逐次学習型ニューラルネットによる 無人搬送車の操舵制御

正員 船 曳 繁 之 (岡山大)

准員 味 野 真 生 (岡山大)

A Steering Control of Automatic Guided Vehicles by Successive Learning Neural Network

Shigeyuki Funabiki, Member, Michio Mino, Associate (Okayama University)

In this paper, a steering control of automatic guided vehicles (AGVs) by a successive learning neural network is proposed. In the proposed control strategy, the learning procedure of the neural network is carried out in some trials. Then, the excellent steering control strategy can be established and the excellent results of the AGV traveling are obtained. At the first step, the teaching signal based on the PI control is proposed. The experiment in the steering control of the right and left turning is put into practice. Then, it is clarified that the excellent learning and the steering control of AGVs is realized by adjusting the coefficients in the teaching signal according to the degree of learning. The proposed strategy using the successive learning neural network is proved to be of much practical use for the steering control of AGVs.

キーワード：無人搬送車，逐次学習，ニューラルネットワーク，教師信号，PI制御

1. まえがき

最近の制御分野では，生体の神経回路を模擬したニューラルネットの学習が注目されている⁽¹⁾。ニューラルネットはニューロンの多重結合による非線形写像が可能となるため，非線形制御能力が期待される⁽²⁾。さらに，学習した知識間の補間能力を持ち，汎化能力も期待できる。このニューラルネットの学習能力を応用したものとして，文字認識，形状認識などの画像処理，音声認識，音声合成などの音声処理，ロボット制御などの運動制御などがある^{(3),(4)}。

産業分野ではFA (Factory Automation) 化が進み，生産工場における無人化が進んでいる。その手段として材料や製品などを各工程間で効率よく運搬する無人搬送車 (Automatic Guided Vehicle: AGV) ⁽⁵⁾が広く利用され，AGVの果たす役割が大きくなってきた。しかし，従来から用いられているPI制御は，調整方法，調整時間等の問題から必ずしも満足できる制御とは言えなくなっている。すでに筆者らは，感覚的な制御が可能なファジィ制御の適用を提案し，安定度の高い操舵制御を実現している⁽⁶⁾。しかし，ファジィ制御においてもスケーリングファクタの調整やルールの検討などから，PI制御と同様に調整が難しい面もある。また筆者らは，ファジィ制御による操舵結果を教師信号とするニューラルネットを用いたAGVの操舵制御法を提案した⁽⁷⁾。この制御法は教師信号として，予め

他の制御法によって良好な操舵制御結果を得ておく必要があり，実用的な制御法とは言えない。

そこで本論文では，リアルタイムに学習が可能な逐次学習型ニューラルネットを用いたAGVの操舵制御法を提案している^{(8),(9),(10)}。提案した制御法では，ニューラルネットは数回の試行により学習し，その結果良好な操舵制御を実現する。まず，試行を繰り返しながらリアルタイムで学習を行う場合のPI制御を考慮した教師信号について説明している。そして，製作したAGVを用いた左右旋回コースでの実験により，この制御法の有効性を検討している。さらに，教師信号中の定数を調整することにより，良好な学習が行われ，実用上十分な操舵制御が実現できることを明らかにしている。

2. AGVシステム

図1にAGVの概略図を示す。本AGVは，幅50mmのガイド磁気テープ（以下，コース）を検出するガイドセンサを車体前部に設置し，前輪1輪を操舵輪，後輪2輪を駆動輪とする3輪型である。ガイドセンサは，±50mmの検出範囲を持ち，±100mmを超えると検出範囲外信号によりコースからの離脱を検知することができる。表1に本AGVの車体仕様を示す。

図2にAGVの制御ブロック図を示す。同図に示すようにAGVの操舵制御系はガイドセンサ，コントローラ，ステアリングモータから構成されている。ガイドセンサから

図1 AGVの概略図
Fig. 1 Schematic diagram.

表1 車体仕様
Table 1 Specification of AGV.

