

修士論文

温度情報に基づく
ニューラルネットワークを用いた
熱変形補償に関する研究

平成 15 年 1 月 30 日提出

指導教官 長尾 高明 教授

1055035

上條 敬一郎

目次

1	序論	4
1.1	研究の背景	5
1.2	従来の研究	5
1.3	研究の目的	6
1.4	論文の概要	6
2	マシニングセンタの構成と計測機器	7
2.1	加工知能化の基本概念	8
2.2	マシニングセンタにおける熱変形能動補償の意義	9
3	ニューラルネットワーク	18
3.1	ニューラルネットワークを用いた制御	19
3.1.1	ニューラルネットワークの理論	19
3.1.2	ジェネティックアルゴリズムによる学習	28
3.1.3	ニューラルネットワークとジェネティックアルゴリズムの融合	33
3.2	マシニングセンタ熱変形補正制御への適用	35
4	学習実験	37
4.1	ニューラルネットワークの学習及び評価	38
4.1.1	測定方法	38
4.2	学習方法	40
4.3	学習結果の評価	42
5	考察と展望	48
5.1	主軸変位予測についての考察	49
5.2	今後の展望	51
6	結論	52
	参考文献	54
	謝辞	55
	付録	56

第 1 章

序論

1.1 研究の背景

未だ続く不況の中、製造業各社は省コスト、省労力に励んでいる。それに伴い、工場の生産ラインの無人化、自動化が進んでいる。そうした省力化、自動化の実現を目指す上で工作機械の高精度化、高信頼性が求められている。そうした要求に応えるには、機械自体が高精度化、高信頼化を行う必要がある。そのためには、基本となる機械構造の高精度化、高剛性化を図るとともに、加工精度低下の主な要因である切削力、熱による影響に対応可能なシステムの構築が重要である。

工作機械における高精度化や高信頼化を実現するために、熱変形を抑制することの重要性は従来からよく認識されている。しかし、実際は熟練者が経験に基づいて補正する、機械を空運転によって熱変形が安定するのを待ってから使用するといった方法が取られている。より能動的な方法として、加工中に発生した熱を抑える方法が上げられる。しかし、これによってすべての熱を抑えることは不可能である。また、熱や加工反力による変形を抑制するといった手段も講じられているが、熱伝播、熱膨張をまったくなくすることが出来ない限り解決にはならない。

以上のように精度の低下の原因となる発熱に関して、根本的な解決策を見つけ出すのは極めて困難な問題である。しかし、省力化、自動化の流れの中での機械の高精度化は実現されなければならない問題である。そこで機械自身、熟練者が行うような補正をすることが出来れば精度の向上が望めるであろうと考えられる。

1.2 従来の研究

工作機械における高精度や高信頼性を実現するために、熱変形を抑制することの重要性は上でも述べたとおりだが、それに伴いこれまでも数多くの研究がなされている。熱変形への対策は大きく2つに分けることができる。ひとつは、熱変形を何らかの形で抑制する方法。もうひとつは、熱変形を容認し、計測または予測して補償する方法である。

前者として、熱変形の発生する場所、大きさ、原因を調べる研究、また、その熱変形を抑制するように、高剛性化、加熱法や熱変形補償形構造、熱伝導の小さい材料(コンクリートやセラミックス)や線膨張率の小さい材料(低熱膨張鉄材など)を用いる方法、ヒートパイプを用いる方法などが試みられている。

後者には、レーザーで熱変形を外部から測定する研究、代表点などの温度を計測し、物理モデルによって熱変形を予測する試みなどがある。

1.3 研究の目的

本研究の目的は、温度環境を変化させ、マシニングセンタの熱変形によって生じる主軸の傾き及び変位をジェネティックアルゴリズムとバックプロパゲーションを併用して構築したニューラルネットワークによって予測する。また、予測誤差を小さくするような予測方法の改善策を考える。

最終的には、熱変形による加工誤差を自ら補償することのできるマシニングセンタの開発を目標とする。

1.4 本論文の概要

本論文は全 6 章から構成される。

第 1 章では、研究の背景及び目的について述べる。

第 2 章では、本研究で使用するマシニングセンタの開発並びにその研究の根本的思想となっている加工の知能化の概念やマシニングセンタの構成と実験などに使用した機器の説明をしている。

第 3 章では、予測モデルとして採用したニューラルネットワークとジェネティックアルゴリズムの理論について述べる。

第 4 章では、マシニングセンタの熱的挙動の予測モデルを構築するための学習実験を行った。

第 5 章では、4 章で行った学習実験の考察をし、今後の展望について考えた。

第 6 章では、本論文の結論を述べ本研究のまとめとする。

第 2 章

マシニングセンタの構成と計測機器

2.1 加工知能化の基礎概念

加工というのは、提示された寸法で正確かつ効率よく作り出すことを目的にしている。しかし、正確に効率良く加工することはとても困難である。




図 2.1 加工中に生じる物理現象

考えられる加工誤差の原因として、図 2.1 に示すような加工中に生じる様々な物理現象がある。マシニングセンタはもちろんのこと工作機械はこれらの現象によって、力と熱で変形し、また、歪み、音、温度などで高精度加工ができない。そこで、私たちは加

工精度低下の原因となる情報をセンサによって取り込み、機械の設定数値とセンサで得た数値とのずれを把握し、ファン、アクチュエータでずれを修正すれば正確な製品を作り出すことが可能になるであろうと考える。また、マシニングセンタとコンピュータを繋げることにより、センサで得たデータや熱アクチュエータの動作内容、加工状態を把握し、それに基づいて内部モデルを修正することで、機械自体が学習し「加工の知能化」を実現しようとしている。その基本構成を図 2.2 に示す。

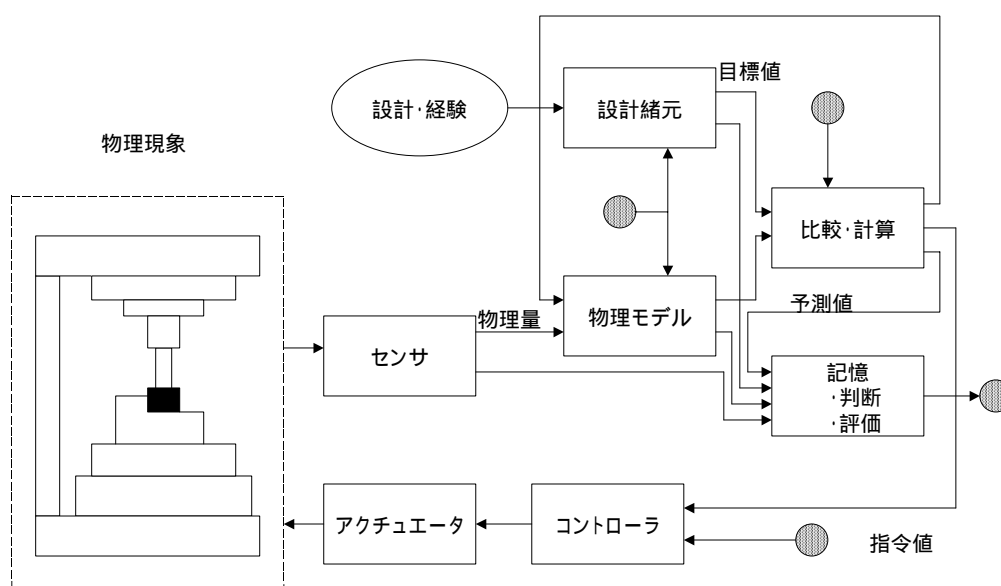


図 2.2 加工知能化の基本構成

2.2 マシニングセンタにおける熱変形能動補償の意義

これまでに述べたように様々な物理現象が加工中に生じ加工誤差を生み出しているが、特に加工反力や熱による変形がマシニングセンタの加工精度を一番低下させている。

加工反力による変形を補うために、工作機械本体の剛性を高めることで、変形を抑えるという方法がとられてきたが、材料の剛性にも限界があり、コストがかかることから、解決には至っていない。

もう一つの原因である熱による変形については、熱を発生する部分を冷やす、発熱部からの伝熱を防ぐといった対策が行われてきた。また、室温変化による変位を防止する為に、室温を一定に保つ（室温を一定に保つだけで、20～30 ミクロンの変形を防ぐこと

ができる。)こともされてきた。しかし、主軸モータや、加工中の工具と工作物からの発熱、工場の室温といった全ての熱を取り除くことは不可能である。

また、マシニングセンタのような多くの部品と複雑な構造で構成される物の加工反力による変形と熱変形を具体的に解析、モデル化することは非常に困難である。モデル化による熱変形補正は複雑な熱変形を十分に補うことは難しい。

そこで本研究では、「加工の知能化」を実現するため熱電対を用い、マシニングセンタの各部の温度を測定し、その情報を基に温度変化による変形を予測することを試みていく。

2.3 マシニングセンタの構成

2.3.1 マシニングセンタ

図 2.3 に本研究に用いたマシニングセンタの外観を示す。



図 2.3 マシニングセンタ

このマシニングセンタは、大阪機工株式会社(OKK)社製の VM4 という汎用マシニングセンタで、コラム下部に熱アクチュエータが装備されており、熱変形に対してアクティブな補正が可能である。

2.3.2 熱アクチュエータ

本研究に用いているような 3 軸のマシニングセンタでは、構造体の変形による主軸位置変位のうち並進方向の変化については座標系の原点をずらすことで $1\ \mu\text{m}$ 刻みでの補正が可能であるが、主軸の傾きについては NC 機能では補正できない。そのために、マシニングセンタのコラム下部に配置された熱アクチュエータで能動的にコラムを変形させることによって主軸の傾きを制御する。

熱アクチュエータは加熱用の面状発熱体を 16 枚、冷却用のファンを 14 個ずつ配置されている。加熱用の面状発熱体は坂口伝熱製のサミコン 230SR の $100\text{V}140\text{W}70\times 100\text{mm}$ を主軸側に 4 枚、その他の場所には $100\text{V}200\text{W}100\times 200\text{mm}$ を 4 枚ずつ 12 枚用いている。冷却ファンについては、オリエンタルモータ製の MS14-DC を主軸側に 2 個、MU825S-43 を背面に 4 個、MU925S-41 を側面に 4 個ずつそれぞれコラムに取り付けられたフィンに搭載している。図 2.4 に熱アクチュエータの外観を示す。




図 2.4 熱アクチュエータ

これらの熱アクチュエータを加熱、冷却することで図に示すように構造体を変形させることが可能になる。この変形によって、主軸の傾きを変化させることで熱変形による主軸の傾きの変化を打ち消すことができる。




