

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
Estimation of an Inertial Load Attached to a Stepping Motor by Neural Network

○細野 寛*, 松尾健史*, 三浦 武*, 田島克文*, 米田 真**

○Hiroshi Hosono*, 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),
慣性変動 (variation of inertia), 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 工学資源学部 電気電子工学科
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、指令パルスを駆動システムに入力することにより駆動され、一定角度ずつステップ状に回転する制御用小形モータである。このため、指令パルスの総数・周波数により、開ループで位置・速度制御が可能であり、低コストで簡易な構造の制御システムを構築することができる。これらの特徴を有するため、FA・OA機器などにおいて幅広く用いられている¹⁾。

一方、ステッピングモータの駆動時には、回転子がステップ状に回転するため、慣性の影響で振動が生じるという問題点がある。これが原因で、脱調や整定時間の増大などの問題が生じる。この問題に対処するため、マイクロステップ駆動法や前置補償要素と

して低域通過フィルタを用いる方法が提案されている²⁾。これらの方法を用いる際、未知の場合が多い慣性負荷の値を推定することができればステッピングモータの制御特性の改善につながると考えられる。しかし、慣性負荷の値の推定のためにセンサなどの外部機器をシステムに組み込めば、ステッピングモータの低コスト性および簡易性を損なう。

上記の問題を解決するためには、センサレスで慣性負荷の値を取得する方法が必要となる。ブラシレス DC モータを用いた場合に関しては、文献 3), 4) によりニューラルネットワークを用いる方法が検討されている。上記の文献においては、モータの状態変数の値から慣性負荷の値を推定しており、高精度な推定が可能であると報告され

ている。本研究でも同様の方法を用いて、ステッピングモータの慣性負荷の値を推定する。

モータの状態変数としては、電流、電圧、回転速度、回転角度が挙げられる。しかし、回転速度、回転角度を用いる場合、センサなどが必要となり、コスト面と機械的な制約の問題が生じる。これに対して、電流、電圧を用いる場合、安価で簡易な回路によってその値を検出できる。本研究では、モータの駆動時に電流制御形駆動システムを用いるので、電流を指令値に合うように制御するとき、駆動条件に応じた変動が見られると考えられる各相の端子電圧の値から慣性負荷の値が推定可能であるか検討を行った。

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。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 D/A 変換器を介して駆動システムに送られる。駆動システム内で指令に従った電流制御が行われ、各相に励磁電流を流すことによって、モータが駆動される。モータの各相の端子電圧は、図 2 に示す電圧取得用回路によって取得される。その際、低域通過フィルタを通して電圧波形に現れる高調波成分を取り除いている。この回路によって取得された電圧は、A/D 変換器を介して PC に入力される。

モータの駆動には、2 相励磁方式を用いた。また、ステッピングモータの \bar{A} 相と \bar{B} 相から A 相と \bar{B} 相への励磁切り替え時に 1 ステップさせ、サンプリング時間 Δt 毎に各相の端子電圧の値を取得した。




図 1 実験システム

Fig.1 Experimental system.




図 2 電圧取得用回路 (A 相)

Fig.2 Circuit to acquire voltage (Phase A).

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	5.4×10^{-6} N · m · s ² /rad
Rated current	1.2 A/phase
Rated voltage	4.0 V
Winding resistance	3.3 Ω/phase
Fundamental step angle	1.8 deg.

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 CSD2112-P(オリエンタルモーター社製)を用いた。

3. ニューラルネットワークの構造と学習

本研究では、ステッピングモータの慣性負荷を推定するためにニューラルネットワークを用いる。以下にその詳細を示す。

用いたニューラルネットワークは、図 3 に示すように中間層を 1 層とした階層型ニューラルネットワークである⁵⁾。図に示すように、ニューラルネットワークにはサンプリング時間 Δt 毎に取得される各相の端子電圧の値が入力される。その後、中間層を介しモータの回転部分の慣性モーメントの推定値が出力される。この値は、回転子と負荷の慣性モーメントの合計値である。

入力層の各ユニットでは、具体的な演算が行われず、中間層の各ユニットへの入力値の分配のみが行われる。また、中間層にはシグモイド関数を用い、出力層には線形関数を用いた⁵⁾。