Wheel base [m]	1.0
Tread [m]	0.6
Inertial mass of car body [kg]	80
Center of gravity (distance from front wheel) [m]	0.6
Distance from guide sensor to front wheel [m]	0.15

図2 AGVの制御ブロック図
Fig. 2 Control block diagram of AGV.

の信号である偏差（コースからのズレ）を用い、ステアリング操作量をコントローラ内のニューラルネットにより決定し、ステアリングモータへ出力する。そして、ステアリング操作量とポテンシオメータからの信号であるステアリング操舵角 θ との差が減少するように、ステアリングモータを位置制御する。

3. ニューラルネットによる操舵制御法

<3・1> ニューラルネットの構成 ここで用いる階層型ニューラルネットは、図3に示すように入力層、中間層、出力層の3層から成り、入力層ユニット数は2個、中間層ユニット数は3個、出力層ユニット数は1個である。入力変数がニューラルネットに入力されると、フォワードプロパゲーションにより出力層からステアリング操作量を出力する。そして、バックプロパゲーションにより教師信号 $T(n)$ とフォワードプロパゲーションの出力 $e(n)$ との二乗誤差が小さくなるよう、各ニューロン間の結合係数を逐次修正する。バックプロパゲーションにおける学習はモーメント法を用いており、学習係数は0.75、安定化係数は0.8である。サンプリング時間（制御周期）毎に偏差を検出し、バックプロパゲーションによる学習を行い、修正されたニューラルネットによるフォワードプロパゲーションで操作量を出力している。すなわち、サンプリング時間毎に一

図3 ニューラルネット
Fig.3 Neural network.

回、学習と操作量の出力を行っている。

ニューラルネットの二つの入力変数には偏差と偏差の和を用いているが、偏差よりも偏差の和の方がかなり大きい値となる。このため、ニューラルネットの出力が偏差よりも偏差の和の方に影響を受け易くなり、安定な制御を行うことができない。従って、入力変数のマッチングを取るために、偏差の和に係数 F_s を掛けてニューラルネットに入力する⁽¹⁰⁾。

<3・2> 教師信号 ニューラルネットの学習で問題になるのが教師信号であるが、これは以下のようにPI制御の考えに基づいて作成する。図4にPI制御のブロック図を示す。同図に示すようにPI制御では、指令値とフィードバック値との差に比例した修正量と差の積分値に比例した修正量の和を操作量としている。 n 回目のサンプリング時の差を $z(n)$ 、操作量を $e(n)$ とすると、PI制御の操作量は離散時間で表現すると次式になる。

$$e(n) = K_p \cdot z(n) + K_i \sum_{i=0}^n z(i) \quad \cdots(1)$$

ここで、 K_p 、 K_i はそれぞれ比例ゲイン、積分ゲインである。 $(n-1)$ 回目のサンプリングでは、

$$e(n-1) = K_p \cdot z(n-1) + K_i \sum_{i=0}^{n-1} z(i) \quad \cdots(2)$$

となり、(1)、(2)式より、

$$e(n) = e(n-1) + K_p \{z(n) - z(n-1)\} + K_i \cdot z(n) \quad \cdots(3)$$

を得る。PI制御では(3)式が操作量となる。これを考慮して教師信号を次式により作成する。

$$T(n) = e(n-1) + K_p \{z(n) - z(n-1)\} + K_i \cdot z(n) \quad \cdots(4)$$

ここで、 K_p 、 K_i は教師信号の修正量に関する定数である。(4)式で定義した教師信号は、 n 回目のニューラルネットの修正量を決定するものであり、 K_p 、 K_i の値が大きいくれ学習が速く進む。

図4 PI制御ブロック図
Fig. 4 Block diagram of PI control.

図5 実験システム
Fig. 5 Experimental system.

表2 実験条件
Table 2 Experimental conditions.