図 2.5 熱アクチュエータの変形モード

2.4 計測機器

以下に本研究に用いた計測機器の仕様を示す。

レーザー測長器

レーザー測長器を使って主軸位置を計測した。測定方法は次項以降で説明する。外観を図 2.5 から 2.7 に、仕様を表 2.3 に示す。



図 2.5 レーザー測長器

表 2.3 レーザー測長器の仕様

型番	(株)東京精密製 DISTAX L-IM-20B
最大測定範囲	10m
分解能	10nm
最大応答速度	630mm/sec
精度	$\pm (L \times 10^{-7} + 0.01 \times 10^{-6}) \text{ m}$ L=測定長さ
タイプ	ヘリウム - ネオン、連続波
最大ビームパワー	350mW
公称波長	633nm
消費電力	75VA



図 2.6 レーザーヘッド



図 2.7 コーナーキューブミラー

多点集計装置（データロガー）

熱電対からの出力を集計するために図 2.7 に示す多点集計装置（以下データロガー）を用いた。合計 16 チャンネルの入力が可能である。このデータロガーは USB と PC カードを介して外部コンピュータと通信を行うことができる。データロガーの仕様を表 2.4 に示す。



図 2.7 データロガー

表 2.4 データロガーの仕様

型式	(株)キーエンス NR-1000
熱電対入力	K 熱電対： - 200 ~ 1300
入力インピーダンス	1M 以上
精度	K 熱電対： $\pm (0.05\% \text{ of rdg} + 1)$
分解能	16bit
サンプリング周期	0.1sec ~ 24h
時間軸精度	$\pm 100\text{ppm}$
使用周囲温度	0 ~ + 50
使用周囲湿度	20 ~ 85%RH(結露しないこと)
ウォームアップ時間	データ収集後 30 分

熱電対

マシニングセンタの温度の計測にフォーク端子取り付けタイプの熱電対を用いた。合計 11 箇所の温度を測定しデータロガーでデータを収集した。外観を図 2.8 に仕様を表 2.5 に示す。




図 2.8 熱電対

表 2.5 熱電対の仕様

型式	八光商事株式会社 HT-150
被覆熱電対種類	ガラス編組被覆 0.65 単線
測温接点	接地形（非接地にして用いた）
常用限度	200
長さ	3m

第 3 章

ニューラルネットワーク

3.1 ニューラルネットワークを用いた制御

3.1.1 ニューラルネットワークの理論

ニューラルネットワークの概要

ニューラルネットワークは、生物の神経回路における神経細胞（ニューロン）をモデル化することにより実現された。図.1 に示す神経細胞（ニューロン）は、樹状突起からの入力の結果、興奮すると出力側の軸索に電気パルス列を送り出すが、モデル化する際には受け取った刺激の総和が細胞ごとに決められたスレッシュホールドを越えると興奮し、スレッシュホールド以下だと興奮しないとされた。このような神経細胞と神経細胞同士を結ぶシナプスから神経回路網（ニューラルネットワーク）が構築される。

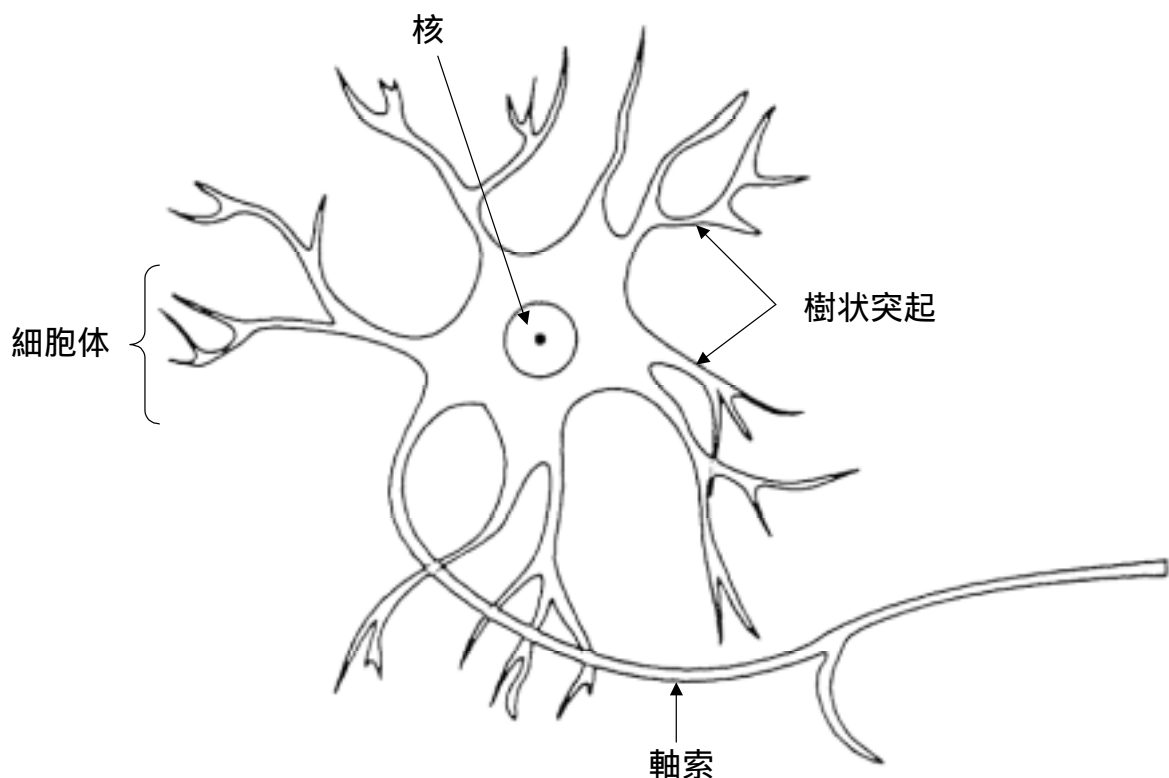


図 3.1 神経細胞の形状

ニューラルネットワークの主な特徴として、学習能力（自己組織化）、非線形対象への適応、があげられる。

学習機能（自己組織化能力） 通常、計算機である問題を解こうとする場合、その入力と出力との関係をプログラマが定義してプログラムを書かなければならない。しかし、ニューラルネットワークでは、教師信号をネットワークに与えてやれば、ネットワーク自身が自己の構造を変えていき入力に対して正しい出力を行うネットワークを作り上げる。

非線形対象への適応 ニューラルネットワークでは、入力の荷重和に簡単な非線形演算を施したものが出力になるモデルがよく用いられている。このときノード間の結合の強さを基にネットワークが構成され、シグモイド関数を用いることにより非線形なモデルも対象とすることができる。

パーセプトロン

ニューロンモデル 神経細胞（ニューロン）をモデル化すると、図 3.2 に示す線形閾値素子モデルのように表される。




図 3.2 線形閾値モデル

このモデルでは、入力 x_i ($i = 1, \dots, n$) に結合の強さ w_i ($i = 1, \dots, n$) をかけた値の総和が閾値を越えていれば出力 y は 1、越えていなければ 0 となる。これを式で表すと、

$$u = \sum_{i=1}^n w_i x_i - \theta \quad (3.1)$$

$$y = f(u) = 1(u) = \begin{cases} 0 & (u \leq 0) \\ 1 & (u > 0) \end{cases} \quad (3.2)$$

ここで、 $1(u)$ は単位ステップ関数である。

線形モデルでは、以上のように出力 y には 1 か 0 の 2 値を用いればよいが、非線形モデルを扱う場合などでは、出力が連続的な値をとる場合も考えられる。この連続値モデルを表すものである出力関数 $f(u)$ にはシグモイド関数(式(3.3))がよく用いられる(図 3.3)。

$$f(u) = \frac{1}{1 + \exp(-u)} \quad (3.3)$$




図 3.3 シグモイド関数

単純パーセプトロン パーセプトロンとは、Rosenblatt がパターン認識を目的として提案したネットワークモデルである。Rosenblatt の定義によれば、パーセプトロンは感覚ユニット(Sユニット、sensory unit)、連合ユニット(Aユニット、association unit)、反応ユニット(Rユニット、response unit)からなる可変の結合荷重を持つネットワークモデルである。このようなモデルの内、以下の5条件を満足するものを単純パーセプトロンという(図3.4)。

- 1、反応ユニットが1個で、すべての連合ユニットと結合している。
- 2、結合は、感覚ユニットから連合ユニットへ、連合ユニットは反応ユニットへと一方向である。
- 3、感覚ユニットから連合ユニットへの結合荷重は固定である。
- 4、各結合の伝送時間帯は零である。
- 5、感覚ユニット、連合ユニット、反応ユニットは、 $y = g(x)$ なる出力関数を持つ。ここで、 x はユニットへの入力の代数和、 y はユニットの出力値である。




図 3.4 単純パーセプトロン

さらに、連合ユニット、反応ユニットの出力関数が閾値関数である単純パーセプトロンを基本パーセプトロンという。

さて、2つのクラスへのパターン分類を考えた場合、前節の線形閾値素子モデルでは、パターンを識別するということは、 $X = \{x_1, x_2, \dots, x_n\}$ の張るパターン空間上を

$\sum_{i=1}^n w_i x_i - \theta = 0$ で表される超平面が2つに分割することを意味する。

しかし、現実には、このような超平面で2つに分割できる“線形分離可能”な問題は少なく、たとえば排他的論理和問題のように“線形分離可能”でない問題がほとんどである。

このような問題に対して、パーセプトロンは、S空間で“線形分離可能”なパターン分類問題をRユニットで正しく識別するには、A空間を正しく分割する超平面を決める必要がある。Aユニットの出力を $Y = \{y_1, y_2, \dots, y_m\}$ 、A-R間の結合荷重を $W = \{w_1, w_2, \dots, w_3\}$ 、Rユニットの閾値を θ とするとパターンを分類する超平面は、

$$W \cdot Y - \theta = 0 \quad (3.4)$$

と表せる。

これは、 $y_{n+1}=1, w_{n+1}=-\theta$ になる+1次元の空間を考えると、

$$W \cdot Y = 0 \quad (3.5)$$

と同値である。

以上より、Rユニットの出力を z とすると、

$$z = \begin{cases} 0 & (W \cdot Y \leq 0) \\ 1 & (W \cdot Y > 0) \end{cases} \quad (3.6)$$

と表せる。

パーセプトロンの学習則でもっとも一般的なものは、入力パターンが与えられる毎に閾値を含む各結合荷重を

$$\Delta W = -\varepsilon(z - \hat{z})Y \quad (\varepsilon > 0) \quad (3.7)$$

だけ変化させるというものである。

ここで、 \hat{z} は教師信号を表し、パーセプトロンが1を出すべきところは1が、0を出すべきところは0が与えられるとする。また、 ε は0に近い正の整数とする。