各相の端子電圧のサンプル数を N とすると、時刻 $(t-N\Delta t)$ から t までの各相の端子電圧の値がニューラルネットワークに入力され、4 相すべてを用いた場合には、ユニット数は $4N$ 個となる。 N の具体的な値と中間層のユニット数は第 5 章で検討される。出力層は、慣性モーメントの値のみを出力するので、ユニット数 1 となる。

ニューラルネットワークの各ユニット間における結合荷重は、あらかじめ取得されたデータを教師データとした教師あり学習によって決定される。この学習には、慣性項を付加した **back propagation 法**(BP 法)⁵⁾ を用いた。その中では、ニューラルネットワークの出力値と教師データの誤差が十分に小さくなるまで学習が繰り返される。このとき、表 2 の 2 つの条件のいずれかを満足した場合に学習が終了する。

また、実際に用いた回転部分の慣性モーメントの値を表 3 に示す。Case 1 ~ Case 3 は、教師データ取得時に用いた負荷である。Case 4 は、Case 2 と Case 3 の間の慣性モー

メントであり、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、ニューラルネットワークの結合荷重の学習をオフラインで行う。また、ニューラルネットワークの時系列データのサンプル数 N や考慮するモータの相数を変化させる。さらに、サンプリング時間も変化させている。それらの具体的な条件の変化を表 4 に示す。その中では、Type 1 ~ Type 3 の 3 種類のニューラルネットワークの構造が用意されている。以下にその詳細を示す。

Type 1 の構造を用いる場合は、サンプリング時間 $\Delta t = 0.50\text{ms}$ として 4 相すべての端子電圧の値を用いる。Type 2 の構造においては、サンプリング時間は Type 1 の構造と同様に $\Delta t = 0.50\text{ms}$ であるが、1 相分の端子電圧の値のみを用いる。Type 3 の構造も端子電圧は 1 相分のみを用いるが、サンプリ




図 3 ニューラルネットワークの構造 (Type 1)

Fig.3 Structure of the neural network (Type 1).

表 2 学習終了の条件

Table 2 End conditions for learning.

- | |
|--|
| <ul style="list-style-type: none"> • Number of learning $\geq 1,000,000$ • Average errors of the inertial load used for learning $\leq 5.0\%$ ($2.5 \times 10^{-6} \text{ N} \cdot \text{m} \cdot \text{s}^2/\text{rad}$) |
|--|

表 3 慣性モーメント(回転子 + 慣性負荷)

Table 3 Moment of inertia
(rotor + inertial load).

Case	Moment of inertia [N · m · s ² /rad]
Case 1	5.4×10 ⁻⁶ (no load)
Case 2	15.4×10 ⁻⁶
Case 3	55.4×10 ⁻⁶
Case 4	35.4×10 ⁻⁶

表 4 ニューラルネットワークの入力構造

Table 4 Input structure of the neural network.

Type	Number of phases	Sampling time Δt [ms]
Type 1	4	0.50
Type 2	1	0.50
Type 3	1	0.20

ング時間はより短い $\Delta t = 0.20\text{ms}$ としている。Type 2, Type 3 の構造では, A 相, B 相, \bar{A} 相および \bar{B} 相のすべてを単一相として試行した。この中で図 3 のニューラルネットワークは, Type 1 の構造である。

4. ニューラルネットワークの入力と教師データ

ニューラルネットワークの入力として用いる時系列データの取得時間の範囲を表 5 に示す。取得時間の上限値を T とすると, 時系列データは $0 \sim T$ の範囲で取得されることになる。表中の 4 個の相を用いた場合において取得時間の範囲に変動があるのは, 入力層のユニット数を変化させたためである。

用いた教師データの例を図 4 に示す。こ

表 5 時系列データの取得時間の範囲

Table 5 Period for the acquisition of a time-series data stream.

