

解説

プラズマ実験解析・制御への ニューラルネットワークの応用

竹田 辰興, 彌政 敦洋¹⁾
(電気通信大学情報工学科, ¹⁾九州大学応用力学研究所)

Applications of Neural Networks to Data Analysis and Control of Fusion Plasma

TAKEDA Tatsuoki and IYOMASA Atsuhiro¹⁾

The University of Electro-Communications, Department of Computer Science, Chofu 182-8585, Japan

¹⁾*Kyushu University, Research Institute of Applied Mechanics, Kasuga 816-8580, Japan*

(Received 25 May 2002)

Abstract

Applications of neural networks to data analysis and control of fusion plasmas are reviewed. First, a brief introduction to the general features of a neural network is presented, where the neural network is considered as a continuous mapping device, a classification device, a statistical processing device, and a time series prediction device. Then, the applications of neural networks to the research field are explained where the problems to be solved are classified as fitting function, shaping an experimentally obtained spectrum, analyzing equilibrium quantity, prediction, tomography, and control problems. Throughout the article, we restrict ourselves to description of applications of multi-layer neural networks.

Keywords:

multi-layer neural network, plasma, nonlinear optimization, asymmetric Abel inversion, computerized tomography, inverse problem

1. はじめに

ニューラルネットワークの研究は、本来、生物システムの中で最も複雑なサブシステムである神経回路網の構造や機能を明らかにすることを目的に行われるようになったものである。したがって、ここで述べるような計算機プログラムや専用電子回路でその働きを模擬したシステムは「人工ニューラルネットワーク (ANN; Artificial Neural Network)」と呼んで生物のニューラルネットワークから区別するのが正しいが、ここでは混乱することもないと思われるので慣用にしたがってニューラルネットワークと呼ぶことにする。ニューラルネットワー

ク一般についての書籍や解説論文も多数存在する[1-4]が、ここではプラズマ核融合分野における実験解析や制御への応用の観点からニューラルネットワークについて解説する。

20世紀の中葉に現在のニューラルネットワークの基礎をなすいくつかの重要な研究がなされ、それらを経て脳の働きを模擬する最も簡単なニューラルネットワークであるパーセプトロンの概念が発見された[5-7]。当初、この単純なパーセプトロンの発展によって脳の働きが解明されるであろうという期待が持たれた。しかし、いくつかの理由により単純なパーセプトロンでは脳で行われて

author's e-mail: takeda@im.uec.ac.jp

いるような複雑なデータ処理は行えないということがわかり、研究は一見下火になった。このような時期にあってもニューラルネットワークの研究は着実に進められ、1980年代中葉にRummelhartらの研究により誤差逆伝播法[8,9]を学習法とする多層ニューラルネットワークが広く知られるようになり、ニューラルネットワーク応用の新しい時代が始まった。プラズマ核融合の研究開発分野における応用研究は1990年ごろから始まって現在ではすでに多くの研究成果が得られているが新しい手法の研究開発も次々と進められている。

ニューラルネットワークは、構造、学習法、ニューロンのタイプ等いろいろな視点から分類することが可能であるが、ニューロン間の結合形態を示すネットワーク構造によって分類するのが最も基本的な分類法である。ここでは、ニューロンが層状に配置されデータは入力層に属すニューロンから中間層を経て最後の出力層に順次伝達される多層ニューラルネットワーク（多層パーセプトロン）の応用に限って解説する。

2. ニューラルネットワーク概要

2.1 ニューラルネットワークの考え方

ニューラルネットワークは、比較的単純な機能を持つプロセッサであるニューロンを結合して構成されているシステムであるが、『ニューラルネットワークとは何であるか』という問いに対して正確に答えることは容易ではない。この問いに対しては観点の違いによって次のようにいろいろな答え方ができる。

(1) 連続写像関数

ニューラルネットワークとは I 次元入力空間から K 次元出力空間への連続写像である。ここで、 I, K は、それぞれ、入力変数と出力変数の数である。後に記すように、この連続写像には具体的な解析的表現を与えることができ、解析的な微分演算が可能である。

(1.1) 豊かな関数表現力

この連続写像を表す関数はニューロン間の結合路の数に等しい数のパラメータ（ウェイト）を含んでおり、このパラメータの値を調整することで極めて広い範囲の関数を表現することができる。「ある条件の下に任意の連続関数を任意の精度で近似できる」ことが数学的に証明可能である[10-12]。特にニューラルネットワークによる写像では比較的少数のパラメータで広い範囲の関数を精度よく近似できるという特徴がある。このことから『ニューラルネットワークは豊かな関数表現力を持つ』と言われることがある。

(1.2) 学習と汎化

ウェイトの値は、ニューラルネットワークが離散的に与えられた有限個の入力パターンに適應するように決定される。この操作をニューラルネットワークの「学習」と呼ぶ。これは、内挿、平滑化、関数当てはめの組み合わせだったもので、学習後のニューラルネットワークは学習に用いた入力データに対してのみならず未学習の入力データに対してもよい近似値を出力する。ニューラルネットワークのこの能力を「汎化」能力と呼ぶ。

学習は、反復計算によって非線形最適化問題を解く過程であるので一般に比較的長い計算時間を要するが、学習済みのネットワークの利用は、単純な代入計算で関数値の評価をするだけだから極めて短時間で計算ができ実時間制御等に適用するのに適している。

(1.3) 効率的学習方法の存在

多層ニューラルネットワークにおいては効率的な学習方法が存在するということが大きな特徴である。ニューラルネットワークの学習とは目的関数の最小点を求める典型的な非線形最適化問題である。この際の基本的な演算は目的関数のウェイト微分の計算であるが、ネットワークの多層構造を有効に利用することで演算量が大幅に減少する。

(2) 分類装置

ニューラルネットワークは入力されたデータをいくつかの組に分類する働きを持つ。ニューラルネットワークの研究は認識問題の研究から始まったことを考えれば、これが分類装置であるという考え方は自然である。

(3) 統計処理装置

自然科学、社会科学等の分野を問わず、ある関係 R で結ばれ、数値で表現された事象 A と事象 B の組を考える。関係 R がある関数形で与えられているならば A と B の関係は明白である。しかし、実験、観測、観察等の行為を通じて得られるのは、有限個の離散的な事象 A と B の数値データの組である。これらのデータにはいろいろな原因によるノイズが含まれているが、このような状況下で $B = R(A)$ の関係を統計的に導くことができる。これは、統計的な関数当てはめ問題であるので、一般的には、最適化すべき目的関数を適当に選んで最小二乗法に基づいた処理を行う。内挿、平滑化、関数当てはめを同時に行って、ニューラルネットワークによって関係 R が構築される。

(4) 時系列解析装置

あるシステムについて時間的に等間隔に得られた観測データの列を時系列と呼ぶ。そのシステムは、(陽には

与えられていない) 何らかの方程式系にしたがって時間発展をする力学系であることは十分に考えられる. この場合, ある時刻におけるすべての状態変数の値が得られるならば, 未来の状態変数の値は予測可能であるはずである. 現実には, 観測される状態変数の数はこのような予測計算を行うには不十分である. しかし, 後に示すように, システムを決定論的方程式に従う力学系と見ることにより, 一変数の時系列からシステムの状態空間を再構築して, ニューラルネットワークを使って未来を予測する可能性が残されている.

2.2 多層ニューラルネットワークの構造

入力層, 出力層, $(M-2)$ 個の中間層の合計 M 層から構成されるニューラルネットワークを M 層の多層ニューラルネットワークという (層の数を数えるとき入力層を含めない場合もある). データは, 各ニューロンにおいて重み付き和と活性化関数による非線形変換という操作を受けながら, 入力層から順次中間層を経て出力層に向かって流れる. この際, 隣り合う層のすべてのニューロンの間に結合路があるが同一層のニューロン間には結合はない. また, すべてのニューロンには固定値 (通常, -1 に設定) を出力するバイアスニューロンからの経路も入力チャンネルになっている. 例として, $M=3$ の多層ニューラルネットワークの概念図を Fig. 1 に示す. このネットワークは入力層, 中間層, 出力層が, それぞれ, I, J, K 個のニューロンから構成されており (バイアスニューロンを除く), 入力層のニューロンに x_i ($i=1, \dots, I$) を入力すると出力層から y_k ($k=1, \dots, K$) が出力される. また, この写像関数は次式のように具体的に書き下すことができる.




