

ニューラルネットワークによる人間オペレータの技量と巧みさの獲得 (倒立振子の安定化制御におけるカオス的時系列データからの ニューロ制御器の生成)

Acquisition of Human Operator's Skills and Dexterity using Neural Network: Automatic Generation of Neural Controller from Chaotic Time Series Data during Stabilizing Control of an Inverted Pendulum

川副嘉彦*
Yoshihiko Kawazoe*
松本 仁*
Jin Matsumoto
半田昌司***
Masashi Handa

榎本弘一**
Kouichi Enomoto**
岡部澄夫*
Sumio Okabe*

* 埼玉工業大学 Saitama Institute of Technology

** 三洋 LSI デザイン・システム・ソフト Sanyo LSI Design System Soft

***小野測器 Ono Sokki

In order to stabilize the inherent unstable system like the inverted pendulum on a cart, severe judgment of situation is required. Accordingly, it can be expected that the human operators exhibit a complex behavior occasionally. This paper tried to identify the skills of human operators from time series data during stabilizing control of an inverted pendulum by using neural network. The operators in the experiment are skilled to some extent in stabilizing the inverted pendulum by training, and the data of ten trials per person were successively taken for an analysis, where the waveforms of pendulum angle and cart displacement were recorded. The simulated results using the identified neural network controller from time series data of the human operator could present the stabilizing behavior of the inverted pendulum. Accordingly, it was seen that the skill of human operators with individual difference and different skill up process could be identified with this neural network identifying system.

1. 緒言

熟練後の人間の特性や人間の制御動作のうち線形応答については多くの成果が得られ、各種の伝達関数モデルが提案されてきた[1]。しかし、難しい制御対象や学習が進行して行く過程での人間の挙動に顕著な非線形・非定常な特性についてはほとんど不明である[2][3]。

倒立振子のように平衡点不安定な非線形系を人間が制御して安定化させるためには、人間には過酷な状況判断が要求され、人間は時と場合により複雑な行動を行うことが予想される。従って、人間が介在したこのような閉ループ制御系には、システム全体として複雑系（要素の変更により新しい性質や能力を生むシステムのことを指す）が形成される可能性が考えられる[4][5]。人間の手による台車上の倒立振子の安定化制御にはリミットサイクル的な挙動や不規則的な挙動が見られ、時系列実測波形についてエントロピー診断を行ったところ、無秩序さの多いことなどを前報で示した[4]–[10]。また、カオス性を示す尺度として算出した最大リアプノフ指数も正の値を示した。さらに、エントロピーの割合は、学習効果によってその値が変化し、学習によって無秩序さの程度が変わることを示した。さらに、不安定系制御対象の例として台車上の倒立振子を取り上げ、外乱にロバストな人間オペレータの巧みな操作を実測時系

列データからファジィ同定する方法について示した[7][11]–[20]。

本論文では、カオス的時系列データからのニューロ同定法がオペレータの技量と巧みさの獲得に有効であるかどうかを検討する。なお、本論文で安定化制御というのは、倒れないという意味の有限振幅の安定性である。

2. 人間オペレータによる安定化制御におけるカオス・複雑系診断の概要

2.1 オペレータによる倒立振子・台車系の安定化実験

図1は、実験装置と実験の様子を示す[5]–[7]。倒立振子の下端をシャフト及びミニチュア・ベアリングを使用して摩擦の少ない状態で支持している。台の上にリニアベアリング用のスライド・レールを固定し、倒立振子が傾くと、人間の手によりリニアベアリングに固定した台車を水平に移動させて、振子が倒れないように制御を行う。振子棒の傾斜角と台車の移動変位をポテンショメータにより検出し、AD変換器を通してパーソナルコンピュータに取り込む。データを取り込むときのサンプリング時間は0.0586[s]であり、60[s]制御したときに得られるデータ数は1024個である。カオス・複雑系診断を行う際には得られた実測データをスプライン補間してデータ数2047個、サンプリング時間 $\Delta t = 0.0293$ [s]として使用した。手で台車を移動させて倒立