Traveling speed V [km/h]	3.6
Sampling time [ms]	10
Cornering radius of guide tape [m]	3.0
First straight [m]	2.0
Straight between right and left turning [m]	2.0
Last straight [m]	2.0

4. 実験システムと評価指標

<4・1> 実験システム 図5に実験システム構成を示す。同図に示すように、走行コントローラへ定速度前進指令を出力し、サンプリング時間毎に車体前部に固定されたガイドセンサによりコースとのズレ(偏差)を検出し、A/D変換器を通してパーソナルコンピュータPC9801NS/T(CPU:386SL(20MHz)+387SX)に取り込む。ガイドセンサで検出した偏差により、ニューラルネットで最適なステアリング操作量を決定し、それをステアリングモータコントローラへD/A変換器を介して出力する。さらに、サンプリング割込みが行われるまで、ステアリング部に設置したポテンショメータからのフィードバックにより、PI制御でステアリングモータの位置制御を行う。

表2に実験条件を示す。実験は平坦なアスファルト上で行い、コースは左右旋回で、旋回半径は3.0m、旋回と旋回間の直線は2.0mとした。走行速度は直線、旋回時ともに3.6km/hで、サンプリング時間(制御周期)は10msである。

<4・2> 評価指標 ニューラルネットの学習によりAGVの操舵制御を行うが、その際に試行成功の程度や学習進捗を示す指標が必要となる。そこで、制御結果、学習進捗の評価指標としてコース追従率 R_f とステア角変化の平均値 M_w を定義する。

コース追従率 R_f を次式で定義する。

$$R_f = \frac{D_a}{D_c} \quad \text{.....(5)}$$

ここで、 D_a はAGVが1回の試行で走行した距離、 D_c はA

GVがコースに完全に追従したときの試行1回当たりの走行距離である。 R_f はコースに完全に追従した場合には1より僅かに大きな値となるが、以下ではこの場合 R_f を1.0としている。また、全く追従できなかった場合には R_f はほぼ0となる。

次に、ステア角変化の平均値 M_w を次式で定義する。

$$M_w = \frac{S_w}{N_s} \quad \text{.....(6)}$$

ここで、 S_w はデータサンプリング時間30ms毎のステア角変化の絶対値の和、 N_s はデータサンプリング回数である。AGVがコースに追従しているとき、操舵が安定であるためにはステアリングの振動が少ない方がよく、 M_w はなるべく小さい値となるのがよい。すなわち、 M_w がある一定値より大きくなるとステアリングが振動しているとみなせ、良好な操舵制御が達成できていないと考えられる。

5. 実験結果

<5・1> ニューラルネット入力係数 ニューラルネットの入力に偏差と偏差の和を用いているが、偏差の和に掛けている係数 F_s の値について検討する。

表3に示すように F_s が0.01, 0.05, 0.1, 0.2の場合について、表2の条件で実験を行った。 K_p , K_i の初期設定値が大きいと試行は成功することが無く、また小さいと試行が成功するまでの試行回数は非常に多くなる。ここでは、早く試行が成功する K_p , K_i の初期設定値として、実験より0.005に決定した。表3に示すように、教師信号定数はあ

表3 教師信号定数
Table 3 Constants in teaching signal.

F_s	Num. of trials	K_p	K_i
0.01	1~2	0.005	0.005
	3~12	0.001	0.001
0.05	1~2	0.005	0.005
	3~6	0.001	0.001
0.1	1~2	0.005	0.005
	3~6	0.001	0.001
0.2	1~3	0.005	0.005
	4~10	0.001	0.001

図6 F_s に対するコース追従率
Fig. 6 Course following rate vs. F_s .

表4 教師信号定数
Table 4 Constants in teaching signal.

$R_K (=K_p/K_f)$	Num. of trials	K_p	K_f
0.1	1	0.0005	0.005
	2~7	0.0001	0.001
1	1~2	0.005	0.005
	3~6	0.001	0.001
10	1~4	0.05	0.005
	5~10	0.01	0.001
100	1	0.5	0.005
	2~13	0.1	0.001

