

ニューラルネットワークによるステッピングモータ制御用前置補償要素の調整法の改善  
**Improvement of a Neural-Network Type Adjusting System  
for a Pre-compensator of a Stepping Motor**

雪田哲志\*, 松尾健史\*, 三浦 武\*, 田島克文\*, 米田 真\*\*  
Satoshi Yukita \*, Kenshi Matsuo\*, Takeshi Miura\*, Katsubumi Tajima\*,  
Makoto Yoneda\*\*

\*秋田大学, \*\*オリエンタルモーター  
\*Akita University, \*\*Oriental Motor Co., Ltd.

キーワード : ステッピングモータ(stepping motor), 慣性負荷(inertial load), 前置補償要素  
(pre-compensator), ニューラルネットワーク(neural network)

連絡先 : 〒010-8502 秋田県秋田市手形学園町 1-1 秋田大学工学資源学研究所 電気電子工学専攻  
三浦 武, TEL. : (018)889-2329, FAX. : (018)837-0406, E-mail : miura@ipc.akita-u.ac.jp

## 1. はじめに

ステッピングモータはその回転角度と回転速度を入力される指令パルスの総数と周波数によって制御できる。そのため角度センサや速度センサを用いない開ループ制御が可能であり、簡易で低コストな制御システムを構築することができる<sup>1)</sup>。

一方、駆動時には回転子の慣性の影響により振動が発生し、整定時間の増大や脱調といった問題点が生じる。この問題を解決する方法として、低域通過フィルタからなる前置補償要素を用いる方法が提案されている<sup>2)</sup>。この手法では、目標角度波形から振動の原因となるシステムの固有周波数付近の周波数成分を除去することで振動を抑制する。よって、このシステムにはフィルタ設計のために固有周波数の値が必要となる。ステッピングモータの固有周波数は回転子の慣性モーメントの逆数の平方根に比例する<sup>2)</sup>ので、慣性モ

ーメントの値を推定することができれば、固有周波数を除去するためのフィルタを設計することができる。

文献3)では、励磁巻線の端子電圧の時系列データを入力としたニューラルネットワークによって、上記の慣性モーメントを推定できることが報告されている。これにより、開ループ制御の利点である簡易性・低コスト性を損なわずに慣性モーメントの推定ができる。また推定された慣性モーメントの値を用いて前置補償要素である低域通過フィルタの遮断周波数を適応的に変化させ、振動を抑制する方法が文献4)で考案されている。

文献3)では時系列データをニューラルネットワーク学習用の教師データとして用いている。他方で、先述したとおり、ステッピングモータの固有周波数は慣性モーメントの値に応じて変化することから、周波数領域の情報が慣性モーメント値と密接に関連していると言える。このことから時系列データを高速フーリエ変換(FFT)によって

周波数領域の振幅スペクトルに変換すれば、より慣性モーメント毎の特徴を表わしたデータが得られると思われる。

上記を考慮し、本研究では、教師データとして時系列データと周波数スペクトルの双方を用い、慣性モーメントを推定することを試みる。さらに、得られた慣性モーメントの値を用いて文献 4)の適応形前置補償要素を設計することにより、低域通過フィルタの遮断周波数の調整法の改善を図る。

## 2. 実験システムの構成

本研究で用いた実験システムを図 1 に示す。使用したステッピングモータは 2 相ハイブリット形であり、励磁方式は 2 相励磁である。ステッピングモータの各相への励磁指令は、パーソナルコンピュータ(PC)から I/O ポートを介して駆動システムへ送られる。この指令に従って駆動システムから各相に励磁電流が流され、モータが駆動される。このときの各相の端子電圧の時系列データは電圧取得用回路により取得され、A/D 変換器を介して PC へ入力される。このデータを FFT で周波数スペクトルに変換する。またステッピングモータの回転角度はロータリエンコーダにより取得され、Up/Down カウンタを介して、PC へ入力される。