Fig.1 Experimental situation

振子が倒れないように制御することは実験の初期には難しいが、練習により 60 s 間の制御が可能になる。本研究では、60 秒間の安定化制御にある程度習熟した各試行者（オペレータ）の 10 回の試行による時系列データを解析した [5]–[10] [20]。

2.2 エントロピーによる無秩序さの診断法[20]

個数 n の時系列データ (x_t) の最大値 ($x_{\max}$) と最小値 ($x_{\min}$) を求め、データの範囲が $x_{\min} \leq x_t \leq x_{\max}$ から、 $0 \leq b_t \leq 1$ となるように正規化する。次に、データ範囲 0 から 1 を N_c 個 (セル数) のセルに分割し、 n 個のデータ (b_t) が N_c 個のセルのどこに入るかを求め、各セルの確率 p_i を用いて、エントロピーを以下のように求める。

$$S = - \sum_{i=1}^{N_c} p_i \log p_i \quad (1)$$

これを本論文では、総エントロピーと定義し、総エントロピーの値を総エントロピーの最大値 $\log eN$ で割った値を総エントロピーの割合と呼ぶ [9] [16] [17]。このエントロピーは無秩序さあるいは不規則さの程度を表すとみなす [20]–[22]。

2.3. 最大リアプノフ指数によるカオス診断法[20]

最大リアプノフ指数が正のとき、系は初期値に鋭く依存するためカオス的な挙動を示すので、これをカオスの定義の一つとして用いる [25]–[28]。

測定された時系列データ $x(t)$ を用いて、遅れ時間を τ とする m 次元の再構成状態空間における m 次元ベクトルを式 (1) のように作成する。一般に遅れ時間 τ は解析する波形の主要周期の数の 1 にとればよいと言われている [22] [24]–[29]。実測波形より、人間の安定化制御における倒立振子の主要な周期はおおよそ 0.5–1.0 [s] であった。

本論文では次元数を多次元へと拡張するため、1 次写像を

$$x_{n+1} = f(x_n) \quad (2)$$

と置き、 n を便宜的に j に置き換え x_j で微分すると

$$\frac{df(x_j)}{dx_j} = \frac{dx_{j+1}}{dx_j} = \frac{x_{j+1} - x_j}{x_j - x_{j-1}} = f'(x_j) \quad (3)$$

と近似表現が可能となり、 m 次元、遅れ時間 τ のヤコビ行列の一般表現が可能となる [22]。グラム・シュミットの直交化法により直交ベクトル b_{ij} ($i = 1, 2, \dots, m$) が求まり、リアプ

ノフ指数 λ_i は、

$$\lambda_i = \frac{1}{t_n - t_0} \sum_{j=1}^{n-1} \log_e b_{ij} \quad (i = 1, 2, 3, \dots, m) \quad (4)$$

となる [21]–[29]。 n はデータ数、 t_0 、 t_n はそれぞれ時系列データの最初および最後の時刻である。

本論文では、埋め込み次元を 5–15 次元まで与えた。各時刻における最大リアプノフ指数は、ある程度時刻が経過するとほぼ一定値に落ちついた。各埋め込み次元における最後の時刻 t_n での値をその次元での最大リアプノフ指数とした。

3. 人間オペレータの実測時系列データを教師信号としたニューラルネットワークによる技量の学習

図 2 はニューラルネットワークの例であり、7 つの状態変数、すなわち、振子角度、振子角速度、振子角加速度、台車変位、台車速度、台車加速度、1 サンプル前の台車へ作用する力 $Ft-1$ を入力変数とし、中間層 4 個の場合を示している。出力は 1 サンプル後の台車への力 $Ft+1$ である。 W_{mn} は入力ユニットそれぞれから中間層 (4 個) へつながる結合係数、 V_n ($n=1 \sim 4$) は中間層と出力層の間の結合係数である。各ユニットの出力に応答関数として図 3 および式 (1) に示すシグモイド関数を用いた。