この式は、パーセプトロンが誤った出力を出したときだけ各結合荷重が修正されることを意味している。この学習則を用いれば、パーセプトロンは有限回の学習で正しい識別をする、すなわち、望ましい超平面でパターン空間を分割することがパーセプトロンの収束定理によって証明されている。

誤差逆伝播法

単純パーセプトロンでは、S-A間の結合荷重がランダムに固定されているので複雑なパターン分離問題を行うには膨大な数のAユニットが必要となり現実的ではない。そこで、Rumelhartらによって提案された学習方法がバックプロパゲーション（誤差伝播法）である。この方法はパーセプトロンでは固定していたS-A間の結合荷重も学習によって修正していくものである。

一般化デルタルール パーセプトロンではパターン分類問題は入力ベクトルに対して1か0を対応させる写像を決定する問題と考えられる。もし、入力ベクトルの要素が1か0であるならばパターン分類問題はある論理関数を作る問題となるわけである。これを一般化すると、入力ベクトルに対して要素がスカラ値である出力ベクトルを対応させる写像を作る問題となる。このような写像を作り上げるための学習則をパーセプトロンの学習則の一般化によって求める。

スカラ値を出力するため、出力関数に閾値関数は使えない。そこで、出力関数としてシグモイド関数（式(3.3)）を用いることにする。入力ベクトルを $x=\{x_i\}$ 、出力ベクトルを $y=\{y_j\}$ 、結合荷重を $W=\{w_{ji}\}$ とすると、

$$u_j = \sum_i w_{ji} x_i \quad (3.8)$$

$$y_j = f(u_j) \quad (3.9)$$

という関係にある。ただし、閾値は入力に対する結合荷重とした。

さて、ある入力パターン c に対して望ましい出力を $\hat{y}_{j,c}$ 、実際の出力を $y_{j,c}$ としたとき、学習の評価として、誤差関数（評価関数） E を考える。

$$E = \frac{1}{2} \sum_{j,c} (y_{j,c} - \hat{y}_{j,c})^2 \quad (3.10)$$

$y_{j,c}$ はそのときの結合荷重 w_{ji} によって決まるので、誤差関数も結合荷重によって決定する関数であるといえる。したがって、各結合荷重を軸とする空間において、誤差関数 E は超曲面を与える。任意の結合荷重からこの“誤差曲面”の極小値に達するには、各結合荷重を

$$\Delta w_{ji} = -\varepsilon \frac{\partial E}{\partial w_{ji}} \quad (\varepsilon > 0) \quad (3.11)$$

ずつ修正していけばよい。これは、誤差曲面上をもっとも急な傾斜方向に進んでいくことに相当し、このような極値探索法を最急降下法という。

さて、式(3.8)、(3.9)のように定義されているので、式(3.11)は合成関数の微分公式により、

$$\frac{\partial E}{\partial w_{ji}} = \sum_c \frac{\partial E}{\partial y_{j,i}} \cdot \frac{\partial y_{j,i}}{\partial u_{j,i}} \cdot \frac{\partial u_{j,i}}{\partial w_{ji}} \quad (3.12)$$

と展開できる。

式(3.8)、(3.9)より、

$$\frac{dy_j}{du_j} = f'(u_j) \quad (3.13)$$

$$\frac{du_j}{dw_j} = x_i \quad (3.14)$$

であるので、式(3.11)は、

$$\Delta w_{ji} = -\varepsilon \sum_c \frac{\partial E}{\partial y_{j,c}} f'(u_{j,c}) y_{j,c} \quad (3.15)$$

となる。

ここで、誤差関数 E は式(3.10)で与えられているので、これを微分することにより、

$$\frac{\partial E}{\partial y_{j,c}} = y_{j,c} - \hat{y}_{j,c} \quad (3.16)$$

が求まり、式(3.15)は、

$$\Delta w_{ji} = -\varepsilon \sum_c (y_{j,c} - \hat{y}_{j,c}) f'(u_{j,c}) x_{i,c} \quad (3.17)$$

となる。これを一般化デルタルールという。

特に、出力関数 f が式(3.3)で与えられるシグモイド関数の場合には、

$$f'(u) = y(1-y) \quad (3.18)$$

となるので、式(3.17)は、

$$\Delta w_{ji} = -\varepsilon \sum_c (y_{j,c} - \hat{y}_{j,c}) y_{j,c} (1 - y_{j,c}) x_{i,c} \quad (3.19)$$

という形になる。

この学習法はすべての入出力パターンが与えられた後で一括して修正が行われるので一括修正法と呼ばれる。一方、

$$\Delta w_{ji} = -\varepsilon (y_j - \hat{y}_j) f'(u_j) x_i \quad (3.20)$$

のように、入出力パターンが与えられるごとに結合荷重を修正する逐次修正法と呼ばれる学習法もある。この学習法において、出力関数 f を

$$f(u) = u \quad (3.21)$$

とするなら、

$$f'(u) = 1 \quad (3.22)$$

$$\Delta w_{ji} = -\varepsilon(y_j - \hat{y}_j)x_i \quad (3.23)$$

となり、前節のパーセプトロンの学習則と同じ形となる。

誤差伝播法 図3.5のようないくつかの中間層を持つ階層型のネットワークを考える。同じ層に属する素子間に結合はなく、どの素子も1つ前の層からのみ入力を受け、次の層へのみ出力を送るものとする。このようなネットワークの中間層に対して、出力層と同様に結合荷重の修正量を導こうとしたとき、式(3.15)の $\frac{\partial E}{\partial w_{ji}}$ の値は直接計算できない。そこで中間層における修正量を、出力層での誤差を使って求めるのが誤差逆伝播法(バックプロパゲーション)である。




図 3.5 階層型ネットワーク

ある層の素子 j の出力を y_j 、次の層の素子 k の出力を y_k とすると、

$$\frac{\partial u_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{du_k} \cdot \frac{\partial u_k}{\partial y_j} \quad (3.24)$$

と展開できる。

式(3.8)より、

$$\frac{\partial u_k}{\partial y_j} = w_{kj} \quad (3.25)$$

であるから、式(3.24)は、

$$\frac{\partial u_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} f'(u_k) w_{kj} \quad (3.26)$$

となる。これが誤差逆伝搬法である。

この方法であると、誤差の極小値付近では勾配が非常に緩やかとなり学習速度は遅くなる。しかし、学習定数 ε を大きくすることでこの問題を解決しようとするとも誤差は小さくならず振動してしまう。この問題に対する有効な解決法として、

$$\Delta w_{ji}(t) = -\varepsilon \frac{\partial E}{\partial w_{ji}} + \alpha \Delta w_{ji}(t-1) \quad (0 < \alpha < 1) \quad (3.27)$$

という式で表されるモーメント法がよく用いられている。ただし、 t は学習の回数を表す。

ここで注意しなければならないことは、誤差逆伝搬法は最急降下法によりいかなる結合荷重の初期値からでも誤差が極小となることが保障されているが、式(3.10)で表される誤差曲面には複数の極小値が存在しうるので、必ずしも誤差が最小になるとは限らないということである。

3.1.2 ジェネティックアルゴリズムによる学習

ジェネティックアルゴリズムの理論

ジェネティックアルゴリズムの概念

ジェネティックアルゴリズム(遺伝的アルゴリズム)は、多点情報を利用した確率的探索法の一つである。ニューラルネットワークと同様に実際の生物をモデルとした探索法であるが、ニューラルネットワークがひとつの細胞に着目していたのに対し、遺伝的アルゴリズムは選択淘汰、交叉、突然変異といった生物の進化をモデルにしている。

ジェネティックアルゴリズムでは、探索空間上の探索点を局所的に探索するのではなく、大域的に同時に複数この点を探索する。この各探索点が遺伝子をもつ各個体(individual)として扱われる。各世代はこのような個体の集合であり、各個体には、遺伝情報としての遺伝子の他に環境に対する適応度が与えられる。適応度の低い個体は環境にそぐわないものとして淘汰され、高い適応度を持つ個体だけが生き残る。淘汰された個体数を補うために、高い適応度を持つ個体同士を親とする子孫の個体を生成する。子孫の生成に際して遺伝子の交叉、突然変異といった操作が行われ、次世代へと移行が完了する。このような世代交代を繰り返すことによって最適解を得る。つまり、図 3.7 のような手順になる。

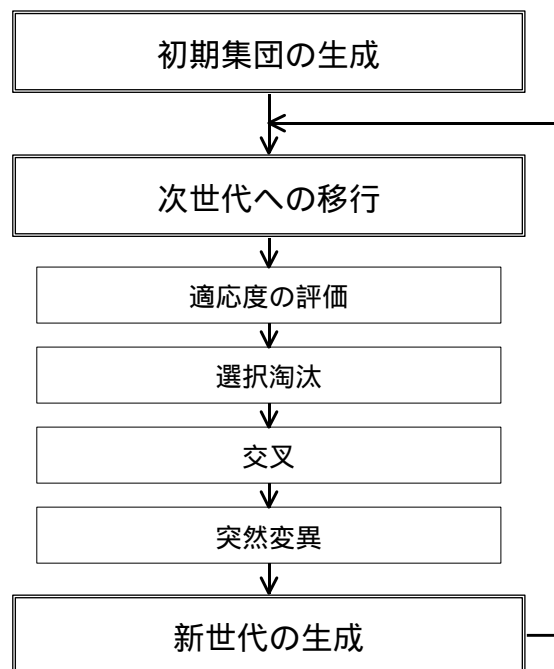


図 3.7 ジェネティックアルゴリズムの処理手順

初期集団の生成

探索を開始するにあたって最初の世代の固体集団を用意しなければならない。この段階では探索空間における適応度の分布がわかっていないので、各個体は探索空間の中にランダムに生成されるのが一般的である。また初期集団の生成時に個体数、染色体の長さや構造が問題に応じて決定されることになる。

適応度の評価

各個体が解としてどの程度問題に適応しているかの評価関数として適応度を設定する。どのような関数を適応度として用いるかは問題によって異なるが、最適解への方向性を正しく与えるようなものでなければならない。

しかし、実際には探索開始直後の世代などにおいて、局所解に陥って高い適応度を示す固体が出現する場合がある。また、何世代も経て解に収束しようとしている世代では固体同士の適応度が似通っていて、遺伝操作を加えても最適解への収束速度が低下する現象が見られる。これらの状況に陥った場合適応度を何らかの関数で処理して適応度の違いを拡大または縮小される操作が必要になる。この操作をスケーリングと呼ぶ。

例えば、各個体 I_i の環境と適応度を $f(I_i)$ に対して、この適応度の値 $f(I_i)$ をある関数 $g()$ に代入して求めた値 $f'(I_i)$ を世代シミュレーションの際に各個体を評価して用いる。