本研究で使用したステッピングモータは、PK244-01B (オリエンタルモーター社製) である。その仕様を表 1 に示す。また、モータの駆動システムとして CMD2112-P (オリエンタルモーター




図 1 実験システム

Fig.1 Experimental system

表 1 ステッピングモータの仕様

Table 1 Specifications of the stepping motor	
Holding torque	0.26 [N · m]
Rotor inertia	$5.4 \times 10^{-6}$ [N · m · s <sup>2</sup> /rad]
Rated current	1.2 [A/phase]
Rated voltage	4.0 [V]
Winding resistance	3.3 [ $\Omega$ /phase]
Fundamental step-angle	1.8 [deg.]

社製) を用いた。

## 3. ニューラルネットワークの構成


### 3.1 ニューラルネットワークの構造

本研究では、文献 3)で提案されたニューラルネットワークを用いる方法をもとに、ステッピングモータの慣性モーメントを推定する。このとき入力データとして、端子電圧の時系列データを入力データとして用いる場合と、周波数スペクトルを用いる場合の双方を検討する。またニューラルネットワークは中間層を 1 層とした階層型のものを用いる。ニューラルネットワークの構造を図 2 に示す。


図 2(a)のように端子電圧の時系列データを用いる場合には、サンプル数を  $N$ 、サンプリング時間を  $\Delta t$  とすると、時刻  $(t-N\Delta t)$  から  $t$  までの各相の端子電圧の時系列データがニューラルネットワークに入力される。従って、全相(4 相)の端子電圧の時系列データを用いた場合にはユニット数が  $4N$  個となる。

また、図 2(b)のように振幅スペクトルを用いる場合には、サンプル数を  $N_F$  とすると、サンプリング周波数  $\Delta f=1/N\Delta t$  ごとに振幅スペクトルが入力される。

学習方法として、慣性項を付加した back propagation 法を用いる<sup>5)</sup>。本研究において中間層では、(1)式のシグモイド関数を、出力層では(2)



(a) Input: time-series



(b) Input: frequency spectrum

図2 階層型ニューラルネットワーク

Fig.2 Multi-layered neural network

式の線形関数を用いている.

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


$$f(z_j) = z_j \quad (2)$$

### 3.2 入力データ


本研究で用いるステップモータの駆動方式は2相励磁方式である. また, ステッピングモータの端子電圧の時系列データは励磁のON/OFFによって大きく変化する. よって本研究では, あるステップの駆動において励磁がOFF→ONになる相を第1相, OFFのままの相を第2相, ON→OFFになる相を第3相, ONのままの相を第4相と定義して用いる.

教師データである各相の端子電圧の時系列データおよび周波数スペクトルの例をそれぞれ図

—— : load 1    - - - - : load 2  
 ····· : load 3    - · - · : load 4



(a) first phase



(b) second phase

図3 教師データ(時系列)

Fig.3 Teacher data (time-series)




図4 教師データ(周波数スペクトル: 第1相)

Fig.4 Teacher data

(frequency spectrum: first phase)

3, 4 に示す. ここで時系列データはサンプリング時間  $\Delta t = 0.5\text{ms}$  で取得され, 周波数スペクトルはサンプリング時間  $\Delta t = 0.2\text{ms}$ , 取得時間  $T_A = 0 \sim 30.0\text{ms}$  で取得された時系列データをデータ数  $N_F = 256$ , ハミング窓の FFT で変換した.

### 3.3 標準化

文献 3) で用いられたニューラルネットワークは学習回数が 100,000 回以上と多い. そこで本研究では, 教師データを分散=1, 平均=0 で標準化することで, 学習回数の減少が可能か検討する.