Fig. 1 Schematic diagram of a three-layered neural network.

$$y_k = \sigma \left[\sum_{j=1}^J w_{jk}^{(2)} \sigma \left(\sum_{i=0}^I w_{ij}^{(1)} x_i \right) - w_{0k}^{(2)} \right], \quad (k=1, \dots, K), \quad (1)$$

ここで, $w_{mn}^{(q)}$ は第 q 層の第 m ニューロンから第 $q+1$ 層の第 n ニューロンへの経路に付与されたウェイトで, $w_{0m}^{(q)}$ はバイアスである. なお, $x_0 = -1$ である. σ は活性化関数で, 目的に応じて, 各層ごとあるいは各ニューロンごとに別のタイプの関数を使うこともできる. 活性化関数としては次のようなシグモイド型のロジスティック関数がよく用いられる.

$$\sigma(X) = \frac{1}{1 + e^{-X}} \quad (2)$$

一度に入力するデータ (入力チャンネルの数だけある) を一組として, 「1 パターン」と呼ぶ. あるパターンに対応する出力データ変数の正しい値が既知である時, これを「教師データ」と呼ぶ. 入力データと教師データから構成される多数の組を用意し, これらの組に対して正しい入力・出力関係が構成されるようにネットワークのウェイトを調整することが「学習」である. この学習を「教師あり学習」という. 学習は, 通常, 出力データと教師データの差の二乗和が最小になるように重みを調整して行う. 出力データと教師データの差の二乗和は誤差評価関数 (目的関数) と呼ばれ, 次のように表される.

$$E = \sum_{p=1}^P [\bar{y}^{t(p)} - \bar{y}^{NN}(\bar{x}^{(p)}; \bar{w})]^2 \quad (3)$$

ここで, P は入力パターン総数で, NN と t はネットワーク出力と教師データを示す.

なお, 本解説では, 第 q 層のバイアスニューロンを除くニューロン数が N_q であるような Q 層ニューラルネットワークの構造を「 $N_1 \dots N_q \dots N_Q$ 」と表すことにする.

2.3 学習と汎化

目的関数はウェイトの関数であるので, 次式に従ってウェイトの値を更新して最適解を探索する. これは「勾配法」または「最大傾斜法」と呼ばれる非線形最適化法である.

$$w_{mn}^{(p)\text{new}} = w_{mn}^{(p)\text{old}} + \Delta w_{mn}^{(p)\text{new}} \quad (4)$$

$$\Delta w_{mn}^{(p)\text{new}} = -\alpha \left(\frac{\partial E}{\partial w_{mn}^{(p)}} \right) + \beta \Delta w_{mn}^{(p)\text{old}} \quad (5)$$

ここで、 α , β はそれぞれ、学習率、慣性項係数と呼ばれる量で収束性能を高めるように調整する。最適解探索には勾配法以外的高速な高次最適化法を採用することも多い。

誤差逆伝播法による学習は、まず、(1)ネットワークに入力データを与えて、入力層から出力層に向かって順方向の計算を行う。この際、各ニューロンにおいて計算された活性化関数の微分値は次の逆方向計算のために保存しておく。次に、(2)ネットワークの出力データと教師データの差から構成された目的関数に基づいて、出力層から入力層の方向に向かって目的関数のウェイト微分を順次計算していく。この微分値を使って上式に従いウェイトの更新量を求めてウェイトを順次更新していく。

勾配法を用いる学習過程には、バッチ法(一括学習法)とオンライン法(逐次学習法)がある。学習用のすべてのパターンを入力して出力値を計算した後にまとめてウェイトを更新するのがバッチ法であり、1パターン入力して出力値を計算するごとにウェイトを更新するのがオンライン法である。通常の線形最小二乗法で行っている計算はバッチ法に対応する。上の(5)式はバッチ法についての式である。学習率の大きさは収束の速さを支配するが、バッチ法では有効な学習率適応制御法があるのに対しオンライン法にはない。しかし、オンライン法ではパターンごとのウェイト更新によってある種のランダム性が取り込まれるためにシステムが局所最小点に陥った時そこから抜け出しやすいと言われており、実際多くの複雑な問題ではバッチ法よりもよい収束性能が得られる。

学習過程では反復法による収束計算が行われるために反復をいつ止めるかが問題である。この際、注意すべきことはネットワークの汎化能力と学習能力のトレードオフである。一般に学習を進めて教師データを高精度で表現できるようになると汎化能力が低下して未学習データに対し精度よい近似解を与えなくなる。これを学習段階で防ぐ方法の一つに学習データの一部を検証データとして保存し学習には用いず誤差評価のためだけに用いる方法がある。学習の進行と共に検証データの誤差も低下するが学習しすぎると検証データの誤差が増え始めるので、検証データの誤差が最小になる近傍で学習を中止すれば汎化能力を維持しつつ十分な学習が可能である。これを「検証データを用いた早期停止法」という[13]。複雑すぎるネットワーク(多すぎるウェイト)も汎化能力を低下させる原因となるので、ネットワークの大きさを

必要最小限に保つことも重要である。

2.4 残差最小化学習

教師あり学習における目的関数としては、通常、入力値に対応するニューラルネットワークからの出力値と教師データの差の二乗の和を採用する。大多数の学習においては、このような目的関数を採用するので、この学習を「標準的学習」と呼ぶことにする。

ところで、目的関数の式において、ネットワーク出力と教師データの部分を、次のようなネットワーク出力が満たすべき方程式に置き換えることも可能である。すなわち、

$$E = \sum_{p=1}^P \{L[\bar{x}^{(p)}, \bar{y}^{NN}(\bar{x}^{(p)}; \bar{w})]\}^2 \quad (6)$$

選点 $\bar{x}^{(p)}$ ($\bar{x}^{(p)} \in \bar{\Omega} \subset \Omega; p=1, \dots, P$) を定義域 Ω の中に一様に十分多くとれば、この誤差評価関数を最小化する解は次式の近似解となることが予想される。

$$L[\bar{x}, \bar{y}(\bar{x})] = 0 \quad (7)$$

ここで、「一般的な関係式」 L には微分、積分を含むいろいろな作用素が含まれていてもよい。この目的関数を最小化するような学習を「残差最小化学習」と呼ぶことにする。

残差最小化学習法には次のような特徴がある。 L として微分方程式、積分方程式、微分積分方程式、代数方程式等いろいろな種類の方程式を採用できるので、残差最小化学習を行うことはこれらの解を直接求めることに相当する。このため、あらかじめ教師データを準備しておく必要はない。このような学習法は、van Milligen, *et al.* および Lagaris, *et al.*によって微分方程式の解法として使えることが示された[14, 15]。微分方程式などが解ける理由は、ニューラルネットワークの解が解析的表現を持った近似解であるということによっている。学習は離散的に与えられた選点の値について数値的に行うが、解は解析的な関数による近似解であるので学習後に選点以外の点の値を計算することができる。この方法は微分方程式解法として見ると、従来からの方法に比べて効率が悪いが、MHD平衡解を求める場合[14]のように後で解の高精度微分が必要になるような場合には有用である。また、残差最小化学習法は、測定値と微分方程式を同時に(近似的に)満たす解を求める「データ同化問題」に使える等非常に広範囲の問題に容易に適用が可能であることが竹田らの研究により示されている[16-22]。

3. プラズマ実験解析・制御とニューラルネットワーク

3.1 関数当てはめ問題

この範疇に属する代表的な問題は「スペクトル整形問題」である。物理実験で得られるデータの解析にあたってはいろいろな測定量のスペクトルについて解析を行うことが必要になる。具体的な測定量としてプラズマ中の原子やイオンから発せられる光のスペクトル分析がある。このスペクトルは、次のようなガウス関数型の分布を持っている。

$$F(\lambda) = A \exp\left[-\frac{(\lambda - \bar{\lambda})^2}{w^2}\right] \quad (8)$$

