) 鍋島邦彦 他：“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)

国際単位系 (SI)

表1. SI基本単位		
基本量	SI基本単位	
	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
物質量	モル	mol
光度	カンデラ	cd

表2. 基本単位を用いて表されるSI組立単位の例		
組立量	SI基本単位	記号
面積	平方メートル	m^2
体積	立方メートル	m^3
速度	メートル毎秒	m/s
加速度	メートル毎秒毎秒	m/s^2
波数	毎メートル	m^{-1}
密度、質量密度	キログラム毎立方メートル	kg/m^3
面積密度	キログラム毎平方メートル	kg/m^2
比體積	立方メートル毎キログラム	m^3/kg
電流密度	アンペア毎平方メートル	A/m^2
磁界の強さ	アンペア毎メートル	A/m
質量濃度 ^(a)	モル毎立方メートル	mol/m^3
質量濃度	キログラム毎立方メートル	kg/m^3
輝度	カンデラ毎平方メートル	cd/m^2
屈折率 ^(b)	(数字の) 1	1
透磁率 ^(b)	(数字の) 1	1

(a) 量濃度(amount concentration)は臨床化学の分野では物質濃度(substance concentration)ともよばれる。

(b) これらは無次元量あるいは次元1をもつ量であるが、そのことを表す単位記号である数字の1は通常は表記しない。

表3. 固有の名称と記号で表されるSI組立単位

組立量	SI組立単位		
	名称	記号	他のSI単位による表し方
平面角	ラジアン ^(b)	rad	$1^{(b)}$
立体角	ステラジアン ^(b)	sr ^(c)	$1^{(b)}$
周波数	ヘルツ ^(d)	Hz	m^{2}/m^2
力	ニュートン	N	s^{-1}
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	$N\cdot m$
仕事を、工率、放射束	ワット	W	J/s
電荷、電気量	クーロン	C	$m^2 kg s^{-3}$
電位差(電圧)、起電力	ボルト	V	$m^2 kg s^{-3} A^{-1}$
静電容量	ファラード	F	$m^2 kg^{-1} s^4 A^2$
電気抵抗	オーム	Ω	$m^2 kg s^{-3} A^{-2}$
コンダクタンス	ジーメンス	S	$m^2 kg^{-1} s^3 A^2$
磁束密度	ウェーバ	Wb	$m^2 kg s^{-2} A^{-1}$
磁束度	テスラ	T	Wb/m^2
インダクタンス	ヘンリー	H	$kg s^{-2} A^{-1}$
セルシウス温度	セルシウス度 ^(e)	°C	K
光束度	ルーメン	lm	cd sr ^(e)
放射性核種の放射能 ^(f)	ベクレル ^(d)	Bq	lm/m^2
吸収線量、比エネルギー分与、カーマ	グレイ	Gy	$m^2 s^{-2}$
線量当量、周辺線量当量、方向性線量当量、個人線量当量	シーベルト ^(g)	Sv	J/kg
酸素活性	カタール	kat	$m^2 s^{-2}$

(a) SI接頭語は固有の名称と記号を持つ組立単位と組み合わせても使用できる。しかし接頭語を付した単位はもやはコヒーレントではない。

(b) ラジアンとステラジアンは数字の1に対する単位の特別な名称で、量についての情報をつたえるために使われる。実際には、使用する時には記号rad及びsrが用いられるが、習慣として組立単位としての記号である数字の1は明示されない。

(c) 調光学ではステラジアンという名称と記号srを単位の表し方の中に、そのまま維持している。

(d) ヘルツは周期現象についてのみ、ベクレルは放射性核種の統計的過程についてのみ使用される。

(e) セルシウス度はケルビンの特別な名称で、セルシウス温度を表すために使用される。セルシウス度とケルビンの単位の大きさは同一である。したがって、温度差や温度間隔を表す数値はどちらの単位で表しても同じである。

(f) 放射性核種の放射能(activity referred to a radionuclide)は、しばしば誤った用語で“radioactivity”と記される。

(g) 単位シーベルト(PV,2002,70,205)についてはCIPM勧告2(CI-2002)を参照。

表4. 単位の中に固有の名称と記号を含むSI組立単位の例

組立量	SI組立単位		
	名称	記号	SI基本単位による表し方
粘度	パスカル秒	Pa s	$m^{-1} kg s^{-1}$
力のモーメント	ニュートンメートル	N m	$m^2 kg s^2$
表面張力	ニュートン每メートル	N/m	$kg s^{-2}$
角速度	ラジアン毎秒	rad/s	$m^{-1} s^{-1} = s^{-1}$
角加速度	ラジアン毎秒毎秒	rad/s ²	$m^{-1} s^{-2} = s^{-2}$
熱流密度、放射照度	ワット每平方米メートル	W/m ²	W/m^2
熱容量、エンントロピー	ジュール毎ケルビン	J/K	$m^2 kg s^{-2} K^{-1}$
比熱容量、比エンントロピー	ジュール毎キログラム毎ケルビン	J/(kg K)	$m^3 s^{-2} K^{-1}$
比エネルギー	ジュール毎キログラム	J/kg	$m^2 s^{-2}$
熱伝導率	ワット每メートル每ケルビン	W/(m K)	$m kg s^{-3} K^{-1}$
体積エネルギー	ジュール每立方米メートル	J/m ³	$m^{-1} kg s^2$
電界の強さ	ボルト每メートル	V/m	$m kg s^{-3} A^{-1}$
電荷密度	クーロン每立方メートル	C/m ³	$m^3 sA$
表面電荷密度	クーロン每平方メートル	C/m ²	$m^2 sA$
電束密度、電気変位	クーロン每平方メートル	C/m ²	$m^2 sA$
誘電率	ファラード每メートル	F/m	$m^{-3} kg^{-1} s^4 A^2$
透磁率	ヘンリー每メートル	H/m	$m kg s^{-2} A^{-2}$
モルエネルギー	ジュール每モル	J/mol	$m^3 kg s^{-2} mol^{-1}$
モルエンントロピー、モル熱容量	ジュール每モル每ケルビン	J/(mol K)	$m^2 kg s^{-2} K^{-1} mol^{-1}$
照射線量(X線及びγ線)	クーロン每キログラム	C/kg	$kg^{-1} sA$
吸収線量率	グレイ毎秒	Gy/s	$m^3 s^{-3}$
放射強度	ワット每ステラジアン	W/sr	$m^4 m^2 kg s^{-3} = m^2 kg s^{-3}$
放射輝度	ワット每平方メートル每ステラジアン	W/(m ² sr)	$m^2 m^2 kg s^{-3} = kg s^{-3}$
酵素活性濃度	カタール每立方米メートル	kat/m ³	$m^{-3} s^{-1} mol$