つまり、

$$f'(I_i) = g(f(I_i)) \quad (3.28)$$

関数 $g()$ には、

$$f'(I_i) = a \cdot f(I_i) + b \quad (3.29)$$

のように線形関数を用いる場合や、

$$f'(I_i) = f(I_i)^k \quad \text{ただし } k \text{ は定数} \quad (3.30)$$

のようにべき乗関数を用いる場合がある。

選択淘汰

適応度、あるいはそれにスケーリングを施したものによって、各個体の評価が決定されたので、これに基づいたより環境に適合した次の世代を形成する。具体的には、表価値の低い固体ほど淘汰され消滅する確立が高くなり、表価値の高い固体ほど生き残り、またほかの遺伝子と交配して子孫を残せる可能性が高くなるような操作をする。

ここで、単純に適応度の高い順に生存固体を決めてしまうと、収束性は最も高くなるものの、局所解に陥る可能性も同時に大きくなってしまう。そこで、適応度の低い固体も次世代に生き残ることができるようにすることで、局所解への収束を回避するような淘汰方法として以下のような方法が考えられている。

適応度比例戦略 選択淘汰の操作において一般的なモデルは、各個体の適応度に比例した確立で子孫を残せる可能性を与える適応度比例戦略である。つまりある固体 i が N 個からなる集団の中で次世代の個体として選択される確率 $P(i)$ を適応度の評価関数を $f(k)$ として、

$$P(k) = \frac{f(k)}{\sum_{j=1}^N f(j)/N} \quad (3.31)$$

という式で表す。

期待値戦略 確率的な選択における問題点としては、個体数が少ないときに乱数の揺らぎによって適応度を性格に反映しない選択が生じる可能性があることが挙げられる。この問題を解決するための手法として期待値戦略が挙げられる。期待値戦略では、各個体が残す子孫の期待値を計算する。そしてこの個体を選択された場合には、その期待値から 0.5 を引く。こうすることによって最悪でも期待値より 0.5 の偏差で子孫を残すことが可能になる。

ランク戦略 適応度によって各個体をランク付けし、あらかじめ各ランクに対して決められている確率で子孫を残せるようにする。ただし、この方法では適応度とランクによる選択確率の関係を正しく設定できないと、わざわざ淘汰に操作を加えたために結果が悪化してしまうことになる。

エリート保存戦略 ここまでに挙げた淘汰戦略はいずれも、もっとも高い適応度を持った個体が次世代に選ばれない可能性を持っていた。エリート保存戦略は、集団中でもっとも高い適応度を持った固体は無条件に次世代に生き残れるようにする戦略である。

この方法を用いると、最良の固体が交叉や突然変位によって破壊されることを回避できるという利点がある。ただしその固体の遺伝子が集団中に広まる可能性が大きいので、エリートになった解が局所解だった場合に、集団全体が局所解に陥る危険がある。

この戦略は、他の戦略との組み合わせで用いられる。

トーナメント戦略 トーナメント戦略は集団から決められた数の個体が無作為に抽出し、その中で最も適応度の高い個体を次の世代に残すという処理を必要な個体数になるまで繰り返すものである。

交叉

交叉(crossover)は、淘汰されずに生き残った個体のうち二つを親として選んで、それらの染色体を組替えてこの染色体を生み出す操作である。ジェネティックアルゴリズムでは、この交叉と次に述べる突然変位とによって新しい探索点が作られていくことになるので、どのように交叉を行うかは問題を解く上で非常に重要になる。

単純交叉 最も単純な交叉方法としては交叉する位置をひとつ決めて、その前後で両方の親の遺伝子を入れ替える方法である。この方法を単純交叉、あるいは一点交叉と呼ぶ。(図 3.8)




図 3.8 単純交叉

複数交叉 複数点交叉は交叉位置が複数個設定し、それぞれの点ごとに二つの親の遺伝子を入れ替えていく方法である。(図 3.9)




図 3.9 複数点交叉の例

一様交叉 一様交叉は交叉時にマスクをかけ、それによってどちらの遺伝子を受け継ぐかを決定する交叉方法である。例として、図 3.10 のように二つの個体とマスクを設定する。マスクのビットが 0 のときは子 1 に親 1 の、1 の時には子 1 に親 2 の遺伝子がコピーされるようにして、この遺伝子を決定する。

親1	1	0	0	1	1	0	1
親2	0	0	1	1	0	1	0
マスク	1	0	1	1	0	1	0
子1	0	0	1	1	1	1	1
子2	1	0	0	1	0	0	0

図 3.10 一様交叉

突然変異

突然変異は遺伝子を一定の確率で変化させる操作である。(図 3.11)




図 3.11 突然変異の例

突然変異の起こる確率が大きいと探索はランダムサーチと貸してしまうが、逆に突然変異が全くないと、初期遺伝子の組み合わせ以外の空間を探索することができないため、得られる解に自ら限界ができてしまう。そのため、ある程度の突然変異は必要となる。一般的に突然変異は一定の確率に設定するが、動的に変化させることも可能である。このような手法として適応変異がある。適応変異は、交叉の結果作られた二つの遺伝子の解空間での距離が近いほど変異率を大きくすることによって集団内の遺伝子型の多様性を確保し、広い解空間を探索しようとする手法である。

3.1.3 ニューラルネットワークとジェネティックアルゴリズムの融合

前節までにニューラルネットワークとジェネティックアルゴリズムの理論についてそれぞれ述べたが、両者を比較するとニューラルネットワークは現在点の近傍でよりすぐれた解を探す、いわゆる極所探索を特徴とし、ジェネティックアルゴリズムは探索空間内の複数の探索点について並列的に解を探す大域探索を特徴としている。つまり、この二つの手法は相互補完的な特徴を有していることがわかる。この相互補完性を利用して長所を融合する方法として、

- 1、 ジェネティックアルゴリズムをニューラルネットワークの学習に利用するもの
- 2、 ジェネティックアルゴリズムを用いてニューラルネットワークの構造を決めるもの
- 3、 両者の融合

などが研究されている。

ここでは、最初の方法を採用する。つまり、ジェネティックアルゴリズムによって最適解近傍までの探索を効率よく行い、ある程度最適会の近くまできた後は、極所探索能力に優れるニューラルネットワークで最適解を見つけ出そうという方法である。(図.12)




図 3.12 探索手法の概念図

両者を融合するために、遺伝的捜査の結果生成された各個体をフォワードプロパゲーションシ、教師信号との自乗和誤差の逆数を固体の環境に対する適応度とした。

つまり、自乗誤差和を TTS 、適応度を $Fitness$ とすると、

$$TTS = \sum_{p=0}^m \sum_{i=0}^n (t_{ip} - o_{ip})^2 \quad (3.32)$$

$$Fitness = \frac{1}{TTS} \quad (3.33)$$

ただし、 m を学習に用いるデータセットの数、 n を出力層のノード数、 t_{ip} を p 番目のデータセットにおける i 番目のノードが出力すべき値（教師信号）、 o_{ip} を p 番目のデータセットにおける i 番目のノードが出力した値とする。

3.2 マシニングセンタ熱変形補正制御への適用

マシニングセンタが熱変形する要因としては、主に室温などの環境条件の変化に伴うマシニングセンタの変形、主軸回転によるモータの発熱、加工時の工具とワークの摩擦熱による発熱などが挙げられる。

本研究では、熱電対からの情報を基にニューラルネットワークを用いて、マシニングセンタの主軸の傾きと位置を予測する。X 軸方向への熱変形は、Y 軸方向に比べ小さいと考え、今回は無視する。

主軸の傾きの補正制御

マシニングセンタの熱変形によって、併進方向の変位とともに、主軸の傾きも生じる。本研究で用いるマシニングセンタには、コラム部に熱アクチュエータを備えており、マシニングセンタ本来の熱変形による主軸の傾きを熱アクチュエータでマシニングセンタを熱変形させることによって補正を行う。そのために、熱変形状況を正確に把握して、得られた情報を適切な熱アクチュエータの操作信号に変換する。

本研究に用いるマシニングセンタには 11 箇所熱電対が装備されており、これにより室温や、コラム、主軸周り、の温度を測定し、マシニングセンタの温度変化状況を把握する。その情報を熱アクチュエータの操作信号に変換することにより主軸の傾きの補正を行う。この変換を行うには、熱変形に伴う挙動を性格に理解し、そのモデルを構築することが不可欠である。本研究では、1 軸方向の主軸の傾きと z 方向の主軸変位のみを予測するため、11 箇所の温度測定で十分であると考えた。

この 11 箇所の熱電対からの情報に対して教師信号を与え、ニューラルネットワークを用いて学習を行うことによって、変形情報と主軸の変位を記述する完全なモデルの構築が可能である。具体的には、図.6 に示すように、主軸周りの温度、室温の変化による主軸の傾きの予測用ニューラルネットワークと、熱アクチュエータの温度変化から主軸の傾きを予測し熱アクチュエータの制御量をフィードバックするためのニューラルネットワークとの 2 つで主軸の傾きを予測する。どちらも 3 層のニューラルネットワークを用いている。11 本の熱電対のうち 6 本は主軸周りの温度、室温の変化を、残りの 5 本は熱アクチュエータの温度変化を測定している。そのため入力層には、それぞれの温度情報を取り入れるため 6 次元と 5 次元、中間層は 6 次元と 5 次元、出力層は主軸前後の移動量 2 次元になっている。理想的には、加工を行いながら学習を進めるシステムを構築するべきだが、現段階では、加工しながら教師信号を与えることが不可能であるので、外部の計算機で学習させた後、その結合荷重を用いて補正を行うようにする。