ここで、 $F(\lambda)$ は、波長 λ に対するスペクトル強度で、 A , $\bar{\lambda}$, w は、それぞれ、振幅、中心波長、スペクトル幅を表している。スペクトル解析の目的は、このような振幅、中心波長、スペクトル幅を求めて、発光粒子の温度、並進速度、量等を推定することである場合が多い。しかし、測定されるスペクトル波形は測定データに含まれるノイズや測定装置の感度特性などのために、測定対象のシステムが持っている本来のスペクトル波形とは異なるものであるのが普通である。さらに、複数のスペクトル線がスペクトル幅に比べて狭い波長領域に分布しているようなときにはスペクトル線の重なりによってガウス関数型と異なるスペクトル分布が測定されるのでこれを複数のガウス関数型分布に分離して特徴的なパラメータを決定する必要がある。これについては、DIII-D トカマク、COMASS トカマク等での研究が報告されている[23-27]。

このような解析を具体的なプラズマ分野の問題に適用した例として、DIII-D トカマク装置における荷電交換粒子スペクトルの分離の例を記す[26]。スペクトルの一例が Fig. 2 に示してあるが、右側のピークは3つのガウス型ピークが重なって1つのピークになったものである。DIII-D トカマクでは、従来、CERFIT と呼ばれる半自動的曲線当てはめプログラムを用いて荷電交換粒子スペクトルの解析を行ってきたが、1日あたり200,000ものスペクトルデータが得られるので解析を完全自動化する必要があるとニューラルネットワークを用いたプログラム CERNEURO を開発した。ニューラルネットワークには、指定した280の波長に対する光の強度が入力され、出力層からは、例えば、あるピークの振幅、中心波長、スペクトル幅が出力される。ネットワーク構造は、例えば、280-34-16-3となる。ニューラルネットワークの学習




Fig. 2 An example of spectra of charge exchange recombination data in DIII-D [26].

には、3,000~4,000の解析済みデータを用いて反復計算を行い、当てはめ誤差が設定値より小さくなった時に学習を終了させる。操作員の介入によってノイズの大きいデータ等を排除した時のCERFITの解析結果に比べると誤差が大きくなるが、運転に際して実時間で解析データを得てフィードバックをかけるための目的には十分対応できる結果が得られた。

一方、測定装置の感度特性を考慮に入れて、低い波長分解能を持つスペクトル測定装置で得られた測定値から元のスペクトルを再現させるためにニューラルネットワークを用いたCOMPASSトカマクにおける例が Bishop らによって報告された[24]。スペクトルを観測するときに、異なる波長領域を担当し有限の波長幅の積分強度を出力する3つの測定器からの測定値 R , G , B からガウス型のBIVスペクトルの3つの特性値(振幅、中心波長、スペクトル幅)を求めるのがこの解析の目的である。それぞれの測定器の感度が、 $r(\lambda)$, $g(\lambda)$, $b(\lambda)$ で表されるとき、 R , G , B は次式で表される。

$$\begin{aligned} R &= \int_0^{\infty} F(\lambda) r(\lambda) d\lambda, \quad G = \int_0^{\infty} F(\lambda) g(\lambda) d\lambda, \\ B &= \int_0^{\infty} F(\lambda) b(\lambda) d\lambda, \end{aligned} \quad (9)$$

ここで、 $F(\lambda)$ は求めるべき実際のスペクトル強度((8)式)である。問題は、 R, G, B の測定値 $F(\lambda)$ から特徴づける A , $\bar{\lambda}$, w を求める逆問題となる。実際は、測定値は振幅 A に比例するので、2つの入力データで2つのパラメータを求める問題に帰着され、ニューラルネットワークの構造は、2-50-2の形をとる。1,000のスペクトルデータを900の学習データと100の検証データに分けて学習した結果、不適切なデータを操作員の介入によって外せば高速な解析方法として役立つことが示された。




Fig. 3 Comparison between the trial function fits and the neural network fits of the equilibrium quantities in DIII-D [29].

比較的低温のプラズマの密度や温度を測定するのに静電プローブを用いることがあるが、これはプローブの電流・電圧特性を表す曲線の形がプラズマの密度や温度に依存することを利用した測定である。Laginらは、スペクトル整形問題と同様の考え方で、TFTR トカマクの周辺プラズマのプローブ測定データ解析にニューラルネットワークを適用した[28]。ダブルプローブの場合、電流(i)・電圧(v)特性は次のように表せる。

$$i(v) = i_0 + c_0 n_e \sqrt{T_e} \tanh\left(\frac{v - v_0}{2T_e}\right) \quad (10)$$

ここで、 n_e と T_e は、それぞれ、電子密度、電子温度を表し、他の量は定数である。入力データは、 $-150 \leq v \leq 150$ volt の区間を 4 volt ごとに設定した電圧 (75点) に対応する電流値であって、出力データは電子密度と電子温度である。ネットワークの構造は75-30-2である。学習データは、密度および温度の領域 ($10^{11} \leq n_e \leq 10^{13} \text{ cm}^{-3}$ および $5 \leq T_e \leq 100 \text{ eV}$) 内に132点を設定して電流・電圧特性を計算したものを使っている。10,000回の反復計算の結果、密度と温度の平均誤差が、それぞれ、2%および11%の解が得られた。同じ程度の精度の解を得るために従来の統計的手法を使った場合に比べて300倍ほどよい計算効率を得られている。

3.2 平衡量解析

プラズマ核融合研究の分野におけるニューラルネットワークの利用に関する研究で最初に注目を集めたものが

Listerらによるプラズマ位置・形状の解析である[29]。この解析は、「プラズマ外部に置かれた磁気プローブ等からの信号 (\vec{M})」をネットワークに入力し「トロイダルプラズマのMHD平衡を特徴づける量 (\vec{G})」を出力することを目的にしている。なお、ここでは、MHD平衡を特徴づける量のことを「平衡量」あるいは「平衡データ」と呼ぶことにする。 \vec{G} から \vec{M} を求める写像 $\vec{M} = L^{-1}(\vec{G})$ は簡単に計算できるが、逆写像 $\vec{G} = L(\vec{M})$ を得ることは困難、あるいは、不可能である。Listerらの研究では、DIII-Dトカマクのシングル・ヌル・ダイバータ配位の場合について学習を行い実際の実験データを用いてニューラルネットワークによる方法の妥当性を検証した。出力データとしては、DIII-Dの形状制御に用いられている7つの平衡量(X点の位置、プラズマ表面の容器壁からの距離、電流中心、内部インダクタンス等)、入力データとしては22個の接線磁気プローブ信号、20個の磁束ループ信号、あるいはそれらの組み合わせなどが用いられた。これらのデータは、1,208個の実験データにおける制御電流等のデータに対してMHD平衡解析プログラムを使って計算したものである。解の精度は、従来の線形解析の場合に比べて全般的に見て50%向上したに過ぎなかったが、ニューラルネットワークによる解析が非線形解析であることに注目すれば、プラズマ断面の非円形度が高くなったときにより高い改善が期待されることが示唆された (Fig.3)。

この種のニューラルネットワーク応用は、その後、各

地の核融合実験装置で試みられるようになった[30-32]. 特に、この解析はプラズマのMHD平衡制御に直接関係する応用として注目された. 十分広範な平衡量に対応できるように学習がなされていれば、実時間制御に利用可能な程度の精度および時間で磁気プローブ信号から平衡量が計算できることが期待される. PBXトカマクは極めて非円形度の大きな断面を持つ装置であるので早くからこの方法の研究が行われ大非円形度でもこの方法が有効であることが示された[30]. JT-60Uにおいては、ディスラプション時に見られるプラズマの急速な垂直移動現象(VDE)の解析に用いられて良い成果が得られた[32].