図7 R_K に対するコース追従率
Table 4 Course following rate vs. R_K

る程度学習が進むと K_p , K_f を初期設定値の1/5倍にしている。以上の条件で行った実験でのコース追従率 R_f を図6に示す。 F_s が0.01のとき R_f は0.6程度まで上がっているが、1.0にはならずコースに追従できていない。同様に、 F_s が0.2のときも R_f は0.5程度まで上がっているが、1.0にはならずコースに追従できていない。一方、 F_s が0.05と0.1のときには、試行回数5回目、4回目で R_f は1.0となり、コースに追従できている。すなわち、 F_s は大きすぎても小さすぎても良くなく、適当な値に選び、二つの入力のマッチングをとる必要がある。図6の結果より、以下の実験では F_s の値を0.1とする。

<5・2> 教師信号定数 ここでは、教師信号定数について検討する。教師信号定数が大きいほど学習は速く進むが、試行の成功する確率が低くなる。一方、教師信号定数が小さいと試行の成功する確率は高くなるが、成功までに時間が掛かる。また、 K_p , K_f それぞれの値の大きさも学習の速さに影響する。

表4に示す $R_K (=K_p/K_f)$ が0.1, 1, 10, 100の場合について、表2の条件で実験を行った。 K_f は最初0.005とし、

表5 教師信号定数
Table 5 Constants in teaching signal.

K_p, K_f	Num. of trials	K_p	K_f
constant	1~12	0.001	0.001
change	1~9	0.001	0.001
	10~12	0.0002	0.0002
	13~14	0	0

図8 左右旋回実験結果
Fig. 8 Experimental results of right and left turning.

(a) 教師信号定数一定

(b) 教師信号定数変化

図9 コース追従率とステア角変化の平均値

Fig. 9 Course following rate and average value of steering angle.

ある程度学習が進むと1/5倍にしている。以上の条件で行った実験でのコース追従率 R_f を図7に示す。 R_f が10の場合は試行が成功するまでに時間が掛かっており、 R_f が100の場合には安定な学習ができていない。一方、 R_f が0.1, 1の場合には、4回目で試行が成功しており、速い学習が実現できている。そして、 R_f が1の場合の成功回数が多いことより、以下の実験では R_f の値として1を用いる。

<5・3> 操舵制御結果 教師信号定数は大きい方が学習が速く進むが、大きいと学習過剰となり試行が成功した後に再び失敗する。そこで、学習進度に応じてこの定数を小さくする必要がある。

ここでは、教師信号定数を変えずに一定で学習した場合と学習進度に応じて教師信号定数を変えた場合の実験について比較検討する。表5に試行回数に対する教師信号定数を示す。ここでは、確実な学習を行うために初期値は0.001とした。すなわち、試行が成功するまでの試行1~10回は両者ともに同じ教師信号定数で学習し、教師信号定数を変えない場合には、試行成功後もそのまま学習を続ける。教師信号定数を変える場合には、試行成功後に教師信号定数を1/5倍と小さくし、さらに試行13回目以降は K_p , K_f を0として、学習を止めている。

図8に表5の条件での左右旋回実験結果を示す。同図(a)は試行10回目の実験結果、図(b)は教師信号定数を変えないで学習を続けた試行12回目の実験結果、図(c)は教師信号定数を変えて学習を続けた試行14回目の実験結果を示して

(a) 試行10回目

(b) 試行12回目 (教師信号定数一定)

(c) 試行14回目 (教師信号定数変化)

図10 ニューラルネットの入出力関係

Fig. 10 Input-output relationship of neural network.

いる。同図(b)より、教師信号定数を変えずに学習を続けると、学習が進みすぎてステア角変化が大きく振動的になり、最後のコーナ脱出時にAGVはコースから離脱している。一方、教師信号定数を学習進度に応じて変えて学習を行うと、良好な操舵制御が実現できている。これは、図9に示すコース追従率 R_f とステア角変化の平均値 M_w からも分かる。すなわち、同図(a)では試行12回目に M_w が大きくなり、 R_f が1.0とならず下がっている。一方、同図(b)では試行が成功した10回目以降、 M_w はほぼ一定の小さな値となり、 R_f も1.0でありコースに良く追従できている。これは、教師信号定数を一定にして学習を続けると、ニューラルネットのゲインが大きくなり、小さな外乱にも敏感になりすぎるためと考えられる。