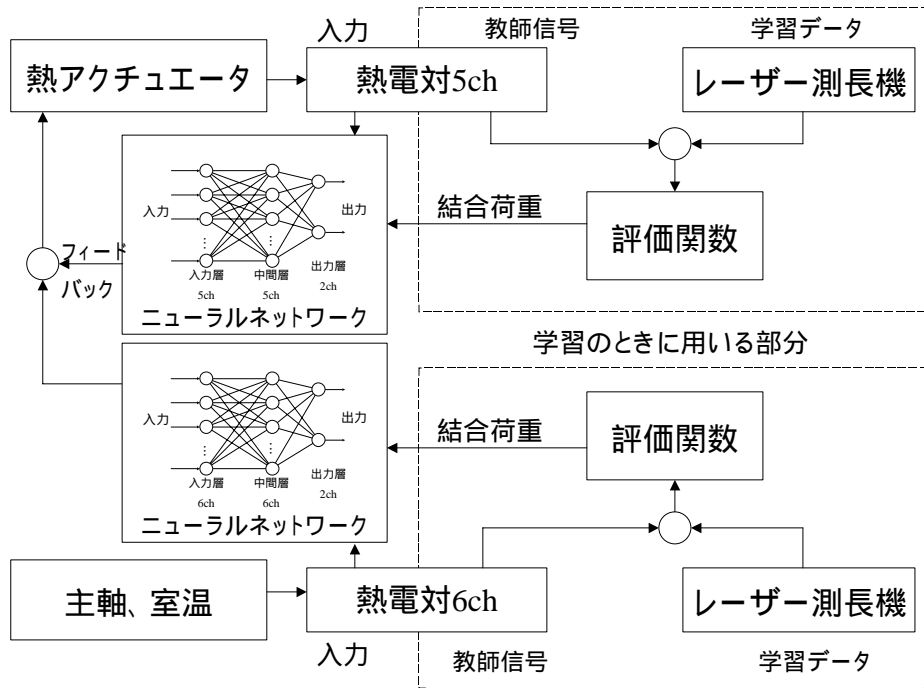


図 3.6 ニューラルネットワークを用いた傾き補正システムの予定概略

第 4 章

学習実験

4.1 ニューラルネットワークの学習及び評価

ニューラルネットワークは、学習によって自己の構造を変更して（自己組織化）、入力に対して正しい出力を行えるようにネットワークを作り上げていく。学習が局所解に陥らずに適切に行われると、そのニューラルネットワークは学習データに対して正しい出力を行うことができ、また、学習データと似たような入力を与えられたときには、学習データと似たような出力を行う。この性質をパターン認識といい、ニューラルネットワークの重要な性質の一つである。このパターン認識と、非線形な系についても記述できるといふ、二つのニューラルネットワークの性質をここでは利用する。

特に本研究では、熱電対（入力に相当）と加工台上のレーザー測長機から主轴との距離（出力に相当）の対応が無限に存在し、そのすべてを学習データとして網羅することは不可能なため、このパターン認識の性質が非常に重要な意味を持つ。

4.1.1 測定方法

温度とレーザー測長機の測定箇所を図 4.1 と図 4.2 に示す。

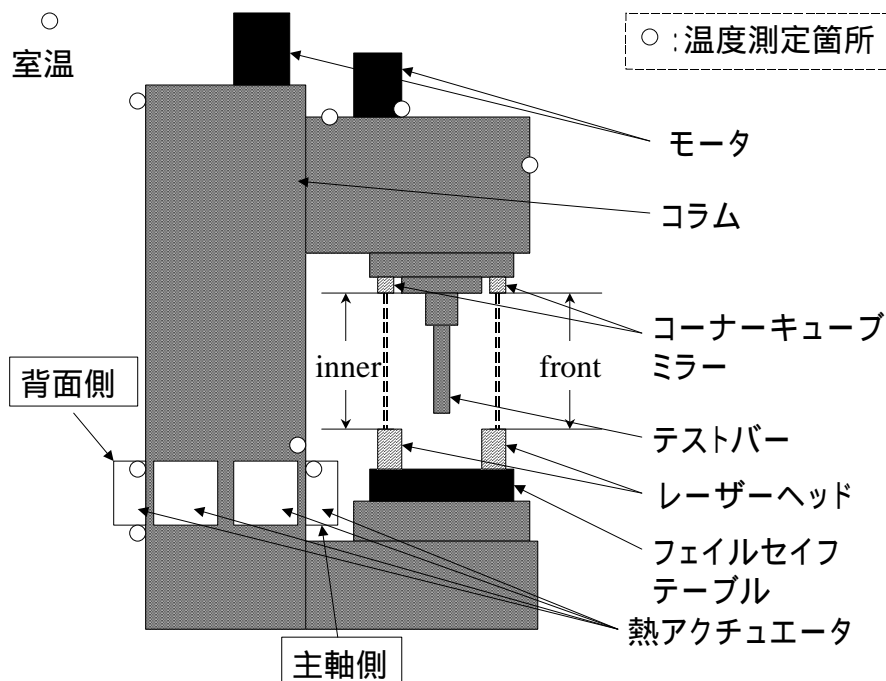


図 4.1 測定箇所

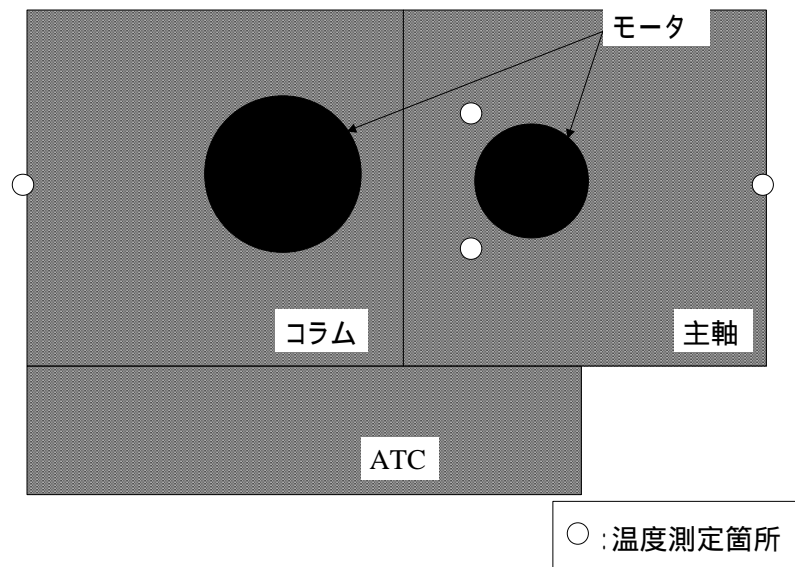


図 4.2 マシニングセンタ上部

加工台から主轴までの距離をレーザー測長機で奥側と手前側（図 4.1 の front と inner）の 2 箇所測定し、そのデータを教師信号データとして用いて結合荷重を求めた。

今回、図 4.1 に示した背面側、主轴側とある 2 つの熱アクチュエータのみを使用した。以後 2 つの熱アクチュエータをそれぞれ、背面側アクチュエータ、主轴側アクチュエータと呼ぶことにする。

熱電対は、熱アクチュエータ部の背面側に 2 箇所、側面の主轴よりに 1 箇所ずつ主轴側に 1 箇所の計 5 箇所と、主轴に 4 箇所、コラム上部に 1 箇所、室温測定用に 1 箇所の合計 11 箇所それぞれの温度を測定している。

学習用の温度、主轴変位測定の概要を図 4.3 に示す。

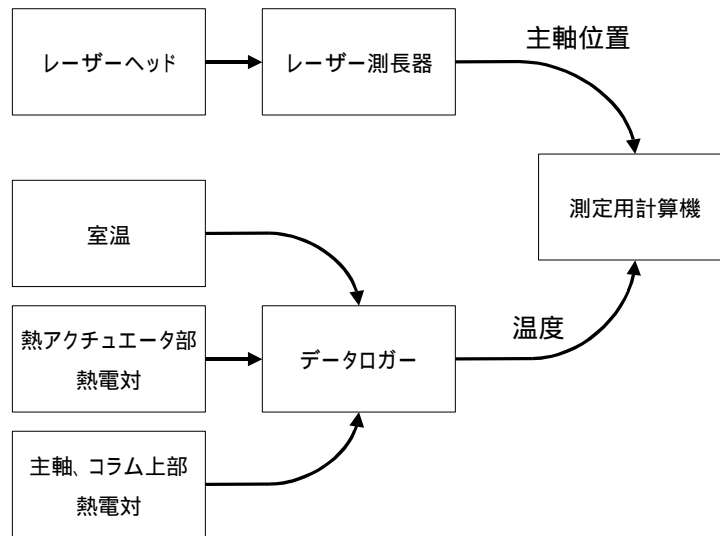


図 4.3 測定装置概要

4.2 学習方法

ここでは 3.2 節で述べたニューラルネットワークの学習を行う。学習データは、電源を切った状態で十分に時間をおき、マシニングセンタ全体がほぼ室温と同じ温度になったところで電源を入れデータを測定する。室温と主軸回転数を表 4.1 のようにそれぞれ変化させた。表 4.1 の設定室温はエアコンの設定温度に設定した温度のことを示す。厳密に室温を制御することはできないが、温度を変化させることが目的であるため、これで十分であると考えた。ただし、表 4.1 の 2,3 の学習実験では主軸を回転させ、ある程度時間を置いた後、室温、主軸回転数を変化させ測定を行った。

アクチュエータを作動させた場合の学習は、主軸がアクチュエータ以外の要因で変位しないよう室温を一定に保ち、主軸を回転させずに表 4.2 のようなパターンで操作した。

以後表 4.1 の学習実験データを R1~3、表 4.2 の学習実験データを A1~4 と呼ぶ事にする。

表 4.1 実験 1 設定温度と主軸回転数

モード	時間(分)	~ 0	~ 30	~ 60	~ 90	~ 120	~ 150	~ 180	
R1	設定室温	25	19		28		25		
	主軸回転数	0							
R2	設定室温	25							
	主軸回転数	1500	1500	3000	1500	3000	1500	3000	
R3	設定室温	25	28		19		28		
	主軸回転数	3000							

表 4.2 実験 2 アクチュエータパターン

モード	時間(分)	0 ~ 20	~ 40	~ 60	~ 80	~ 100	~ 120	~ 140	~ 160
A1	主軸側	-	H	C	-	-	H	C	C
	背面	-	-	-	H	C	C	H	C
A2	主軸側	-	-	-	H	C	C	H	C
	背面	-	H	C	-	-	H	C	C
A3	主軸側	-	-	H	C	C	-	H	C
	背面	-	H	C	-	H	C	-	C
A4	主軸側	-	H	C	-	H	C	-	C
	背面	-	-	H	C	C	-	H	C

(H は加熱、C は冷却を表している)

学習の際、ジェネティックアルゴリズムとバックプロパゲーションとを融合した学習則を用い、効率的な学習を行わせるようにした。

ジェネティックアルゴリズムを用いることによって大域的な探索を行う。まず、個体の設定をしなければならないが、個体の遺伝子は、ニューラルネットワークの各結合荷重を投影したものとする。そのため、各遺伝子の値は 0,1 のビットではなく実数で扱うものとする。個体数は 25、淘汰確率は 0.4 とし、交叉には一様交叉を用いた。選択淘汰をされるか否かは各個体の適応度によって判断される。また、その他のパラメータを表 4.3 と表 4.4 にまとめる。

表 4.3 ニューラルネットワークのパラメータ

	主軸変位予測	アクチュエータ変位予測
入力層	6	5
中間層	6	5
出力層	2	2
染色体数	56	42
シグモイド定数	0.8	5
学習パターン	181	161
初期学習定数	1.0×10^{-6}	1.0×10^{-6}
1 ループでの BP の回数	500	500