上に述べたように、ニューラルネットワークを用いた方法によれば線形の解析に比べて解の平均二乗誤差を小さくできる上に、プラズマの断面の変形度が大きい場合や平衡量の変域が大きい場合に改善が見られることが確認できた. 将来の動向に関しては、AlbaneseらによってITERの平衡解析に応用した場合についての検討が行われている[33]. この研究では、従来法である関数パラメータ化法(FP法)と比較の下に検討が進められた. ITERの燃焼実験の段階では、学習データとして2,000程度の平衡データを使うことで十分な性能を発揮できるとして、FP法と同等の評価が与えられている. ニューラルネットワークによる方法はFP法の非線形問題への拡張と位置づけられ、上記の特徴が再確認された. Wijndandsらは、DIII-DおよびTore Spuraの平衡を対象に、従来法(FP法, CCA法: 正準相関解析法, SVD法: 特異値分解法)との比較研究を行い、ニューラルネットワークによる解析法の優位性を確認した[34].

学習の高速化が重要であることは言うまでもないが、実験解析・制御にあたっての計算実行時間の高速性[34]の問題は、特に、中小型装置において重要な課題である. 例えば、彌政らは、TRIAM-1Mトカマクのプラズマ位置制御にニューラルネットワークを用いることを目指して平衡解析に関してこの課題の研究を行った[35, 36]. 具体的には、入力変数を削除する等してニューラルネットワークの構造を単純化したりプラズマ位置予測計算を行い位置計算を節約する等を試みて高速化のための基礎的研究を行った.

一方、制御を念頭に置いた信頼性向上の研究も行われている. 通常、ニューラルネットワークの性能は平均二乗誤差により評価される. しかし、制御に使用する際には1点でも制御可能領域を逸脱することは許されないので、平均誤差が小さくなるだけでなく最大誤差も限度内である必要がある. センサ等の異常に伴う入力信号の異

常への対応も不可欠である. これらの問題に対処するためにKSTARトカマクの研究に関していくつかの新しいネットワーク構造が提案された. その中の一つである二重ニューラルネットワーク(DNN: Double Neural Network)[37, 38]は、単独で平衡量の解析が可能な多数のニューラルネットワークからなる一次ネットワークと二次ネットワークから構成されており、二乗誤差を小さくすると同時に最大誤差を抑制することを目的としている. 性能評価の結果、所期の目的が達成されていることが確認され、センサ異常に基づく誤信号はエラーフィルタ付きDNN法を使って判別できることが示された.

このほかにも、プラズマの平衡解析にニューラルネットワークを利用することに関する多数の文献がすでに存在する. Wróblewskiらの研究[39]は磁気プローブデータから磁気軸の安全係数(q_0), 安全係数の最小値(q_{\min}), およびその位置($\rho_{q_{\min}}$)を定めることを目的としたもので、ニューラルネットワークによって決定できるパラメータの種類を広げた点で意味がある.

3.3 予測問題

核融合研究における重要な課題の一つにディスラプション現象の予測がある. ディスラプション現象は複合的な現象である上に実際に発生する現象には原因の異なるいくつかの違うタイプものがあるため、この現象の発生を方程式に基づいて確定的に予測することは現在のところできない. しかし、ディスラプションを発生させる原因は必ずプラズマに内在すると考えられるし、またこの原因に関する情報は事前の計測データの中に含まれていると考えるのが自然である. そこで、事前の計測データとディスラプション現象の発生との間の数値的關係のみに注目してディスラプション現象の発生を予測しようというのが、ニューラルネットワークを用いたディスラプション現象予測の立場である. 現在までに試みられたニューラルネットワークによるディスラプション予測の方法は、時系列予測, 安定境界予測, プラズマ寿命予測の3種類に分類することができる.

(1) 時系列予測

ディスラプション現象を顕著に示す計測データの将来の時間波形を予測してディスラプション現象の発生を予知する方法である. 具体的には、タイムステップ τ ごとの測定によって離散的に与えられた時刻 t までの観測データ $x(t-M\tau), \dots, x(t-\tau), x(t)$ を使って未来の時刻 $t+\tau$ におけるデータ $x(t+\tau)$ を予測(SS: シングルステップ予測)し、この予測値を組み込んで得られた $x[t-(M-1)\tau], \dots, x(t), x(t+\tau)$ を使って時刻 $t+2\tau$ にお

るデータ $x(t+2\tau)$ を予測するという過程を反復して未来の時刻 $t+m\tau$ のデータ $x(t+m\tau)$ を予測 (MS: マルチステップ予測) する, あるいは, データ $x[t-(M-1)\tau], \dots, x(t), x(t+\tau)$ から直接, 時刻 $t+m\tau$ でのデータ $x(t+m\tau)$ を予測 (MTS: マルチタイムスケール予測) する等の方法がある. 時系列データから学習によって次の関数形を求めることが基本である.

$$x(t+m\tau) = f[x(t), \dots, x(t-M\tau)] \quad (11)$$

ニューラルネットワークの豊かな関数表現力と学習能力, 汎化能力を活用すれば測定データの組から上記の非線形関数を求めることは比較的容易である. この方法は線形問題でよく研究がなされている線形最良予測 (自己回帰予測) と形式的には類似の形状をしている. 自己回帰予測の際は関数 f として $x(t-M\tau), \dots, x(t-\tau), x(t)$ の線形結合を採用する.

$$x(t+\tau) = \sum_{j=0}^M a_j x(t-j\tau) \quad (12)$$

しかし, 一般の時系列データの予測可能性という観点から見ると両者は全く異なった根拠に基づく方法である. 自己回帰予測は線形ストカスティックモデルに基づき線形の相関が存在することを根拠にして予測可能性を仮定しているが, 非線形時系列予測問題では非線形的決定論を根拠としている. すなわち, 時系列データで表現される波形がいかにランダムに見えようとも背景には決定論的力学系が隠れているので同じ状態から出発すれば必ず同じ状態に到達するという信念に基づいた時系列予測になっている.

非線形時系列予測にはいくつか注意すべき点がある. まず, 線形予測の場合と異なり, 測定データは力学系の状態を表す複数個 (J 個) の変数の一部 (普通は 1 変数) でしかないということである. 力学系の状態は J 個の変数を座標軸とする J 次元空間の中の 1 点として表される. J 個の変数値が完全に測定できればある時点での力学系の状態が完全に決まるので将来の状態を完全に決定することができる. 一般には 1 変数の時系列データのみが得られているので, 時系列データから力学系のフラクタル次元 D を求め, Takens の定理に基づいて, $2D+1$ を状態空間の次元とする. 即ち, 入力時点数 $(M+1) = 2D+1$ とすれば入力データは予測に必要な情報を含むものと考えられる. 次に問題となるのは, このような状態空間軌道は力学系の状態空間におけるストレンジアトラクタ上にあると考えられるので初期値鋭敏性

が極めて強く長期予測が困難であるという点である. これは, 非線形時系列予測問題に伴う基本的課題であるので本質的な改善はかなり難しい. 測定や計算の誤差を減らしアルゴリズムを工夫したり関係する測定量の種類を増やして実用上必要とされる未来の時点の予測ができるようにすることが課題である.

プラズマ核融合分野でのこのような非線形時系列予測の研究は, Hernandez らが TEXT トカマクのディスラプション予測を行ったのが最初である [40]. TEXT の予測では, 磁気プローブ信号の時系列を用いてマルチステップ予測とマルチタイムスケール予測による長期予測が試みられた. 使用されたニューラルネットワークは, シングルステップおよびマルチステップ予測については 15-9-3-1, マルチスケール予測については 15-8-1 の構造を持つものでタイムステップ幅は 0.04 ms である. 前者の方式による時系列マルチステップ予測により 1.12 ms 先の値を予測する場合メジャーディスラプションの前に起きるマイナーディスラプションのパターンを識別することが可能であることが示された (Fig. 4). より未来の値を求めるために反復数を増やしていくと指数関数的にネットワーク性能が劣化していく. マルチタイムスケール予測は $m = 25$ とした予測まで行われたが, 実際のデータと予測されたデータと時刻にずれが生じており良好な結果は得られなかった. その後, TEXT では, 軟 X 線信号を使った予測の研究も行われ, 予測時間の改良が見られた [41]. Sengupta, Ranjan によって ADITYA トカマクについて同じ原理に基づく予測研究が行われた [42]. 複数の計測信号 (4 つのミルノフコイル, 軟 X 線信号, H_α 信号) の 10 タイムステップ分の値を入力し, 60-16-16-1 の構造を持つネットワークでマルチステップ予測 (タイムステップ幅: 0.02 ms) を行い, ディスラプション発生前の約 8 ms の時点で予測が可能であることが示された. 測定信号の種類によって予測性能が変わることは, 『良好な予測のためにはプラズマ内部においてディスラプションの発生原因の存在する位置と信号の発生位置が近いことが重要である』ことを示唆している. これらの方法で, 達成された性能を Table 1 にまとめてある.