標準化の方法を図 5 に示す. ここで  $i$  はニューラルネットワークの第  $i$  入力,  $j$  は教師データの番号をそれぞれ示す. また  $\bar{x}_i$  は(3)式のように  $m$  個ある  $i$  番目の入力データの平均値,  $X_{SDi}$  は標準偏差であり, それぞれ

$$\bar{x}_i = \frac{1}{m} \sum_{j=1}^m x_{ij} \quad (3)$$

$$X_{SDi} = \sqrt{\frac{1}{m} \sum_{j=1}^m (x_{ij} - \bar{x}_i)^2} \quad (4)$$

となる. この  $\bar{x}_i$  および  $X_{SDi}$  を用いて  $x_{ij}$  を次式のようにして標準化する.

$$x'_{ij} = \frac{x_{ij} - \bar{x}_i}{X_{SDi}} \quad (5)$$

### 3.4 入力データの条件

文献 3) と同様な時系列データを用いる場合の入力データの形式を表 2 に示す. また, 周波数スペクトルを用いる場合のものを表 3 に示す.

上記のような形式を持った入力データと, 文献 3) で最も良好な推定結果が得られたと報告された構造を持つニューラルネットワークを用いる. ニューラルネットワークの構造を表 4 に示す.

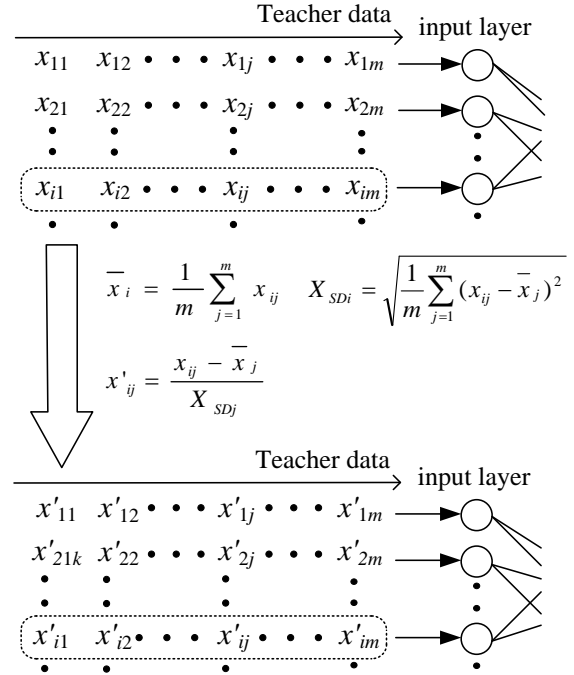


図 5 標準化

Fig.5 Standardization

表 2 ニューラルネットワークの入力データ (時系列データ)

Table 2 Input data of the neural network(time-series)

condition	choice
Phase used as input	all phases
Sampling time $\Delta t$	0.50[ms]
Acquisition time	14.5[ms]

表 3 ニューラルネットワークの入力データ (周波数スペクトル)

Table 3 Input data of the neural network (frequency spectrum)

condition	choice
Phase used as input	first phase
Number of data	$N_F = 256$
Sampling time	$\Delta t = 0.20[\text{ms}]$
Sampling frequency	$\Delta f = 19.5[\text{Hz}]$
Window function	Hamming window
Acquisition time	$T_A = 30.0[\text{ms}]$
Maximum frequency	$f_{\text{max}} = 253.5$

### 3.5 ニューラルネットワークの学習

本研究で用いる回転子と慣性負荷の和の慣性モーメントの値を表5に示す。load1~load4の慣性モーメントは出力に対する教師データとして、load5, load6はニューラルネットワークの汎化能力を確認するために用いる。

本研究では、教師データに時系列データを用いる場合および周波数スペクトルを用いる場合それぞれに関してニューラルネットワークの学習を行う。また、上記のそれぞれに関して、データの標準化を行った場合と行わない場合の学習も実施する。そのときの教師データの与え方(Type)を表6に示す。また学習する際の終了条件として、文献3)より表7に示す2つの条件を用いる。