表 4.4 ジェネティックアルゴリズムのパラメータ

個体数	25
1 ループでの世代交替数	25
交叉	一様交叉
子孫の突然変異の確率	0.05
淘汰確率	0.4

4.2 学習結果の評価

上記の手法で実際に学習を行ったニューラルネットワークの評価を行う。

方法としては、測定したデータでそれぞれ学習を行い、実験 1 のデータは実験 1 のデータ同士で、実験 2 のデータは実験 2 のデータ同士で学習を行ったデータ以外を未知のデータとして用いて主軸前後の変位をニューラルネットワークで予測した。

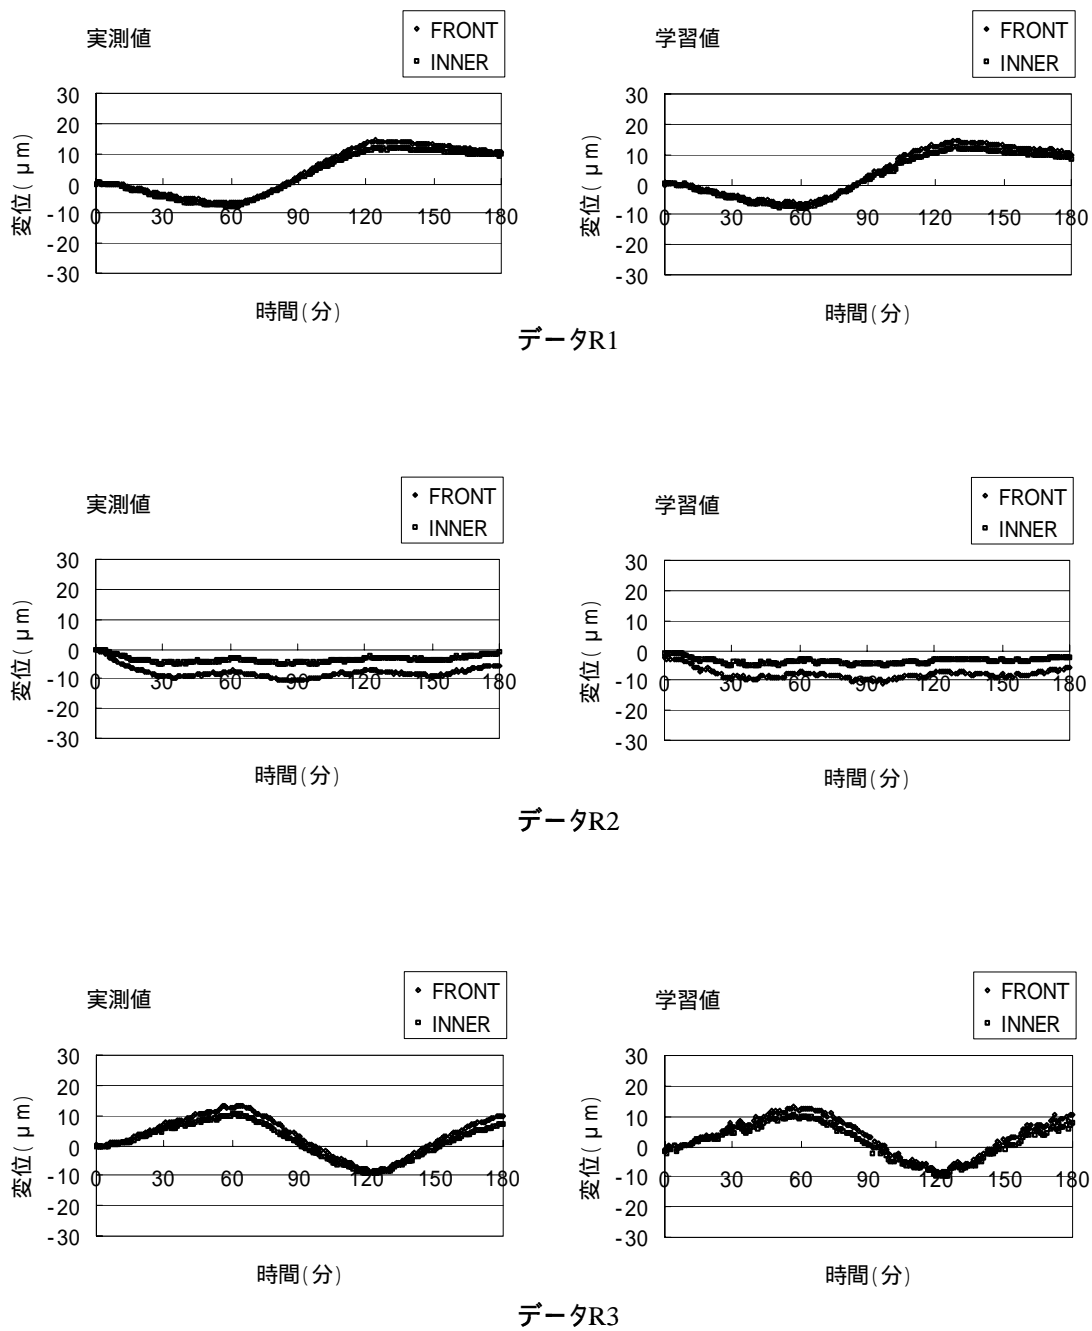


図 4.4 実験 1 実測値と学習値

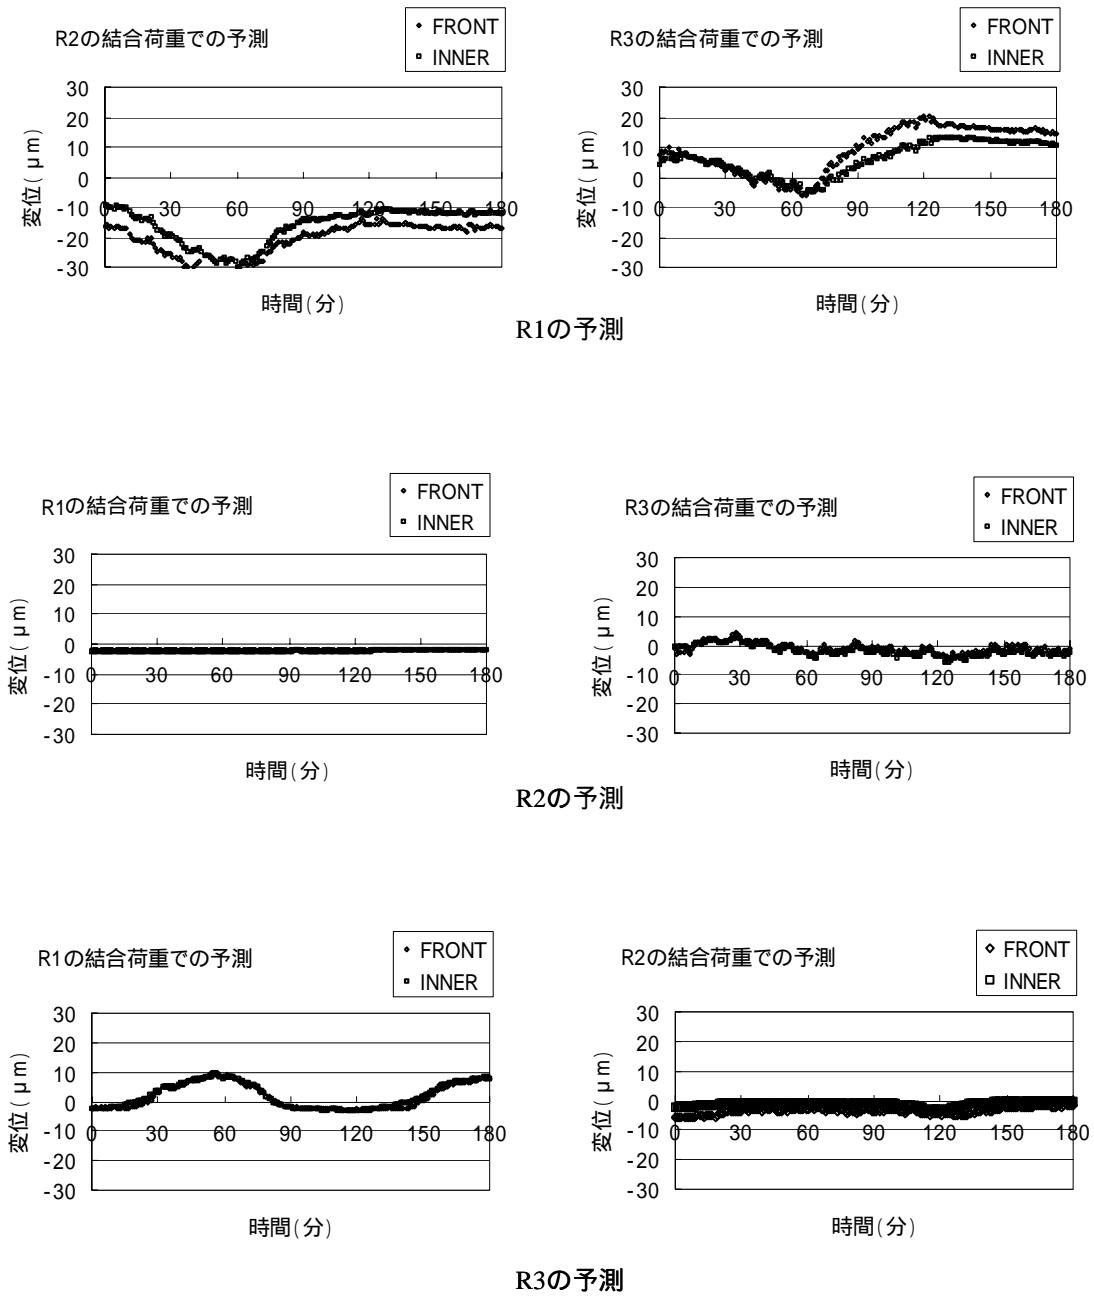


図 4.5 実験 1 未知データの予測値

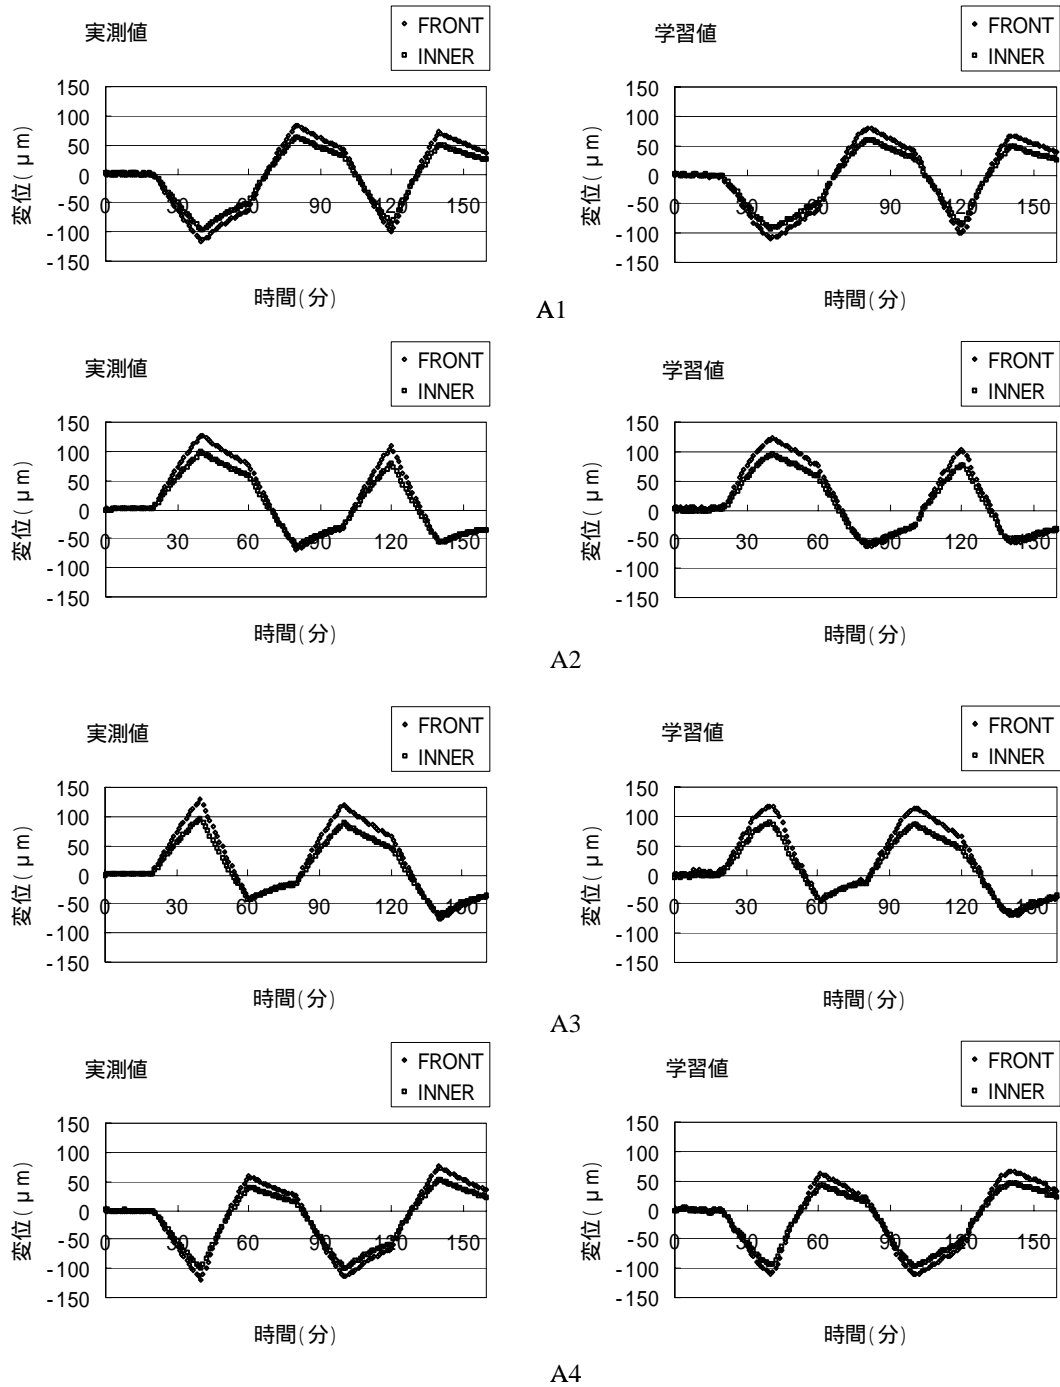


図 4.6 実験 2 実測値と学習値

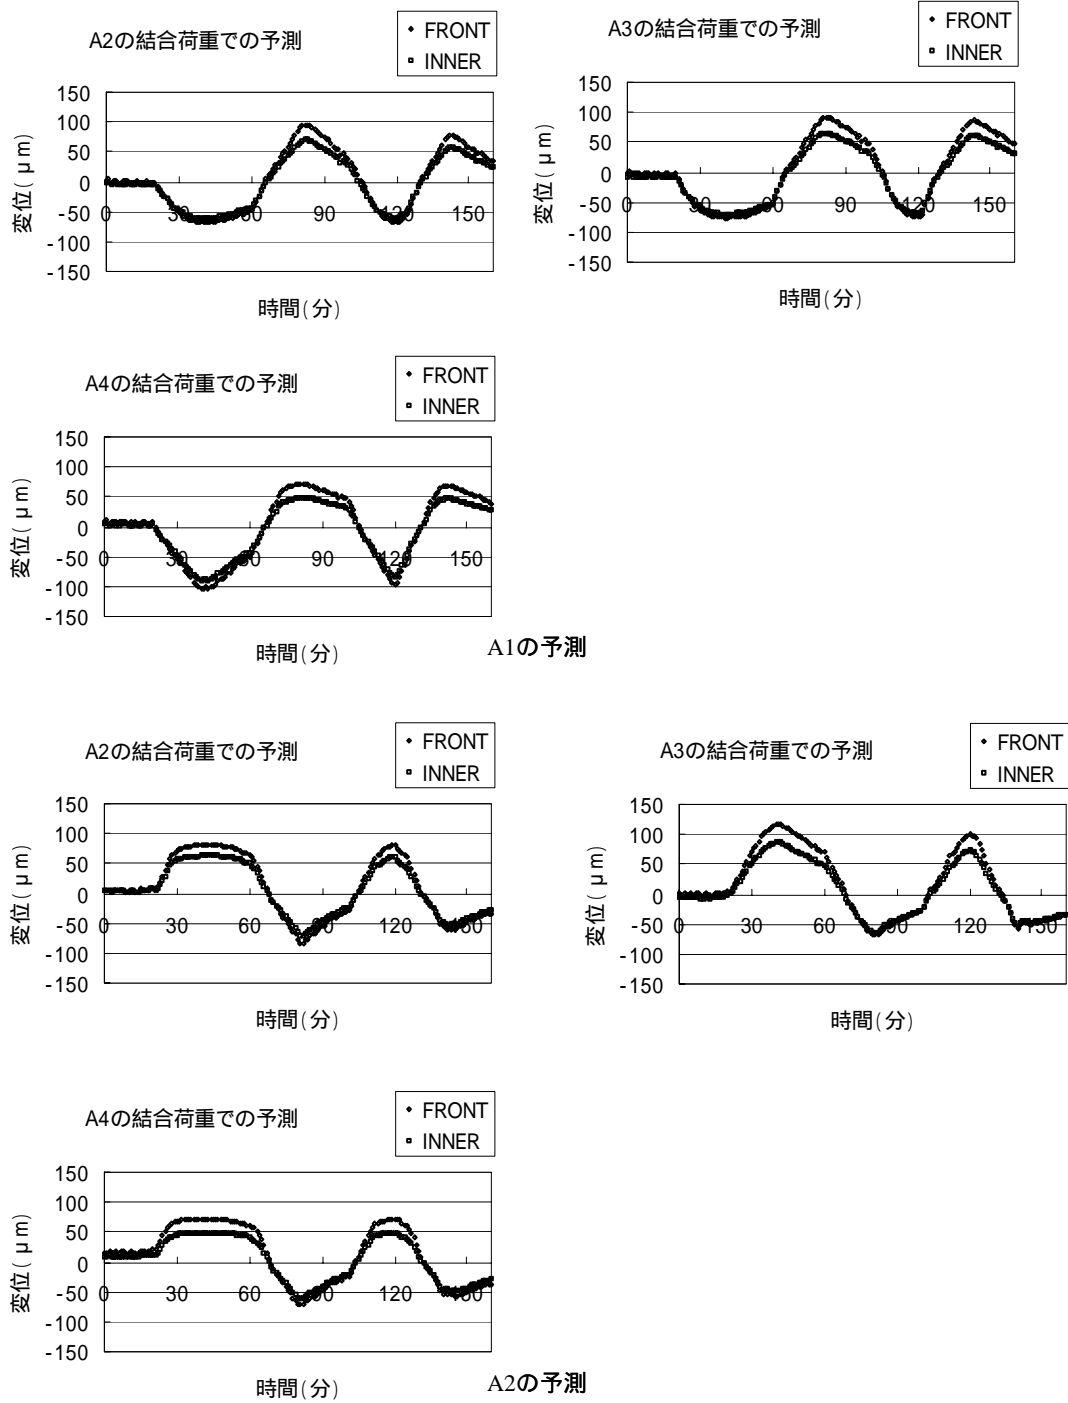


図 4.7 実験 2 未知データの予測(1)