(2) 安定境界予測

時系列予測の方法では, ディスラプション現象発生の物理的メカニズムは「隠れた力学系」の性質に押し付けて表面に現れた測定値の数理的性質にのみ依存して予測を行うが, この安定境界予測ではディスラプション現象発生の物理的メカニズムを考慮してプラズマの状態が不安定領域にどれくらい近づいたかを推定してディスラプ

シヨンの発生を予測する。ディスラプション現象の発生原因やディスラプションに至るシナリオがいくつか考えられることから、それに応じて異なる安定境界に関してディスラプション予測ができる。今までDIII-Dトカマク(限界ベータ値)とADITYAトカマク(密度限界)で行われた研究が報告されている[43, 44].

DIII-Dのディスラプション予測は『ある測定時点のプラズマの状態を示す諸量をネットワークに入力してその




Fig. 4 The actual and predicted magnetic fluctuation signals of a TEXT tokamak disruption [40].

時点の「限界ベータ値」を出力する』ことが基本である。この時点での実際のベータ値が限界ベータ値に近ければディスラプション発生は近いと判断して警報を発する。このネットワークの学習には教師データとして使う限界ベータ値が必要であるが、これはそのショットのプラズマが最終的にディスラプションを起こす時点でのベータ値をその限界ベータ値と見なして使う (Fig. 5). 解析にあたっては、33-12-6-1の構造を持つネットワークが用いられた。入力データは、磁気プローブ、フラックスループ、反磁性ループ、ミルノフプローブ、 H_α 線モニタ、軟X線、可視分光、中性子検出器、マイクロ波干渉計である。学習にあたっては、84のディスラプション放電が用意され56ショットが学習データ、28ショットが性能試験用データとされた。テストの結果、ディスラプションの数10ms前に予測できることが示された (Fig. 6). 単純にTroyon限界を計算して予測した場合には50%の予測が的中し20%は誤警報であったが、この方法では90%以上の予測が的中し20%以下の誤警報であった。

一方、ADITYAにおいては、同様の原理に基づき、密度限界ディスラプションの予測について調べられた。入力信号としては、ミルノフプローブ他の合計13種類の信

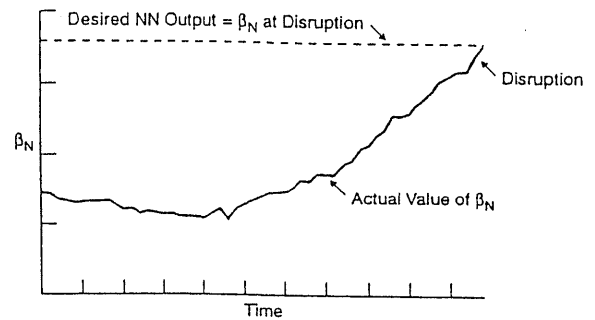


Fig. 5 Training principle for the disruption alarm neural network of DIII-D [43].

Table 1 Comparison of performance of time series prediction of disruption. MS: Multi-step prediction, MTS: Multi-time scale prediction, MP: Magnetic probe. #: Number of time steps employed for the input data. #P: Number of time steps to the predicted timepoint.

Year	Device	Network Structure (#I)	Prediction Mode (#P)	Time Step Width	Measured Signals	Maximum Prediction Time	Ref.
1996	TEXT	15-8-1(15)	MS(23)	0.04 ms	MP	1.12 ms	[40]
			MTS(25)	0.04 ms	MP	>1 ms	
1999	TEXT	15-9-3-1(15)	MS(63)	0.04 ms	SX	2.53 ms	[41]
			MTS(78)	0.04 ms	SX	3.12 ms	
2000	ADITYA	60-16-16-1(10)	MTS(200-400)	0.02 ms	4×MP, SX, H_α	8 ms	[42]




Fig. 6 Sample of neural network training results of the disruption alarm neural network of DIII-D [43].

号が用いられた。出力信号は、DIII-Dの場合には Troyon 係数であったのに対して、ADITYA の場合には密度に関する Murakami 係数がこれに対応している。実際のディスラプションは、予測された密度限界がそれに非常に近い値で起きており十分な精度でディスラプションを予測することが可能であることが示された。入力データ数を削減して 8 入力とし予測を行ったところ、性能の低下は見られず正しい予測の確率は 67%、誤警報を出す確率は 22%であった。

(3) プラズマ寿命予測

ASDEX-Upgrade の制御に用いられている今までの予測方法は厳密にはディスラプションを予測するものではなかったのでこれに代わるものとして新たにニューラルネットワークによるディスラプション予測システムが開発された[45, 46]。この方法では、安全係数、内部インダクタンスとその時間微分、Greenwald 密度限界で規格化した密度とその時間微分、入射パワーに対する放射パワーの比とその時間微分、スケールンク則で規格化したエネルギー閉じ込め時間、MARFE の有無、ロックモードの有無、規格化ベータ値とその時間微分の合計 13 の信号を入力データとし、ディスラプションが起きるまでの時間を出力する。ネットワーク構造は、13-30-1 である。出力値は 0 から 1 の間で規格化しており予測時間の最大値を 0.8 s (または 0.5 s) に制限し、最大値を超える予測時間は最大値と同じ値にしている。入力データも 0 と 1 の間に規格化され 25 ms にわたる平均値が 2.5 ms 毎に標本化される。教師データは安定性境界予測と同様




Fig. 7 Network prediction for a density limit disruption of ASDEX Upgrade. The alarm conditions are reached at $t = 3.955$ s, 65 ms before disruption [45].

の手順で用意する。約 1,400 ショットの中から学習データと 500 ショット程度のテスト用データが用意されて学習および性能テストが行われた (Fig. 7)。出力の最大値を 0.5 s とし、50 ms 以内にディスラプション発生が予測される時に警報が発せられるように設定された。ディスラプションの起きた 65 ショット中 85% が 50 ms 前の予測に成功しており、誤警報は 500 ショット中 1% であった。これはディスラプション予測としては十分な性能であると考えられる。オンラインの実験を行った結果、オフラインの計算結果とほぼ同程度の性能が実現できた。

3.4 トモグラフィ型問題

核融合プラズマの診断のためにニューラルネットワークを用いたコンピュータトモグラフィ (CT) を本格的に用いた例はほとんど見受けられない。しかし、馬らによってニューラルネットワークによる少数データコンピュータトモグラフィの新しい方法が提案されてモデルデータによるテストで所期の成果を得ている [16, 17]。電磁波干渉計測によるプラズマ密度再構成の問題は再構成像の等高線の形に制限を設けた一次元トモグラフィ問題と考えられるが、これについては多くの試みがなされている [18, 19, 24, 47]。電磁波反射計測のデータからニューラルネットワークを使ってプラズマ表面付近の密度分布を再構成する問題もアーベル変換に帰着するが、これについても ASDEX-Upgrade でテストが行われ、ロバストで高速で高精度であることが確認された [48-50]。