### 3.6 推定結果の評価方法

ここではニューラルネットワークにより学習したシステムの推定精度を比較するために、評価指標を以下のように定義する。学習を終了したニューラルネットワークに、load1~load6の6パターン(L=6)のデータを5個(P=5)ずつ入力し、それぞれ推定された慣性モーメント  $J_{ip}$  と、実際の慣性モーメント  $J_i'$  との2乗誤差を次式のように求め、それらの平均値の平方根を評価値  $E$  とする。

$$E = \sqrt{\frac{1}{2(L \times P)} \sum_{l=1}^L \sum_{p=1}^P (J_l' - J_{lp})^2} \quad (6)$$

## 4. 適応形前置補償要素の構成

### 4.1 遮断周波数の決定

本研究では適応形前置補償要素として用いられる低域通過フィルタに、2次バターワースフィルタおよび2次ベッセルフィルタを用いる。ここでフィルタの遮断周波数  $f_c$  は、文献4)に従い、システム全体のゲイン特性の最大値が3[dB]以下になるように決める。これにより求められた回転子の慣

表4 ニューラルネットワークの構造

Table 4 Structure of the neural network.

Input	time-series	spectrum
Sampling time $\Delta t$ [ms]	0.50	0.20
Number of phases	4	1
Number of input-layer units	120	14
Number of hidden-layer units	20	20
Number of output-layer units	1	1

表5 慣性モーメント(回転子+慣性負荷)

Table 5 Moment of inertia (rotor + inertial load).

Load	Moment of inertia ( $\times 10^{-6}$ ) [N · m · s <sup>2</sup> /rad]
load 1	5.4 (no load)
load 2	15.4
load 3	35.4
load 4	55.4
load 5	25.4
load 6	45.4

表6 教師データ

Table 6 Teacher data

data type	number of data	standardization	
	for each condition	not standardized	standardized
time-series	1	Type1	Type2
	5	Type3	Type4
spectrum	1	Type5	Type6
	5	Type7	Type8

表7 学習の終了条件

Table.7 End conditions for learning

- Number of learning  $\geq 1,000,000$
- Average errors of the inertial load used for learning  $\leq 5.0\% (2.5 \times 10^{-6} \text{N} \cdot \text{m} \cdot \text{s}^2/\text{rad})$