Number of phases	Sampling time Δt [ms] (Type)	Acquisition time T [ms]
4	0.50 (Type 1)	4.5, 9.5, 12.0, 14.5, 19.5
1	0.50 (Type 2)	49.5
	0.20 (Type 3)	19.8




図 4 教師データの例 (Type 3)

Fig.4 Examples of teacher data (Type 3)

の図は, Type 3 の構造を用いる場合の A 相と B 相の教師データである。

5. ニューラルネットワークによる学習および慣性モーメントの推定

一般にニューラルネットワークの使用に関しては, 学習に用いる教師データ数が少

なく、且つ汎化能力が高いことが望まれる。しかし、汎化能力を向上させるには教師データ数を増やさなければならない。よって、両者を満足させるためには、用いる教師データの種類、各層のユニット数、演算で用いる学習率と慣性項の係数などを適切に選ぶ必要がある。本章では、各層のユニット数およびニューラルネットワークの構造の変化が学習・演算時間や推定精度などにどのような影響を及ぼすか検討する。

5.1 推定法

本研究では、第3章の表4で述べたようにニューラルネットワークの入力構造を変化させて実験を行う。Type 1の構造を用いる場合には、入力層のユニット数および中間層のユニット数の検討を行い、ここで得られた結果を用いてType 1～Type 3のそれぞれの構造を用いて慣性モーメントの値を推定する。

本研究では、学習が安定に行われることを考慮して試行錯誤により学習率 10^{-6} 、慣性項 0.10 としている。

5.2 Type 1の構造の場合

Type 1の構造における学習回数および推定結果を表6、表7、図5に示す。

表6では、Type 1の構造を用いた場合において、入力層のユニット数を変化させた場合の学習回数の変化を示している。表6の T は、第4章の表5で示した取得時間の上限値である。この表から、入力層のユニット数が 100 のときの学習回数が最も少ないことが分かる。ここで、予備解析として

Type 2, Type 3 の構造の場合においても同様の計算を行ったが、その場合においても入力層のユニット数が 100 のときに最も学習回数が少なくなった。これらの結果に基づいて、入力層のユニット数を 100 に固定し、中間層のユニット数を表7のように決定した。この表を見ると、中間層のユニット数を増やすことにより学習回数が減ることが分かる。しかし、中間層のユニット数を増やすことは、推定時における演算時間の増加につながるためこの数をむやみに増やすことは望ましくない。そこで以下では、中間層のユニット数をどの程度まで減少できるか検討する。

図5は、Type 1の構造を用いた場合の推定結果である。図5(a)は、表7の条件で学習させたニューラルネットワークを用いて慣性モーメントの値を推定した結果であり、図5(b)は、このときの慣性負荷の真値と推定値の誤差である。図5(a)、図5(b)より、中間層の最も少ないユニット数が 10 の場合の誤差が大きく、他の場合は、ほとんど差がないことが分かる。よって、その中で中間層のユニット数が最も少ない 20 を選択する。

表6 学習回数(中間層 20, 出力層 1, Type 1)

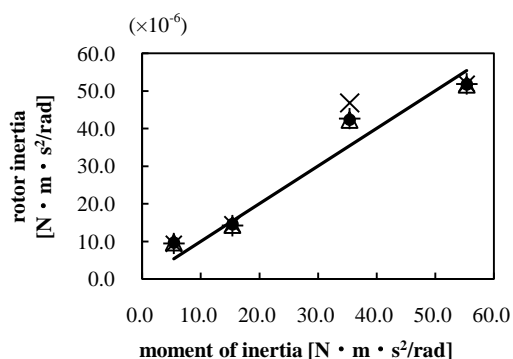
Units of input layer (T)	Number of learning
40 (4.5 ms)	1,000,000
80 (9.5 ms)	367,578
100 (12.0 ms)	102,508
120 (14.5 ms)	294,425
160 (19.5 ms)	1,000,000

表 7 学習回数(入力層 100, 出力層 1, Type 1)

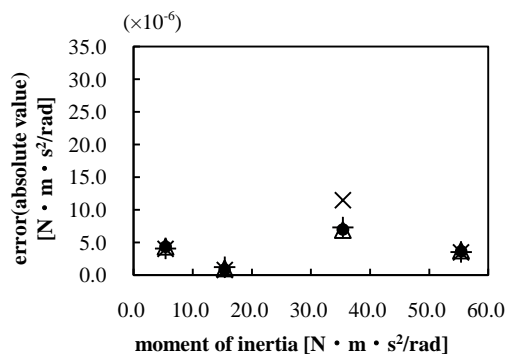
Table 7 Number of learning
(input layer 100, output layer 1, Type 1).

Units of hidden layer	Number of learning
10	194,133
20	102,508
30	77,258
40	68,303

× : hidden layer 10 + : hidden layer 20 ● : hidden layer 30
△ : hidden layer 40 — : true value



(a) Estimated values of moment of inertia.