(1) 少数データ CT

透過 CT 型の逆問題の代表的な方法はフィルタ補正逆投影法である。医療用の X 線 CT に関してはきわめて高精度で効率の良い方法が開発されている。しかし、これらは測定データである線積分値を与える投影経路の数が十分多くかつ一様に分布している場合を想定している。プラズマ・核融合研究をはじめ、物理・工学の実験や自然観察では投影経路の数が必ずしも十分でなく (少数データ)、経路の分布も一様ではない。この問題を解決するためにニューラルネットワークを利用した新しい方法が提案され有効性がモデル数値実験で確認できた。目的は、二次元領域 Ω 内で定義された関数 $f(x,y)$ を多数の測定値 (線積分値) $g(r_p, \theta_p)$ ($p=1, 2, \dots, P$) から再構成することである (Fig. 8)。入力データを x, y とし、出力データを f とするネットワークを構成し残差最小化学習によって解を求める。誤差評価関数は次式のようなものを使う。

$$E = \sum_{p=1}^P [g^{\text{NN}}(r_p, \theta_p) - g_p^{\text{meas}}]^2 \quad (13)$$

$$g^{\text{NN}}(r_p, \theta_p) = \int_{(\rho)} f^{\text{NN}}(x,y) ds \approx \sum_q a_q^{(p)} f^{\text{NN}}(x,y) \quad (14)$$

ここで、NN はニューラルネットワークからの出力を、meas は測定データを表している。また、 $a_q^{(p)}$ は線積分を数値的に行う際の重みを表す。この学習を十分に行えば、ネットワーク出力 $f^{\text{NN}}(x,y)$ は求める再構成像になる。計測データの数 P が非常に多い時には従来法が優れているが、 P が少ない時にはこの方法が有利である (Fig. 9)。




Fig. 8 The computational domain for 2-dimensional CT image reconstruction [17].

(2) 非対称アーベル逆変換

プラズマ断面の二次元領域で定義された関数の形を透過型 CT の手法でプラズマ外部から確定しようとするにはプラズマ全周にわたってあらゆる方向のデータを求める必要があるが、再構成像の等高線の形やそれらの相互関係について条件を設ければ必要な計測データの数は大幅に削減できる。等高線の組が同心円で表される場合には一方向の線積分の組だけを使ってアーベル逆変換の手法で解を得ることができる。

マイクロ波等による電磁波干渉計データからの核融合プラズマの密度分布解析にはこの種の方法が用いられるが、一般に、プラズマ閉じ込め装置の中では密度分布形状は同心円状ではない。このような逆変換を「非対称アーベル逆変換」と呼ぶ。等高線の組が同心円でない場合には、逆変換に際し等高線の値のみならず等高線の形や位置までも決定しなければならない。ニューラルネットワークを非対称アーベル逆変換のために使用する方法としては、教師データを使ってニューラルネットワークを線積分データを局所密度分布に写像する統計的写像法と、ある種の非線形関数で密度分布が表せると仮定して関数系を決めるパラメータを求める方法、残差最小化学習法を使う方法等がある。

統計的写像法：入力データである電磁波干渉計データを、出力データである局所的プラズマ密度分布に直接対応づける方法で Bishop らの論文がある [24]。アーベル逆変換における「密度等高線は円形でしかも同心円である」という制約条件に対応するような「何らかの制約条件」として、Bishop らは、干渉計データ (6 点) に加え MHD 平衡の Lao-Hirshman 係数 (7 個) を入力データとした。

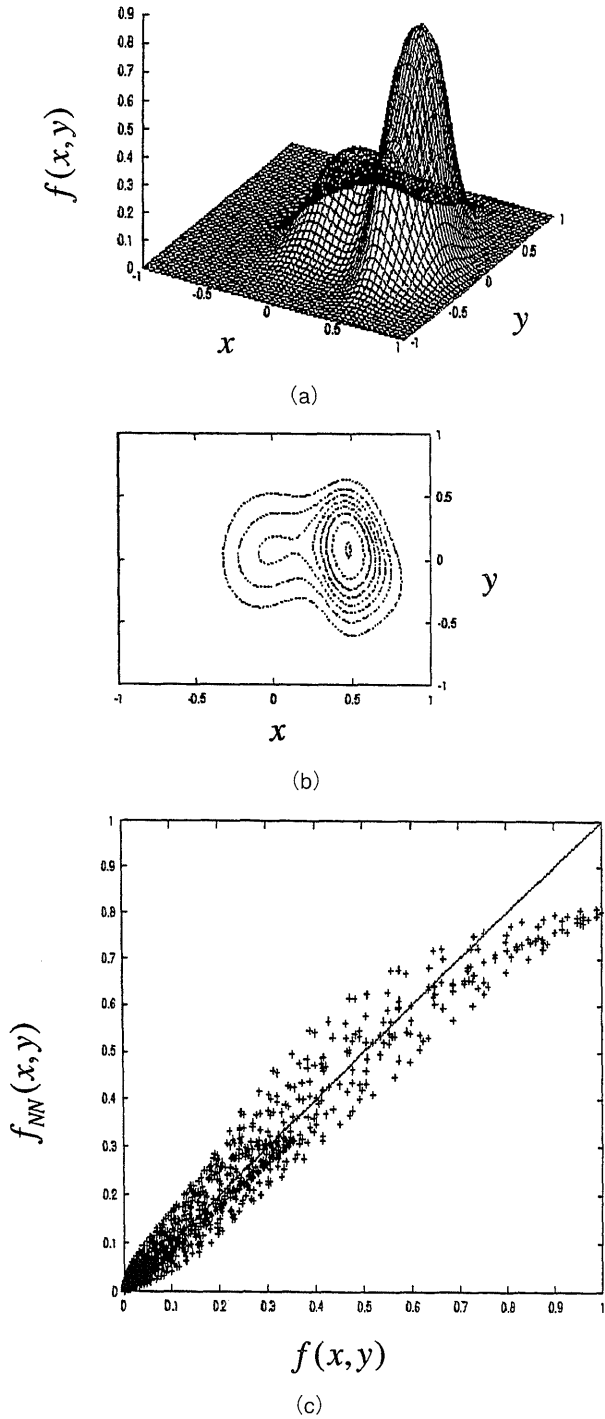


Fig. 9 Bird-eye view(a), contour plot(b), and correlation diagram (c) of reconstructed image $f_{NN}(x,y)$ (from an extremely small amount of projection data produced from the original double Gaussian peaks $f(x,y)$) (two peaks are placed on the $y=0$ line). The pivots of three fans of 10 beams each (30 beams in total) are located at angles of $0, \pi/2,$ and π on a circumference outside of the computational domain.

出力データは主半径上の35点の密度とした。教師データとしてはLIDAR計測で得られた密度の値が使われた。LIDAR測定は空間分解能は十分ある(9 cm)が時間分解能がない(1-2 Hz)のに対し、干渉計出力は時間分解能は十分ある(10 kHz)のに局所値が直接得られない。学習済みのネットワークは干渉計の時間分解能とLIDARの空間分解能を合わせ持つ。

非線形関数パラメータ決定法：分布形状を何らかの非線形関数で近似して測定データに適合するようにパラメータを決める方法である。Demeterのトモグラフィ[47]はこのタイプの分布再構成法の最も簡単な応用で、中心位置 (x_0, y_0) 、幅 (σ_x, σ_y) 、高さ (A) の5パラメータを持つガウス分布を決める問題に帰着させている。実験目的は、MT-1Mトカマクに不純物ペレットを注入して不純物の輸送過程を研究することで、不純物からの軟X線を水平・垂直方向のマイクロチャンネルプレートカメラ(MCP)からの合計32チャンネルのデータを使って行われた。32-20-1の構造のニューラルネットワークを5つ(出力パラメータ1つを1つのネットワークが担当)使った。測定経路が限られているが決めるべきパラメータの数が少ない場合には有効である。

残差最小化学習法：核融合プラズマの研究で、干渉計データからの密度分布解析のために比較的よく用いられるのは、オニオンピーリング法、スライス・アンド・スタック法等である。これらは、密度分布の等高線の形や位置を比較的少数のパラメータで表し、その可変範囲内で測定値(線積分値)を適合させる。よく制御された閉じ込め装置では、一連の実験におけるMHD平衡は1個あるいは数個パラメータ値の時間変化で表せる場合が多い。MHD平衡の磁気面はほぼ密度等高線と見てもよいので、MHD平衡データベースを組み合わせて密度等高線群の位置・形状をその中から選んで非対称アーベル変換が実行できる。しかし、MHD平衡から得られるデータと密度線積分値の関係は複雑でこの解析を精度良く行うことは従来の方法ではかなり困難である。ニューラルネットワークを残差最小化学習法で学習させることでこの解析が容易に実行できる(Fig. 10)。馬らはモデルデータについて数値実験を行いよい結果を得た[18]。LHDプラズマの密度解析に適用したところ従来の方法で求めた密度分布とよい一致を示し、MHD平衡パラメータとして使ったベータ値も反磁性信号から得られたベータ値の変化とよい一致を示した[19]。これは密度等高線の形も正しく再現されていることを示唆している(Fig. 11)。

3.5 制御




Fig. 10 Flow diagram of the asymmetric Abel inversion by the residual minimization training of a neural network [18]. After training is over the "feed-forward network" can, only by itself, calculate the local density distribution, $n(\psi_1), \dots, n(\psi_M)$ from a set of the measured data, ϕ_1, \dots, ϕ_K .