性モーメントと遮断周波数の対応を図6に示す。この図をもとにして、推定した慣性モーメントから遮断周波数を決める。

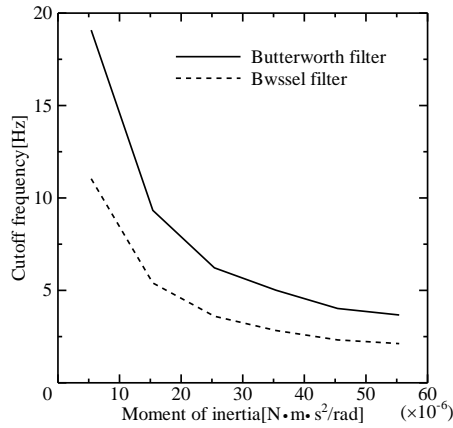


図 6 慣性モーメントと遮断周波数の対応


Fig.6 Correspondence between the moment of inertia and the cutoff frequency

## 4.2 制御方法

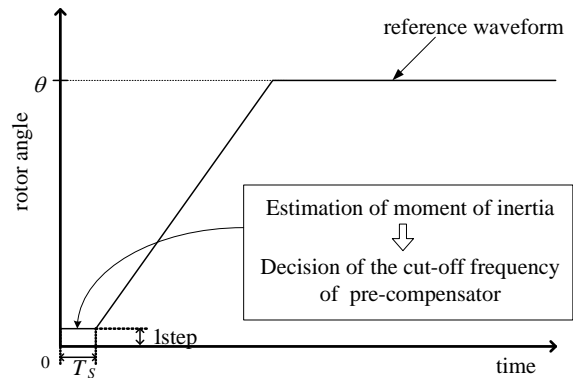
本研究では、文献 4)と同じ構成の制御システムを用いる。制御システムの構成図および補償要素を用いた場合の回転角度の目標波形を図 7 に示す。このシステムの制御アルゴリズムは以下のようにして実施される。まず遮断周波数を決定するため、ステッピングモータを 1 ステップだけフルステップで駆動させる。このとき各相の端子電圧を取得し慣性モーメントを推定し、その値に応じて遮断周波数を決定する。このステップの駆動時間  $T_s$  は、時系列データを用いる場合には 20.0ms、周波数スペクトルを用いる場合には 35.0ms である。次に、補償要素を適用し角度目標値  $\theta_r$  から  $\theta_r'$  へ修正しつつ制御する。この制御システムによる振動抑制を定量的に評価するため、最終停止位置における整定時間と行き過ぎ量を評価指標として用いる。

## 5. 慣性モーメントの推定実験

表 6 のようにしてニューラルネットワークに教師データを与え学習させた。また、教師データ取得時と同一の条件で慣性モーメントの推定実験を行った。実験結果を表 8 に示す。教師データ



(a) Schematic view of control system.



(b) Reference waveform in the cases that the pre-compensator is used.

図 7 適応形前置補償要素を用いた制御

Fig.7 Control with the adaptive pre-compensator.

表 8 評価関数  $E$  および学習回数

Table 8 Performance index  $E$  and number of learning

Learning Type	$E(\times 10^{-6})$	number of learning	
time-series	Type1	2.4	351,309
	Type2*	9.2	17,289
	Type3	12.2	1,000,000
	Type4*	6.7	26,044
spectrum	Type5	1.9	79,715
	Type6*	5.0	39,094
	Type7	1.7	17,399
	Type8*	2.1	88,813

\*: standardized

に端子電圧の周波数スペクトルを用いた場合、時系列データを用いた場合に比べ推定精度が高く、学習回数も少ない。このことから、慣性モーメントの推定に周波数スペクトルを用いることで、推定精度を向上できることが可能とわかった。

教師データを標準化した場合、学習回数は Type7-8 を除き減らすことができた。しかし推定精度は Type3-4 を除き悪化している。

時系列データを用いた場合および周波数スペ

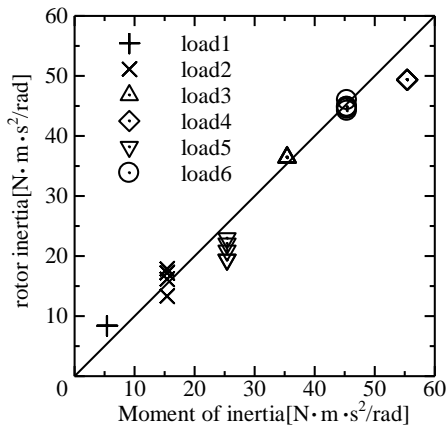


図8 慣性モーメントの推定値(Type1)

Fig.8 Estimated values of the moment of inertia (Type1)




図9 慣性モーメントの推定値(Type7)

Fig.9 Estimated values of the moment of inertia (Type7)

クトルを用いた場合それぞれに関して最も推定精度が高い推定結果を図8, 9に示す.

時系列データを入力した場合は, Type1(標準化なし, 各負荷データに対する教師データ数:1)の場合が最も推定精度が高い. 同様に周波数スペクトルを入力した場合は, Type7(標準化なし, 各負荷データに対する教師データ数:5)の場合が最も推定精度が高い. よって適応形前置補償要素にはこれらの推定システムを用いる.