乗数	接頭語	記号	乗数	接頭語	記号
10^{24}	ヨタ	Y	10^{-1}	デシ	d
10^{21}	ゼタ	Z	10^{-2}	センチ	c
10^{18}	エクサ	E	10^{-3}	ミリ	m
10^{15}	ペタ	P	10^{-6}	マイクロ	μ
10^{12}	テラ	T	10^{-9}	ナノ	n
10^9	ギガ	G	10^{-12}	ピコ	p
10^6	メガ	M	10^{-15}	フェムト	f
10^3	キロ	k	10^{-18}	アト	a
10^2	ヘクト	h	10^{-21}	ゼット	z
10^1	デカ	da	10^{-24}	ヨクト	y

表6. SIに属さないが、SIと併用される単位

名称	記号	SI単位による値
分	min	1 min=60s
時	h	1h=60 min=3600 s
日	d	1 d=24 h=86 400 s
度	°	$1^\circ=(\pi/180) \text{ rad}$
分	'	$1'=(1/60)^\circ=(\pi/10800) \text{ rad}$
秒	"	$1''=(1/60)'=(\pi/648000) \text{ rad}$
ヘクタール	ha	$1ha=1hm^2=10^4 m^2$
リットル	L	$1L=1dm^3=10^3 cm^3=10^{-3} m^3$
トン	t	$1t=10^3 kg$

表7. SIに属さないが、SIと併用される単位で、SI単位で表される数値が実験的に得られるもの

名称	記号	SI単位で表される数値
電子ボルト	eV	$1eV=1.602 176 53(14) \times 10^{-19} J$
ダルトン	Da	$1Da=1.660 538 86(28) \times 10^{-27} kg$
統一原子質量単位	u	$1u=1 Da$
天文単位	ua	$1ua=1.495 978 706 91(6) \times 10^{11} m$

表8. SIに属さないが、SIと併用されるその他の単位

名称	記号	SI単位で表される数値
バール	bar	$1 bar=0.1 MPa=100 kPa=10^5 Pa$
水銀柱ミリメートル	mmHg	$1 mmHg=133.322 Pa$
オングストローム	Å	$1 \text{ \AA}=0.1 nm=100 pm=10^{-10} m$
海里	M	$1 M=1852 m$
バーン	b	$1 b=100 fm^2=(10^{-12} cm)^2=10^{-28} m^2$
ノット	kn	$1 kn=(1852/3600) m/s$
ネーベル	Np	$SI \text{ 単位との数値的な関係は、対数量の定義に依存。}$
ベル	B	
デジベル	dB	

表9. 固有の名称をもつCGS組立単位

名称	記号	SI単位で表される数値
エルグ	erg	$1 erg=10^{-7} J$
ダイニン	dyn	$1 dyn=10^{-5} N$
ボアズ	P	$1 P=1 dyn s cm^{-2}=0.1 Pa s$
ストークス	St	$1 St=1 cm^2 s^{-1}=10^{-4} m^2 s^{-1}$
スチルブル	sb	$1 sb=1 cd cm^{-2}=10^4 cd m^{-2}$
フォント	ph	$1 ph=1 cd sr cm^{-2} 10^4 lx$
ガル	Gal	$1 Gal=1 cm s^{-2}=10^{-2} ms^{-2}$
マクスウェル	Mx	$1 Mx=1 G cm^2=10^8 Wh$
ガウス	G	$1 G=1 Mx cm^{-2}=10^4 T$
エルステッド	Oe	$1 Oe \triangleq (10^3/4\pi) A m^{-1}$

(e) 3元系のCGS単位系とSIでは直接比較できないため、等号「△」は対応関係を示すものである。

表10. SIに属さないその他の単位の例

名称	記号	SI単位で表される数値
キュリ	Ci	$1 Ci=3.7 \times 10^{10} Bq$
レントゲン	R	$1 R=2.58 \times 10^4 C/kg$
ラド	rad	$1 rad=1 cGy=10^{-2} Gy$
レム	rem	$1 rem=1 cSv=10^{-2} Sv$
ガンマ	γ	$1 \gamma=1 nT=10^{-9} T$
フェルミ	fm	$1 \text{ フェルミ}=1 fm=10^{-15} m$
メートル系カラット		$1 \text{ メートル系カラット}=200 mg=2 \times 10^{-4} kg$
トル	Torr	$1 Torr=(101 325/760) Pa$
標準大気圧	atm	$1 atm=101 325 Pa$
カロリ	cal	$1 cal=4.1868 J ([15^\circ C] \text{ カロリー}), 4.1868 J ([IT] \text{ カロリー})$
ミクロ	μ	$1 \mu=1 \mu m=10^{-6} m$