ニューラルネットワークを制御に用いる試みは種々の分野でなされている。プラズマ核融合研究の分野では、今まで、主として閉じこめ実験装置の運転制御のために、DIII-D, TFTR, COMPASS 等の装置で検討がなされ実際に使われている [51-54]。また、ITER の制御のためにニューラルネットワークの利用が積極的に検討されている [54]。ここまでの解説で触れた課題の中にも、制御の観点から計測データ解析の問題を取り扱った問題も含まれている。なお、制御系にニューラルネットワークを用いることの利点は異なる種類の複数信号を容易に組み合わせられることである。

これらの制御の問題とやや異なる重要課題に核融合炉における燃焼制御にニューラルネットワークを使ったシステムの検討がなされている。Vitela の問題設定では、次のダイナミカルシステム F (0次元プラズマシミュレーションプログラム) とニューラルネットワーク制御系 N を考える [55]。

$$\vec{z}_{k+1} = \vec{F}(\vec{z}_k, \vec{u}_k) \quad (15)$$

$$\vec{u}_k = N(\vec{z}_k) \quad (16)$$

ここで、 \vec{z}_k, \vec{u}_k は系の状態量と制御変数で、 k は離散的な時間である。問題は、ある範囲内で任意に選ばれた状態 \vec{z}_1 を初期条件として、目標状態 \vec{z}_t に落ち着くような制御が可能かどうかということである。自己点火条件に近い低温のもと不安定なオペレーション領域で核融合炉を運転する時にニューラルネットワークを使った制御装置がプラズマの安定化に有効に働くかどうかを確認するために、上記のダイナミカルシステム F と制御システム N から構成されるシステムの時間的振る舞いが調べられた (Fig. 12)。ネットワーク構造は3-16-3である。[通時的誤差逆伝播法 (BPTT: Back-Propagation





Fig. 11 (a) An example of reconstructed density profiles where results by the neural network method (+, *, \square , \bullet) are compared with the previous calculations (x, \square , \circ , Δ) for $t=0.5(+, x)$, $0.6(*, \square)$, $0.7(\bullet, \circ)$, and $0.8(\bullet, \Delta)$. (b) Parameter β of an MHD equilibrium selected as the density contours is shown by the symbol (+) with the experimentally obtained diamagnetic β (*).

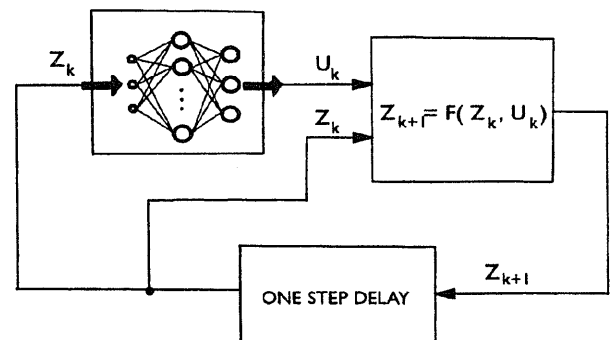


Fig. 12 Neural network-dynamical system configuration used for the feedback stabilization of the thermonuclear reactor model [55].

Through Time)]と呼ばれる学習法でネットワークの学習がなされた。この方法は、基準状態(目的状態: \bar{z}_i)の周辺に P 個の入力パターン (初期条件) $\bar{z}_1^{(p)}$ (密度, ヘリウム濃度, 温度) を選びネットワークのウェイトのセットを固定して最終状態 $\bar{z}_N^{(p)}$ (N ステップ目) までシミュレーションを行う。これが入力パターン $\bar{z}_1^{(p)}$ に対する 1 回の前進計算であるとして, その他の操作は通常の誤差逆伝播学習を行う。注意すべき点は, 最小化すべき目的関数 ($\bar{u}_k = N(\bar{z}_k)$) が制御変数を直接には含んでいないことである。しかし, ダイナミカルシステムのシミュレーションを行う時には $\bar{z}_N^{(p)}$ は差分式を通じてと結びついている。したがって, これも残差最小化学習の特別な場合であると考えられる。計算の結果, 各プラズマ状態量の稼働目標値から 10~20%異なる値を初期条件として設定してシミュレーションを行ったところ目標値に収束し安定に運転が続けられることを確認した。

4. まとめ

プラズマ・核融合研究開発分野で行われているニューラルネットワークの利用について概観した。ニューラルネットワークの応用に関する論文はトカマク等のトロイダル装置のプラズマに関するものが大部分であるのは, 研究者や装置の数が多いためであろう。しかし, 多くの応用は他の種類の装置のプラズマについても同様に適用可能である。主として, 計測データの解析に関するものについて記述したが, 安定な運転制御を目指すための応用も多く行われている。また, ニューラルネットワークについても, シグモイド関数型の滑らかな活性化関数を使った多層ニューラルネットワークの応用の解説に限定した。これは, 実際の応用が多層ニューラルネットワークに集中しているためでもある。しかし, 他の種類のネットワークの応用もいろいろと考えられる。ここで述べなかったような応用もいろいろとなされている。たとえば, Allen, Bishop によるエネルギー閉じ込め比例則の表現はニューラルネットワークによる統計的関数当てはめの例である [56]。また, Tribaldos, van Milligen による数値平衡解の解析関数化は安定性解析などに有効に使えらる [57]。

参考文献

- [1] R. Beale and T. Jackson, *Neural Computing: An Introduction* (IOP Publishing, Bristol, 1990).
- [2] C.M. Bishop, *Rev. Sci. Instrum.* **65**, 1803 (1994).
- [3] R. Rojas, *Neural Network: A Systematic Introduction* (Springer, Berlin, 1996).
- [4] K. Swingler, *Applying Neural Networks: A Practical Guide* (Academic Press, London, 1996).
- [5] W.S. McCulloch and W. Pitts, *Bull. Math. Biophysics* **5**, 115 (1943).
- [6] F. Rosenblatt, *Psychological Rev.* **65**, 386 (1958).
- [7] M. Minsky and S. Papert, *Perceptron — An Introduction to Computational Geometry* (The MIT Press, Cambridge, 1969).
- [8] S. Amari, *IEEE Trans. Electron. Comput.* **EC-16**, 279 (1967).
- [9] D.E. Rummelhart, G.E. Hinton and R.J. Williams, *Nature (London)* **323**, 533 (1986).
- [10] K. Funahashi, *Neural Networks* **2**, 183 (1989).
- [11] K. Hornik, M. Stimchombe and H. White, *Neural Networks* **2**, 359 (1989).
- [12] G. Cybenko, *Math. Control Signal Syst.* **2**, 303 (1989).
- [13] A.S. Weigend, B.A. Huberman and D.E. Rummelhart, *Predicting Sunspots and Exchange Rates with Connectionists Networks, Nonlinear Modeling and Forecasting, SFI Studies in the Sciences and Complexity, Proc. Vol.XII*, Eds. M. Casdagli, S. Eubank (Addison-Wesley, Boston, 1992) p.395.
- [14] B.Ph. van Milligen, V. Tribaldos and J.A. Jimenez, *Phys. Rev. Lett.* **75**, 3594 (1995).
- [15] I.E. Lagaris, A. Likas, D. I. Fotiadis, *IEEE Trans. Neural Netw.* **9**, 987 (1998).
- [16] X.F. Ma, M. Fukuhara, T. Takeda, *Nucl. Instrum. Methods Phys. Res. A* **449**, 366 (2000).
- [17] 馬笑峰, 竹田辰興: 日本応用数理学会論文誌 (Trans. JSIAM) **10**, 145 (2000).
- [18] X.F. Ma and T. Takeda, Asymmetric Abel inversion by neural network for reconstruction of plasma density distribution, *Nucl. Instrum. Methods Phys. Res. A*, to be published.
- [19] X.F. Ma, M. Fukuhara and T. Takeda, K. Tanaka, K. Kawahata, T. Tokuzawa and S. Okajima, Reconstruction of plasma density distribution by neural network from interferometric data, *Plasma Phys. Control. Fusion*, submitted.
- [20] A. Liaqat, M. Fukuhara and T. Takeda, *Comput. Phys. Commun.* **141**, 350 (2001).
- [21] A. Liaqat, M. Fukuhara and T. Takeda, Optimal estimation of parameters of dynamical systems by neural network collocation method, *Comput. Phys. Commun.* to be published.
- [22] A. Liaqat, M. Fukuhara and T. Takeda, Applying neural network collocation method to an incompletely known dynamical system via weak constraint data assimilation, *Mon. Weather Rev.* submitted.