(b) Errors of the estimated values.

図 5 推定結果

Fig.5 Results of estimation (Type 1).

以上から、入力層のユニット数が 100、中間層のユニット数が 20 の場合が適当だと考えられるので、これ以降ではこれらのユニット数に固定して実験を行う。

また、教師データ取得時に用いていない Case 4 ($35.4 \times 10^{-6} \text{ N} \cdot \text{m} \cdot \text{s}^2/\text{rad}$)を用いた場合の誤差が最も大きくなった。このことから、Type 1 では、この場合に汎化能力が低くなっていることが分かる。

5.3 Type 2 と Type 3 の構造の場合

Type 2 と Type 3 の構造における学習回数および推定結果を表 8, 表 9, 図 6, 図 7 に示す。

表 8, 表 9 は、ニューラルネットワークの構造を Type 2, Type 3 とした場合における

表 8 学習回数

(入力層 100, 中間層 20, 出力層 1, Type 2)

Table 8 Number of learning
(input layer 100, hidden layer 20,
output layer 1, Type 2).

Phase used as input	Number of learning
Phase A	188,042
Phase B	195,608
Phase \bar{A}	106,539
Phase \bar{B}	143,249

表 9 学習回数

(入力層 100, 中間層 20, 出力層 1, Type 3)

Table 9 Number of learning
(input layer 100, hidden layer 20,
output layer 1, Type 3).

Phase used as input	Number of learning
Phase A	185,801
Phase B	192,536
Phase \bar{A}	186,436
Phase \bar{B}	51,219

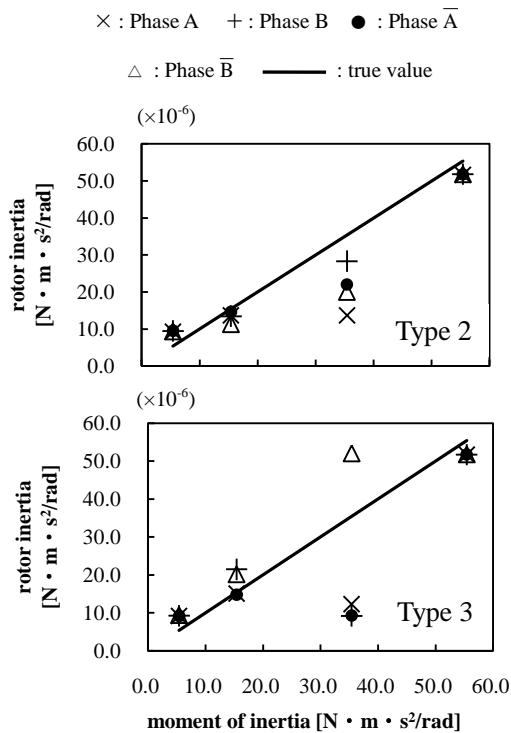


図6 慣性モーメントの推定値

Fig.6 Estimated values of moment of inertia.

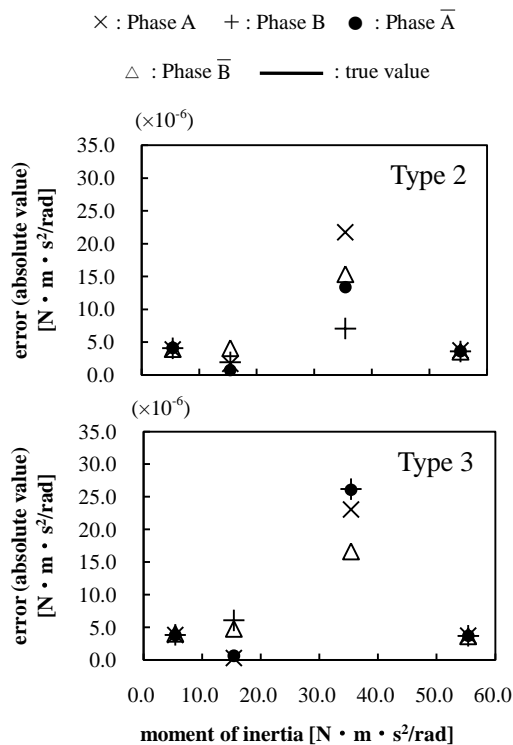


図7 推定値との誤差

Fig.7 Errors of the estimated values.