## 6. 適応形前置補償要素による制御実験

### 6.1 実験条件

適応形前置補償要素を用いた制御システム実

験条件を以下に示す. 駆動方法としては8分割のマイクロステップ駆動を用いる. 駆動速度をフルステップ換算で580pps, 800ppsとして行う. また最終停止位置を720deg.とする. ここで580ppsはフルステップ, load4接続, 補償なしで700deg.以上駆動できる速度の最大値である. 駆動時には慣性負荷load1~load6を取り付ける. これに加えて,  $f_c$ 値を全ての条件において最大負荷load4の値に固定した場合の前置補償要素でも実験を行い, 結果を比較する.

### 6.2 実験結果

図10に, load1, load3時のモータ駆動時の回転子角度の時間変化を示す. 図10(a)~(d)はバターワースフィルタを用いた場合, 図10(e)~(h)はベッセルフィルタを用いた場合である. また800ppsにおける整定時間を図11に, 行き過ぎ量を図12に示す.

まず教師データの違いを比較する. 図10(a)を見ると, 入力データとして時系列データを用いた場合, 周波数スペクトルを用いた場合双方とも似たような波形になっている. また, 目標角度到達時刻は時系列データを用いた方が短いことが分かる. 図10(b)~(h)でも同様のことが言える. つまり速度, 慣性モーメントの変化にかかわらず目標角度到達時刻は時系列データを用いた方が短いことが分かる. これは推定に用いるデータの取得時間の差が表れたためと考えられる.

次にバターワースフィルタとベッセルフィルタの違いを比較する. 図10(a)~(d)を見た場合, バターワースフィルタを用いると行き過ぎ量が大きく, 目標角度到達時刻が短いことが分かる. また図10(e)~(h)を見た場合, ベッセルフィルタは整定時間, 行き過ぎ量が小さく, 早期に整定している. また図10(a)(b)(e)(f)および図11, 12を見た場合, 低負荷時において, 遮断周波数を一定にした前置補償要素に比べて目標角度到達時刻の遅れ, 整定時間, 行き過ぎ量の増加が抑えられることが分か