次に、図8(a), (b), (c)のときのニューラルネットの入出力関係を図10に示す。試行が成功した同図(a), (c)のニューラルネットの入出力関係は、偏差の和の入力に対して非線形で飽和特性を持っている。同図(b)では学習の行き過ぎにより、試行が成功した同図(a)の場合と比較し、 z に対するゲインが高くなっており、入出力平面の傾きが全く異なっている。従って、小さな偏差にも出力が大きく変化するため、ステアリングに振動が現われ、試行は失敗している。一方同図(c)では、同図(a)と同様の入出力関係となっており、学習が収束していることが分かる。以上より、教師信号定数を学習進度に応じて変えることにより確実な学習が行われ、安定した操舵制御ができることが明らかとなった。

6. ま と め

逐次学習型ニューラルネットによるAGVの操舵制御法を提案した。左右旋回コースでの操舵制御実験を行い、ニューラルネットの入力係数、教師信号定数について検討した。本論文を要約すると、以下の通りである。

- (1)PI制御の考え方に基づいて教師信号を作成し、これを用いてリアルタイムで学習を行う逐次学習型ニューラルネットによるAGV操舵制御法を提案した。
- (2)ニューラルネットの入力変数のマッチングをとるための係数について検討し、0.1辺りの値を用いれば試行も成功し、速い学習ができる。
- (3)教師信号定数の比について検討し、 R_k を1辺りの値を選べば速く安定な学習ができる。
- (4)教師信号中の定数を一定として学習を行うと、試行成功後に学習過剰で制御ゲインが大きくなり、ステアリングが振動して操舵制御が失敗する。
- (5)教師信号中の定数を学習進度に伴って調整することにより、安定な学習ができ、コースに滑らかに追従させることが可能である。

以上のように、自己学習により数回の試行でAGVの安定な操舵制御法が実現できた。本論文では、教師信号中の定数を学習進度に従ってオペレータが調整したが、これを自動で調整することが望まれる。これについては現在検討

中であり、別の機会に報告する予定である。

(平成6年3月30日受付)

文 献

- (1) 合原：ニューラルコンピュータ，(平元) 東京電機大学出版局
- (2) 藪田：「ニューラルネットワークの制御への応用」，平5電気学会全大，S.4-2
- (3) 佐藤，小杉：「ニューロおよびファジィ技術の応用 II. 1 ニューラルネットワークのパターン認識への応用」，電学誌，111，14～16 (平3-1)
- (4) 大松：「ニューラルネットワークによる適応制御」，電学誌，112，503～506 (平4-7)
- (5) 「無人搬送システム」，神鋼電機技報，34，25～27 (平元-2)
- (6) 船曳，妹尾：「ファジィ推論による無人搬送車の操舵系制御」，電学論D，112，959～965 (平4-10)
- (7) 船曳，味野：「ニューラルネットによる無人搬送車の操舵制御」，電学論D，113，1363～1370 (平5-12)
- (8) 味野，船曳：「逐次学習型ニューラルネットによる無人搬送車の操舵制御」，平4電気・情報関連学会中国支部連大，090417
- (9) 味野，船曳：「逐次学習型ニューラルネットによる無人搬送車の操舵制御(2)」，平5電気学会産業応用部門全大，190
- (10) 味野，中塚，船曳：「逐次学習型ニューラルネットによる無人搬送車の操舵制御(3)」，平5電気・情報関係学会中国支部連大，010404

船 曳 繁 之 (正員) 昭和54年3月岡山大学大学院修士課

程修了。同大学助手，講師を経て，現在，同電気電子工学科助教授。工学博士。パワーエレクトロニクス，ニューラルネット，ファジィ制御の応用などの研究に従事。IEEE，計測自動制御学会，システム制御情報学会，パワーエレクトロニクス研究会会員。

味 野 真 生 (准員) 昭和44年4月生。平成6年3月岡山

大学大学院修士課程修了。同年4月三井造船(株)入社，現在に至る。大学院でニューラルネットによる無人搬送車の走行制御に関する研究に従事。