$$f(x) = 1 / \{1 + \exp(-2x/u_0)\} = \{1 + \tanh(x/u_0)\} / 2 \quad (1)$$

u_0 はシグモイドの傾き係数である。




Fig.3 Sigmoid functions

図 4 にニューラルネットワークによる学習のブロック線図を示す。人間による安定化制御実測値からなる各状態変数の値を 0–1 の数値に正規化し、教師信号




Fig.2 Multilayer feedforward neural network for identification

としては状態変数実測値から倒立振り・台車系の運動方程式を使って間接的に算出した力を正規化して与える。教師信号 $F_{t+1}(T)$ とニューラルネットワークからの出力 $F_{t+1}(N)$ の差を求め、バックプロパゲーション法によりその差が小さくなる様にネットワークに学習させる。バックプロパゲーション法として逐次修正法を用いた。ここでの学習パターンとは、実測値とそれに対応する教師信号である。1

つの学習パターンに対して教師信号とニューロ出力の差が許容誤差 10^{-5} に達するまで結合係数 W_{mn} , V_n , オフセット値 θ_n を繰り返し計算し、収束した値を次の時刻のデータの初期値とする。約 1000 個の時系列実測データについて繰り返し、これを 1 回の学習とし、1 回の学習後に制御シミュレーションを行い、うまく同定されていない場合はこの学習結果を初期値として 2 回目、3 回目と学習を繰り返す。結合係数に関する学習係数 α , オフセット値に関する学習係数 β を広範囲に変えて学習を試みた。

4. 時系列データの学習により生成したニューロ制御器による安定化制御シミュレーションと技量の獲得

4.1 安定化制御シミュレーションの方法

図 5 に、人間オペレータによる実測時系列データの学習により生成されたニューロ制御器を用いた安定化制御シミュレーションのブロック線図を示す。時刻 t における状態変数を倒立振り・台車系モデルに与え、ルンゲ・クッタ法により時刻 $t+1$ の状態変数を算出する。算出された状態変数をニューロ制御器に入力することにより次の時間に台車に加える力を算出する。以後、この計算を繰り返し倒立振り・台車系の安定化制御シミュレーションを行う。ニューロ制御器のサンプリング周期は、実測時系列データのサンプリング周期 $0.0586 [s]$ を用い、安定化の範囲は振り角度 $\pm 15 [deg]$, 台車変位 $\pm 2 [m]$ とした。初期値として、振り角度に 2 度を与え、それ以外は 0 としている。




Fig.4 Identification system for a human operator using a neural network




Fig.5 Block diagram of stabilizing control simulation with neural controller identified from human operator

4.2 技量の同定と学習係数

図 6 は、人間オペレータ NK の試行 1 回目 (NK01), 5 回目 (NK05), 10 回目 (NK10) およびオペレータ OT の試行 1 回目 (OT01), 5 回目 (OT05), 10 回目 (OT10) について、それぞれ実測時系列データを教師信号とする学習により生成したニューロ制御器を用いて 60 秒間のシミュレーションを行い、そのときの安定化制御持続時間(s)を高さとした等高線図を示す。シグモイドの傾きは $u_0 = 2.0$, 学習係数 $\alpha \cdot \beta$ はそれぞれ $1.0 \sim 20$ まで 1.0 刻みで設定した。試行回数を重ねた実測時系列データを用いてニューロ同定しても 60 秒間の安定化制御が可能な $\alpha \cdot \beta$ の範囲





Fig. 6 Contour map of stabilizing control duration [s] ($u_0=2.0$)



(NK01, $\alpha=5, \beta=7$, Learning repetitions: 20 times) (OT01, $\alpha=17, \beta=11$, Learning repetitions: 39 times)
Fig.7 Simulated results of stabilizing control of an inverted pendulum on a cart