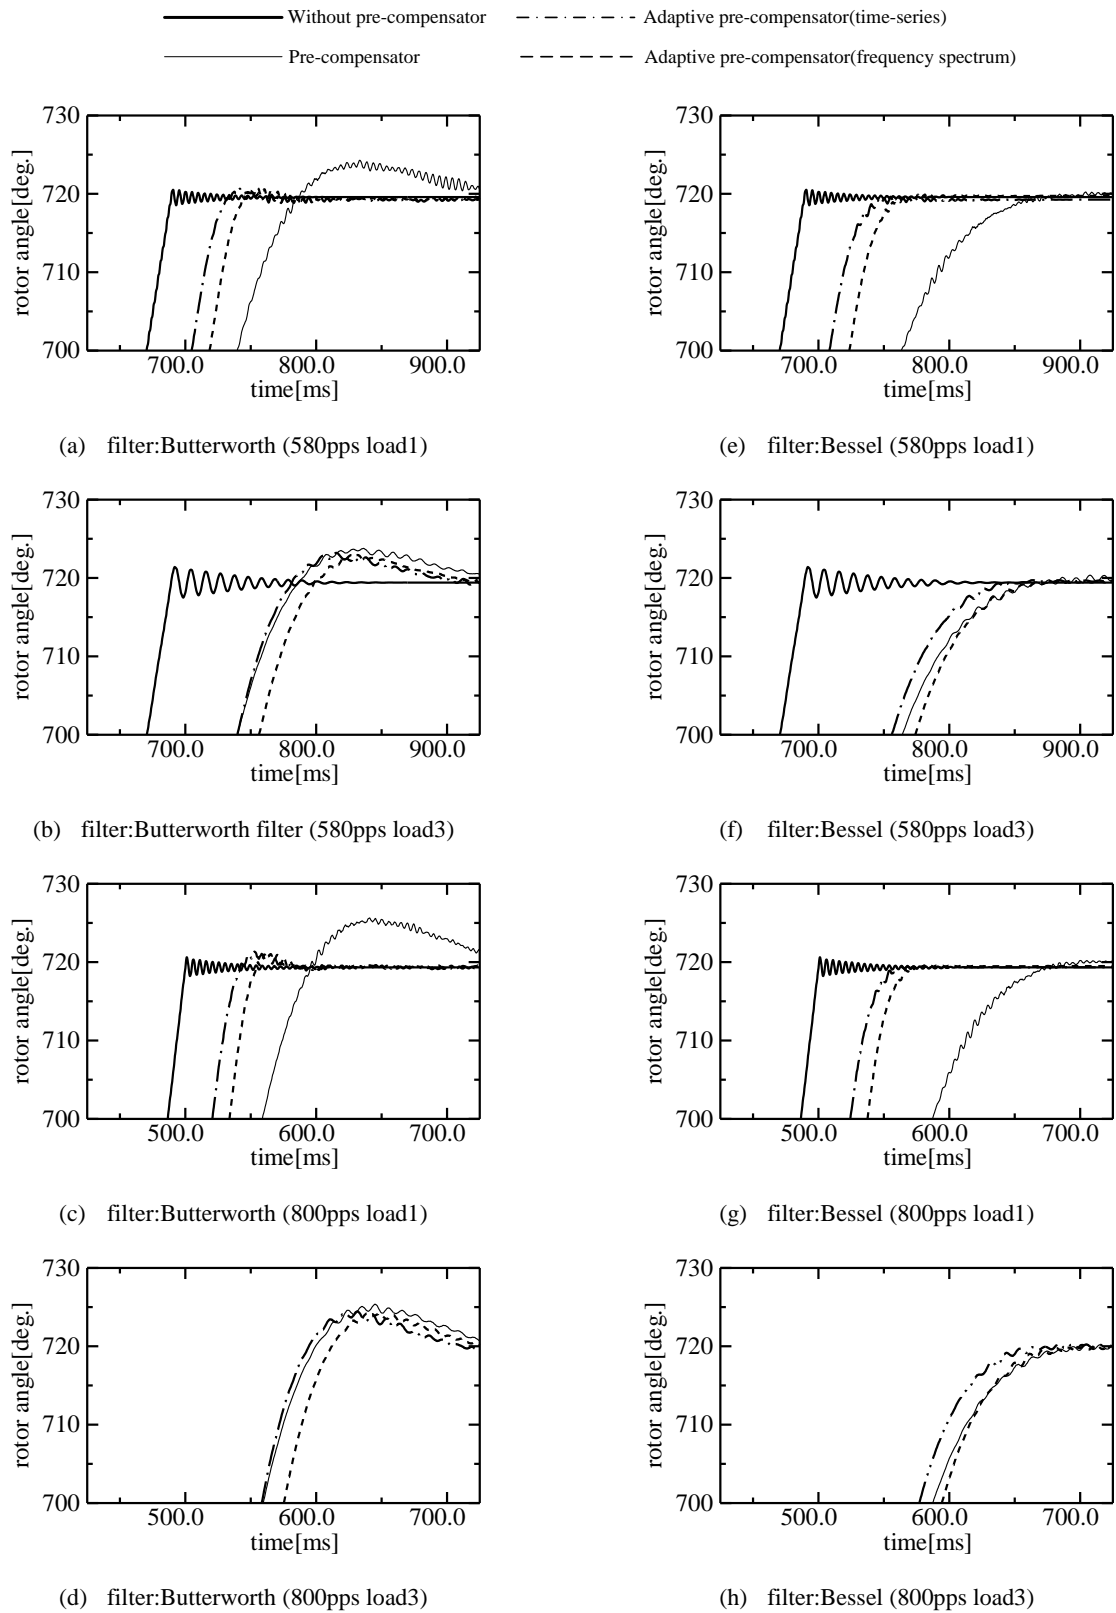


図 10 回転子角度の時間変化  
 Fig.10 Temporal variation of the rotor angle



- Butterworth(time-series)      △ Bessel(time-series)
- Butterworth(frequency spectrum)    ▲ Bessel(frequency spectrum)
- Butterworth(constant)            ▲ Bessel(constant)
- + Without pre-compensator