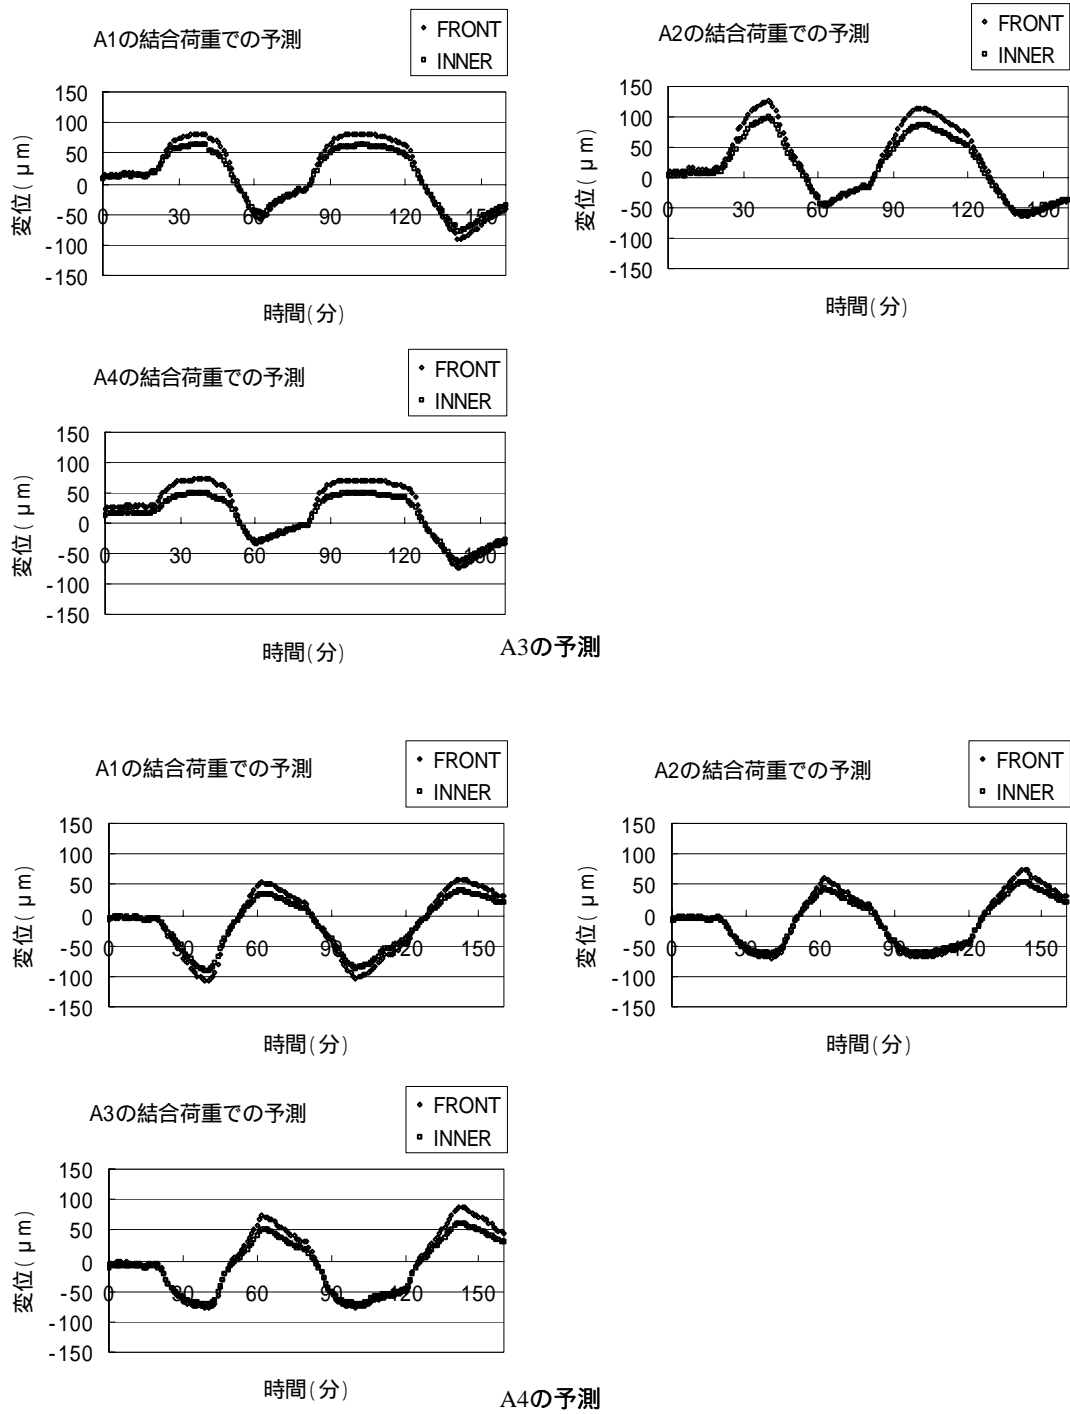


図 4.8 実験 2 未知データの予測(2)

第 5 章

考察と展望

5.1 主軸変位及び傾きの予測についての考察

これまでの高精度マシニングセンタの熱変位学習実験の結果をまとめると、以下の2つがあげられる。

1. 傾向の似たデータについては予測がほぼ可能である。
2. アクチュエータを作動させた場合での主軸位置の予測に関して、満足の行く結果は出ていない。
3. 主軸周りの温度変化による熱変形については、予測が不十分であった。
 - 1.に関しては特にいうことはないので、後2.と3.の原因について考察する。
考えられる原因として以下のことがあげられる。
 - a. 熱電対の取り付け位置、あるいは数に問題がある。
 - b. 学習実験で用意したデータの選び方に不備があった。
 - c. ニューラルネットワークの学習方法に問題がある。

ニューラルネットワークの学習方法は極一般的なバックプロパゲーションであり、この方法に特に問題があるとは考えられない。したがって、c.が原因であるとは考えにくい。ただし、ニューラルネットワークの各パラメータについては、改良の余地がある。

原因 a.については、試行錯誤の段階なので大いに考えられる。また、入力チャンネルを増やすことで原因 b.にも変化があるであろうと予想できる。3.の原因としては、b.の理由が一番にあてはまると考えられる。より広い温度の範囲で学習をさせることで、予測精度の向上ができるであろうと考えられるが、今の状態では実験での範囲内では室温を変化させることができないため、これについては今後の課題とする。

ここで考え方を変え、結果 1.に注目し、より予測誤差が少なくなるような予測方法を考えてみる。似た傾向のデータのときには予測がほぼ可能であるのだから、ある範囲に特化した学習データの結合荷重を使用し、閾値で区切り予測すれば予測誤差が少なくなるであろうと考えられる。そこで、0 を閾値にしプラスとマイナスで結合荷重を切り替え予測することを試みた。次のページにグラフを示す。

これにより 45 μm 以上あった予測誤差を 20 μm 以下にすることができた。

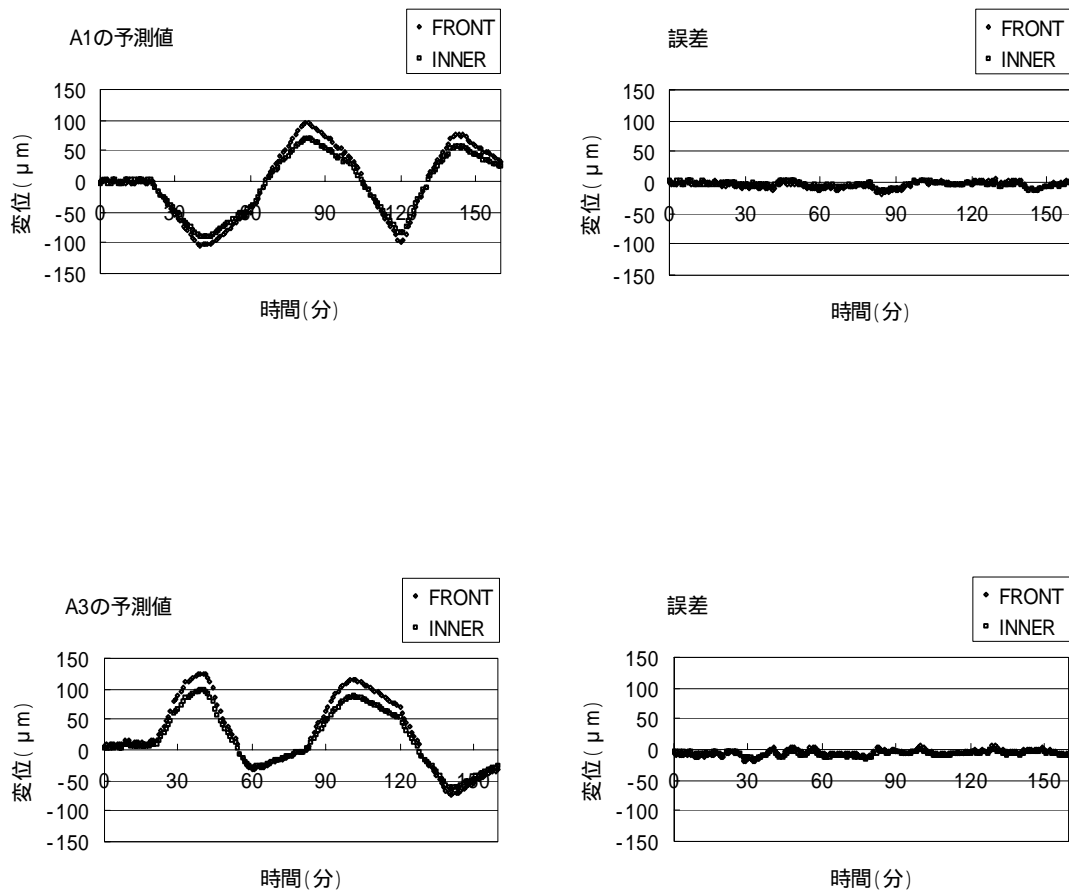


図 5.1 閾値で結合荷重を切り替えた場合の予測値と誤差

5.2 今後の展望

今後の課題として、主軸位置の予測精度の向上があげられる。特に熱アクチュエータを作動したときに誤差が大きかったことも考えると、新たにアクチュエータ周辺に熱電対、あるいは他のセンサを取り付けるといった方法が考えられる。

その他には、今回 Y 軸と Z 軸方向のみの予測であったものを XYZ の 3 軸すべてを測定し、予測できるようなシステム構築があげられる。また、実際に制御、加工実験を行い有用性や、更なる改善点を確かめる必要がある。

第 6 章

結論

本論文では、熱変形による加工誤差を自ら補償することのできるマシニングセンタの開発を目標とし、熱変形の予測について議論してきた。

本論文の結論は次の通りである。

- ・ 本研究では、熱電対を用いて各部の温度を測定し、傾きの予測をしたが、主軸周辺を中心にセンサの数や位置に関して改善の余地がある。
- ・ 熱アクチュエータを作動した場合の主軸位置については、0 を閾値としてプラス側とマイナス側とで結合荷重を切り替えることで、45 μm 以上あった予測誤差を 20 μm と小さくすることができた。

参考文献

[1]杉田直彦，長谷川洋介，“高精密マシニング・センタの姿勢制御とその評価に関する研究，”1993年度東京大学工学部産業機械工学科卒業論文，1993.

[2]奥村努，“変形情報に基づく姿勢制御によるマシニング・センタの高精密化の研究，”1994年度東京大学工学部産業機械工学科修士論文，1994.

[3]大家哲司，“マシニング・センタの熱変形能動補償に関する研究，”1996年度東京大学大学院工学系研究科産業機械工学専攻卒業論文，1996

[4]長尾高明，畑村洋太郎，光石衛，中尾政之，“知能化生産システム”2000.




謝辞

本研究を進めるにあたり、多くの方々にご指導、ご協力いただきました。




長尾教授、小林教授には日頃から親身なご指導やためになる経験談などをお聞かせいただきました。両研究室の院生、木崎君、更谷君、橋本君、松井君、和田君、小林君、白倉君には日ごろの話し相手になっていただいたり、各々のされている研究の説明をしていただいたり、時にはアドバイスなどもしていただいたりと、様々な面においてとても参考になりました。大変感謝しております。また、学部4年の浅田君、飯田君、岡田君、緒方君、川村君、小山君、静君、高谷君、にも話し相手になっていただき感謝しています。特に高谷君には研究の手伝いなどもしていただきました。ありがとうございました。

以上の方々、プライベートの友人達、他多数の方々にもとても感謝しております。この場をかりて、すべての方々に深く感謝し、厚く御礼申し上げます。本当にありがとうございました。




付録






R1 温度






R2 温度






R3 温度






A1 温度



A2 温度



A3 温度



A4 温度