が拡大するとは言えない。図6において60秒間の安定化制御に成功したシミュレーション波形は、ほとんどが図7のような収束的またはリミットサイクル的な波形を示した。

4.3 学習における修正回数と学習係数

1回目の学習における結合係数・オフセット値の総修正回数を高さにとった等高線図を描いてみると(図は省略)、60秒間の安定化制御に成功した学習係数 $\alpha \cdot \beta$ の組み合わせ(図6)と総修正回数の少ない学習係数 $\alpha \cdot \beta$ の組み合わせは必ずしも一致しているわけではない。すなわち、結合係数・オフセット値の収束が速いほど人間の技量をうまく同定できるとは限らない。人間NKの試行NK05, NK10, および人間OTの試行OT10では、学習係数 α がある程度大きい範囲では、60秒間の安定化制御に成功した範囲と総修正回数が20000~30000回の範囲の形が比較的似ている。人間OTの試行OT01では、総修正回数が50000~60000回の範囲の形と似ている。人間オペレータの実測時系列デ

ータごとに学習に必要な修正回数が異なっている。

4.4 ニューロ制御器の状態変数と結合係数

60秒間の安定化制御に成功したニューロ制御器の結合係数の値を調べると、人間オペレータNKの試行NK01の実測時系列データについて学習係数 $\alpha=10, \beta=10$ とし、30回の学習を行った場合、ニューロ制御器の出力に最も影響を与えるのは振り角度、その次が台車変位であることが推測できる。学習係数 $\alpha \cdot \beta$ の組み合わせが異なると、台車変位よりも台車速度の影響が大きい場合や、中間層のユニットごとに影響の大きい状態変数が異なる場合が見られた。しかし、ほとんどの場合、振り角度ユニット-中間層間の結合係数の値は他の結合係数にくらべて大きい。人間オペレータNKの試行NK01の学習により生成されたニューロ制御器は、振り角度を重視して安定化制御を行っていることになる。

5. ニューラルネットによる動きの個人差と巧みさの同定
人間NKの試行1回目(NK01)の実測時系列データについて、シグモイド関数の傾き u_0 を2.~5.まで1.刻みで変えてみた。学習係数 $\alpha \cdot \beta$ は1.~20.まで1.刻みで変えた。

図8は、シミュレーションにおける安定化制御持続時間[s]の等高線図である。 u_0 を大きくしてシグモイド関数の傾きを緩やかにしてゆくと、60秒間の制御が可能となる




Fig.8 Contour map of stabilizing control duration [s] ($u_0=2.0$) vs. sigmoid u_0 (NK01)




Fig.9 Simulated Wave forms vs. sigmoid u_0 (NK01)




Fig.10 Measured wave forms (NK01)

$\alpha \cdot \beta$ マップの範囲が狭くなっている。

図9は、図8の等高線図の中で60秒間の安定化制御に成功したシミュレーション波形の例である。 $u_0=4.0, 5.0$ におけるシミュレーション波形ではリミットサイクル的または収束的な波形のほかに、図9(c)と図9(d)のように図10の実測波形に似た不規則的な波形も得られた。

6. カオス診断・エントロピー診断

図11は、人間オペレータNKの試行1回目から10回目までの実測波形とシミュレーション波形のエントロピー診断結果である。試行回数が増すと、エントロピーが低下する傾向が見られる。また、シミュレーション波形から算出した最大リアプノフ指数もすべて正の値であり、カオス的挙動であることを示した。

図12は、最大リアプノフ指数の算出値から推定した推定次元数(運動の自由度)である。試行回数を重ねると推定

次元数が増す傾向があり、習熟度が増すと、運動の自由度が増すことをうかがわせる。詳細は別報に報告する。




Fig. 11 Entropy ratio vs. Trial number




Fig. 12 Estimated dimension (Degree of freedom) vs. Trial number

7. 結論

実測時系列データからのニューラルネットワークによる学習に基づくニューロ制御器を用いたシミュレーションは60秒間の倒立振子の安定化制御に成功し、カオス性や無秩序さを有することを示した。また、シグモイド関数の傾きを変えることにより、オペレータの実測時系列波形に似たシミュレーション波形を得た。ニューロ同定法は、不安定系を安定化するというオペレータの技量の獲得に有効であった。人間の巧みな技量が同定できれば、外乱にロバストな制御器を実現できる可能性がある。