図 11 整定時間の比較(800pps)

Fig.11 Comparison of settling time(800pps)




図 12 行き過ぎ量の比較(800pps)

Fig.12 Comparison of overshoot(800pps)

った。

## 7. 考察

第5章においては、教師データに時系列データを用いる場合、周波数スペクトルを用いる場合、それらを標準化して用いる場合でニューラルネットワークの学習を行い、それらの推定精度、学習回数を比較した。その結果、教師データに周波

数スペクトルを用いることで推定精度が向上することが分かった。

また各データを標準化して用いた場合、標準化しない場合と比較して学習回数が減少する傾向がみられる。一方で、標準化することで推定精度に関しては全体的に悪化している。ただし教師データが増えると精度が向上する傾向がみられる。これはデータ数が増えることでデータに含まれるノイズの影響が減るためと思われる。特に周波数スペクトルを用いた場合には、標準化しない場合の推定精度に大きく近づいており、教師データをより増やせば標準化しない場合の精度と同程度になる可能性があると思われる。

以上のことから、標準化は教師データを増やすことで精度をさらに向上できる可能性があると思われる。

第6章においては、第5章で得た時系列データ、周波数スペクトル双方の慣性モーメント推定システムを用いた。慣性モーメントの推定に時系列データを用いた場合と周波数スペクトルを用いた場合を比較すると、両者に大きな差がないことが分かった。これは5章での推定精度の向上の度合いが、明確な差を生み出すほどなかったためと思われる。よって、今回の実験条件では、適応形前置補償要素には推定時間の短い時系列データを用いる方が良いと思われる。

またバターワースフィルタ、ベッセルフィルタの違いを比較し、バターワースフィルタは目標角度到達時刻が早く、ベッセルフィルタは整定時間、行き過ぎ量の小ささに優れていることが分かった。このことから、制御系の設計仕様に応じてフィルタを使い分ければ、より目的に適した適応形前置補償要素による制御が行えると思われる。

## 8 おわりに

本研究では、ニューラルネットワークの教師データとして端子電圧の時系列データと周波数スペクトル双方を用い、推定精度を比較した。また

教師データの値を標準化して行い, それらの推定結果と学習回数を比較, 検討した. またその推定システムを適応形前置補償要素に用いることで, 遮断周波数の調整法の改善を図った.

周波数スペクトルを用いることにより, 時系列データを用いる場合よりも高精度な推定が可能となった. また標準化においても, 教師データの数を増やすことで, 精度が向上する可能性が示された.

しかし適応形前置補償要素に用いる場合, 双方の回転子角度の時間変化に大きな違いはなかった. よって今回の実験の範囲内では, 推定時間の短い時系列データを用いる方が良いと分かった.

## 参考文献

- 1) 百目鬼英雄: ステッピングモータの使い方, 7/42, 工業調査会(1993)
- 2) 三浦 武, 谷口敏幸, 百目鬼英雄: 前置補償要素の適応によるステッピングモータのマイクロステップ駆動時における回転子振動の抑制, 電学論 D, Vol.120, No.12, 1462/1470, (2000)
- 3) 細野寛, 松尾健史, 三浦武, 田島克文, 米田真: ニューラルネットワークを用いたステッピングモータの慣性負荷の推定, 計測自動制御学会東北支部第 259 回研究集会, 259-7(2010)
- 4) 小松田弘瑛, 松尾健史, 三浦武, 田島克文, 米田真: 適応形前置補償要素を用いたステッピングモータの回転子振動抑制, 計測自動制御学会東北支部第 267 回研究集会, 267-10(2011)
- 5) 坂和正敏, 田中正博: ニューロコンピューティング入門, 25/37, 森北出版株式会社(1997)