- [23] C. Bishop, *Rev. Sci. Instrum.* **63**, 4772 (1992).
- [24] C.M. Bishop and C.M. Roach, *Rev. Sci. Instrum.* **63**, 4450 (1992).
- [25] C.M. Bishop, C.M. Roach and M.G. von Hellermann, *Plasma Phys. Control. Fusion* **35**, 765 (1993).
- [26] D.R. Baker, R.J. Groebner and K.H. Burrell, *Plasma Phys. Control. Fusion* **36**, 109 (1994).
- [27] J. Svensson, M.G. von Hellermann and R.W.T. König, *Plasma Phys. Control. Fusion* **41**, 315 (1999).
- [28] L. Lagin, D. Manos, M. Diesso, *Bulletin of the American Physical Society, Division of Plasma Physics Thirty-Third Annual Meeting*, (1991) Vol.36 (9), 7T13.
- [29] J.B. Lister and H. Schnurrenberger, *Nucl. Fusion* **31**, 1291 (1991).
- [30] L. Lagin, R. Bell, S. Davis, T. Eck, S. Jardin, C. Kessel, J. McEnerney, M. Okabayashi, J. Popyack and N. Sauthoff, *Proceedings of the 17th Symposium on Fusion Technology*, Rome (1993) Vol.2, p.1057.
- [31] E. Coccorese, C. Morabito and R. Martone, *Nucl. Fusion* **34**, 1349 (1994).
- [32] R. Yoshino, J.K. Koga and T. Takeda, *Fusion Technol.* **30**, 237 (1996).
- [33] R. Albanese, E. Coccorese, O. Gruber, R. Martone, P. McCarthy and F.C. Morabito, *Fusion Technol.* **30**, 219 (1996).
- [34] T. Wijnands, F. Parlange, B. Couturier and D. Moulin, *Nucl. Fusion* **36**, 1405 (1996).
- [35] 彌政敦洋, 竹田辰興, 中村一男, 伊藤智之: プラズマ・核融合学会誌 **76**, 911 (2000).
- [36] 彌政敦洋, 竹田辰興, 中村一男, 伊藤智之: プラズマ・核融合学会誌 **77**, 171 (2001).
- [37] Y.-M. Jeon, Y.-S. Na, M.-R. Kim and Y.S. Hwang, *Rev. Sci. Instrum.* **72**, 513 (2001).
- [38] Y.-S. Na, Y.-M. Jeon, S.H. Hong and Y.S. Hwang, *Rev. Sci. Instrum.* **72**, 1400 (2001).
- [39] D. Wroblewski, *Rev. Sci. Instrum.* **68**, 1281 (1997).
- [40] J.V. Hernandez, A. Vannucci, T. Yajima, Z. Lin, W. Horton and S.C. McCool, *Nucl. Fusion* **36**, 1009 (1996).
- [41] A. Vannucci, K.A. Oliveira and T. Tajima, *Nucl. Fusion* **39**, 255 (1999).
- [42] A. Sengupta and P. Ranjan, *Nucl. Fusion* **40**, 1993 (2000).
- [43] D. Wroblewski, G.L. Jahns and J.A. Leuer, *Nucl. Fusion* **37**, 725 (1997).
- [44] A. Sengupta and P. Ranjan, *Nucl. Fusion* **41**, 487 (2001).
- [45] G. Pautasso, S. Egorov, Ch. Tichmann, J.C. Fuchs, A. Herrmann, M. Marascheck, F. Mast, V. Mertens, I. Perchermeier, C.G. Windsor and T. Zehetbauer, *J. Nucl. Mater.* **290-293**, 1045 (2001).
- [46] Th. Zehetbauer, G. Pautasso, C. Tichmann, S. Egorov, A. Lorenz, V. Mertens, G. Neu, G. Raupp, W. Treutterer and D. Zasche, *Fusion Eng. Des.* **56-57**, 721 (2001).
- [47] G. Demeter, *Rev. Sci. Instrum.* **68**, 1438 (1997).
- [48] J. Santos, F. Nunes, M. Manso and I. Nunes, *Rev. Sci. Instrum.* **70**, 521 (1999).
- [49] J. Santos, F. Nunes, M. Manso and P. Varela, *Fusion Eng. Des.* **48**, 119 (2000).
- [50] F.D. Nunes, J. Santos and M.E. Manso, *Rev. Sci. Instrum.* **70**, 1047 (1999).
- [51] J.R. Ferron, A. Kellman, E. McKee, T. Osborne, P. Petrach, T.S. Taylor, J. Wight and E. Lazarus, *Proc. of the 14th IEEE/NPSS Symposium on Fusion Engineering*, San Diego, California (Institute of Electrical and Electronics Engineers, Inc., Piscataway, 1992) (1992) Vol. 2, p.761.
- [52] L. Lagin, *Proc. of the 14th IEEE/NPSS Symposium on Fusion Engineering*, San Diego, California (Institute of Electrical and Electronics Engineers, Inc., Piscataway, 1992) (1992) Vol. 2, 824.
- [53] C. M. Bishop, P. S. Haines, M.E.U. Smith, T.N. Todd and D.L. Trotman, *Neural Comput.* **7**, 206 (1995).
- [54] C.G. Windsor, T.N. Todd, D.L. Trotman and M.E.U. Smith, *Fusion Technol.* **32**, 416 (1997).
- [55] J.E. Vitela and J.J. Martinell, *Plasma Phys. Control. Fusion* **40**, 295 (1998).
- [56] L. Allen and C.M. Bishop, *Plasma Phys. Control. Fusion* **34**, 1291 (1992).
- [57] V. Tribaldos and B.Ph. van Milligen, *Rev. Sci. Instrum.* **68**, 931 (1997).



たけだ たつおき
竹田辰興

経歴：1963年東京大学理学部物理学科卒業，1968年東京大学大学院博士課程終了（理学博士），1969～1994年日本原子力研究所（核融合研究に従事），1994年～現在電気通信大学情報工学科（その間，九州大学，日本原子力研究所計算科学技術推進センター併任）。研究分野：現在はニューラルネットワークの計算科学への応用を主に研究している。趣味：写真撮影，クラシックカメラ，篆刻その他。



いよ まさあつひろ
彌政敦洋

2001年九州大学大学院総合理工学研究科博士課程修了。現在は九州大学応用力学研究所炉心理工学研究センターの技術補佐員。主な研究分野はニューラルネットワークのトカマクプラズマへの応用。なかなか信じてもらえないが趣味は音楽鑑賞および楽器演奏（オーケストラ），その他にはテニスなど体を動かすことも。