る学習回数の結果である。図6、図7は、これらの表の条件で学習させたニューラルネットワークにより得られた慣性モーメントの推定値および真値との誤差である。

構造を Type 2 とした場合の学習回数に関しては、表8から \bar{A} 相のデータを用いた場合が最も少ないことが分かる。これに対して、図6、図7の Type 2 を見ると、B相を用いた場合の推定精度が最も高くなっている。このように、単一相のみを用いた場合には、学習回数と推定精度の間で適切な相が異なることが分かる。

Type 3 の構造に関しては、表9から \bar{B} 相を用いた場合の学習回数が最も少ない。また、図6、図7の Type 3 より、いずれの相を用いた場合でも教師データ取得時に用いなかった Case 4 における推定精度が他の負荷と比較して低いので、この条件下では高い汎化能力は得られないと言える。

5.4 各 Type の構造における学習回数および推定精度の比較

本節では、Type 1 ~ Type 3 の構造における学習回数および推定精度を比較する。

Type 2 と Type 3 の構造を用いた場合を比較すると、前節の表8、表9から Type 2 の構造では \bar{A} 相、Type 3 の構造では \bar{B} 相の学習回数が最も少ないことが確認できる。これらの結果から、サンプリング時間 Δt の値を変化させると、ニューラルネットワークへの入力として用いるべき相も変化するという現象が生じることが分かる。また、前節の図6、図7より、Type 3 の構造を用いた場合の方が教師データ取得時以外の Case 4 を装着した場合に推定精度が低くなって

いることが確認できる。Type 3 の場合は、サンプリング時間 Δt が短いためにニューラルネットワークに入力されるデータの取得時間の範囲が狭くなる。このことが、推定精度の悪化を招いているのかもしれない。

ここで、第 5 章 2 節の図 5 に示される 4 相すべてを用いた場合と前節の図 6, 図 7 に示される単相のみを用いた場合を比較すると、全体的に 4 相すべてを用いた場合の方が推定精度および汎化能力が高いと言える。このことから、ニューラルネットワークの入力値としてステッピングモータの 4 相すべての端子電圧を用いて回転部分の慣性モーメントの値を推定することが適当ではないかと考えられる。

6. おわりに

本研究では、ニューラルネットワークを用いてセンサレスでステッピングモータの慣性モーメントの推定を行った。ニューラルネットワークの入力としては、モータの各相の端子電圧を用いた。また、ニューラルネットワークの時系列データのサンプル数、考慮するモータの相数、サンプリング時間を変化させて実験を行った。

上記の実験より、各相の端子電圧からニューラルネットワークを用いて慣性負荷の推定が可能であることが確かめられた。また、4 相すべての端子電圧の値を用いた場合の推定精度および汎化能力が高くなることも分かった。しかし、学習時に用いていない条件下での推定精度が低くなるという問題点もあった。これに関しては、教師データ取得時に用いる負荷を増やすことによって、改善できると考えられる。

以上のように、上記の問題点を考慮すれば、ステッピングモータの利点である低コスト性および簡易性を損なわず、慣性負荷の推定が可能になると考えられる。

謝辞

本研究に関する貴重なご意見を頂いた秋田大学教授 故谷口敏幸先生に哀悼の意と共に感謝の意を表する。

参考文献

- 1) 見城尚志：ステッピングモータの使い方，7/13，工業調査会 (1993)
- 2) 柴田真生，松尾健史，秋山宜万，三浦武，谷口敏幸：ステッピングモータの開ループ制御における目標値波形整形用前置補償要素，計測自動制御学会東北支部第 230 回研究集会，230-3 (2006)
- 3) 坂 圭介，松尾健史，秋山宜万，三浦武，谷口敏幸，米田 真：回転子慣性の変動に対応したブラシレス DC モータの位置制御その 2，計測自動制御学会東北支部第 230 回研究集会，230-4 (2006)
- 4) 齊藤寛之，秋山宜万，松尾健史，三浦武，谷口敏幸，米田 真：回転子慣性の変動に対応したブラシレス DC モータの位置制御その 3，計測自動制御学会東北支部第 244 回研究集会，244-8 (2008)
- 5) 坂和正敏，田中雅博：ニューロンコンピュータ入門，27/37，森北出版株式会社 (1997)