参考文献

- [1] 井口, 人間-機械系, 情報科学講座(1970), 共立出版
- [2] 藤井・田口, システムと制御, 25-6 (1981), pp.328-335.
- [3] 伊藤・伊藤, 電気学会論文誌 C, 96-5 (1976), pp.109-115.
- [4] 井上, カオスと複雑系の科学, 日本実業出版社
- [5] 川副嘉彦, 日本機械学会・第2回運動と振動の制御シンポジウム講論集, No.910-52, pp.95-100. (1991)
- [6] 川副嘉彦, 日本機械学会・機械力学・計測制御講演論文集, (A), No.920-55 (1992), pp.1-6
- [7] Kawazoe Y (1992), Proc. of the First International Conf. on Motion and Vibration Control, pp.930-935.
- [8] Kawazoe Y & Ju DY (1994), Proc. 2nd International Conf. on Motion and Vibration Control, pp.645-650.
- [9] 川副嘉彦・太田智洋・田中健一・永井健一, 日本機械学会, 第5回運動と振動の制御シンポジウム講論集, No.97-31 (1997.11), pp.395-398.
- [10] Kawazoe Y, Ohta T, Tanaka K (2000), Proc. of ICMA2000-Human friendly mechatronics, pp.457-462.
- [11] 川副嘉彦, 日本機械学会論文集 51-461, (1985), pp.404-409.
- [12] 川副嘉彦, 日本機械学会論文集, 51-471, (1985), pp.2789-2795.
- [13] 川副嘉彦, 日本機械学会論文集, 56-523, (1990), pp.693-699.
- [14] Kawazoe Y (1999), Motion and vibration control in Mechatronics, Edited by Seto K, Mizuno T & Watanebe T, pp.133-138.
- [15] Kawazoe, Y., Proc. 6th Int. Symp. on Artificial Life & Robotics, (2001), pp.9-12.
- [16] Kawazoe, Y., J.Robotics & Mechatronics, 13-1. (2001), pp.23-29.
- [17] 川副嘉彦・橋本剣・太田智洋, 日本機械学会・機械力学・計測制御講演論文集, (B), No. 98-8 (1998), pp. 168-171.
- [18] 川副嘉彦, 日本機械学会・機械力学・計測制御講演論文集, (A), No. 99-7 (1999), pp. 251-254.
- [19] 川副嘉彦・松本仁, 第17回ファジィシステムシンポジウム論文集, 日本ファジィ学会, (2001. 9), pp. 715-718.
- [20] 川副嘉彦・松本仁, ファジィ推論による時系列データからの人間オペレータの技量獲得 (倒立振子の安定化制御における技量の個人差の同定), 第11回インテリジェント・システム・シンポジウム, 計測自動制御学会, (2001), pp.415-420.
- [21] Baker GL and Gollub JP (1996), Chaotic dynamics: an introduction, Cambridge University Press. 86-87.
- [22] Baierlein R (1971), Atoms and information theory, W.H.Freeman & Co., San Francisco, Chapter 3.
- [23] 下条隆嗣, カオス力学入門, 近代科学社, pp.86-95, pp.107-111.
- [24] Takens F (1981), Detecting strange attractors in turbulence, In Rand DA and Young LS (ed), Lecture Notes in Mathematics, Vol.898, Springer-Verlag, Berlin, 366-381.
- [25] Mane R (1981), On the dimension of the compact invariant sets of certain nonlinear maps. In Rand DA and Young LS (ed), *ibid*, Vol.898, Springer-Verlag, Berlin, 230-242.
- [26] Wolf A, Swift JB, Swinney HL, and Vastano JA (1985), Determining Lyapunov exponents from a time series, Physica, 16D, 285-317.
- [27] 合原一幸編, カオスセミナー, 海文堂, pp.51-53, p.150.
- [28] 長島弘幸・馬場良和, カオス入門, 培風館, pp.89
- [29] 小寺平治, 線形代数, 共立出版(株), p.94.