

# ニューラルコンピュータ用基本素子連続時間 Folthretを用いた学習自動車の基礎的検討

(平成6年11月24日 原稿受付)

北九州高専 電子制御工学科 吉 野 慶 一  
九工大 電気工学科 横 井 博 一

## A Primary Study of Learning Car Using Continuous Time Folthret as Fundamental Element for Neural Computer

by Keiichi Yoshino  
Hirokazu Yokoi

In this paper the term "learning car" is used to denote an automobile featuring an automatic driving operation capability based on the learning function of a neural computer. For this use, continuous time Folthret is newly proposed as a fundamental element for a neural computer, and was implemented electronically. A neural computer with a single output was constructed from such implemented Folthret and mounted in an electric car, thereby converting it to a learning car. A driving experiment was then conducted by using the learning car and its autonomous driving performance was examined. The experimental results confirm that the neural computer is capable of learning the driver's steering operations after some 10 trials, thereby demonstrating the efficiency of a neural computer with a single analog output constructed from continuous time Folthret for the automated steering operation.

### 1. まえがき

自動車による交通事故の原因のほとんどは人的過誤である。そのため、交通事故を大幅に減らすには、運転操作を人間より信頼性が高くかつ性能の優れた機械に代行させること、すなわち運転の自動化がどうしても必要になる。このための具体的方法としては、交通管制センタからの一局集中方式の運転管理が以前から考えられているが、これは自動車を電磁波や超音波により外部操作するので、自動車の最大の特長である自由性が失われる。そこで、ノイマン型コンピュータを組み込んで高度な判断能力を持たせた、自律走行可能なインテリジェント自動車が盛んに研究されるようになった。しかし、ノイマン型コンピュータはプログラム内蔵方式で、あらかじめ処理のアルゴリズムがわかっているなければならない、運転操作のような複雑な情報処理には向かない。また、プログラムによる決まった処理しかできないため、プログラムの中で想定されていない状況には対応できない。

これに対して、ニューラルコンピュータは学習機能と汎化機能を持っており、ニューラルコンピュータを自動

車に組み込めば、人間の運転操作を学習することにより運転の自動化を可能とし、また十分に学習を積み上げれば、学習期間に出会っていない環境や状況に対しても妥当な運転が行えるようになるものと期待される。従って、自動車の運転の自動化には、交通管制センタによる一局集中管理方式やノイマン型コンピュータによる自律走行方式も確かに有効な面はあるが、今後はニューラルコンピュータの利用が是非とも必要になる。ここでは、ニューラルコンピュータが人間の運転操作を学習する自動車のことを学習自動車<sup>(1)-(4)</sup>と呼ぶことにする。

但し、学習自動車と類似の研究は、われわれとは独立に Cheng ら<sup>(5)</sup> や Pomerleau<sup>(6), (7)</sup> によって既に着手されている。しかし、Cheng らの場合、ニューラルコンピュータは人間の運転操作を学習するのではなく、トラッキングエラーが小さくなるように学習を行うため、トラックに沿って走行する場合にしか使えない。Pomerleau の場合は、ニューラルコンピュータが人間の舵取操作を学習する方式を用いているが、自律走行時での走行方向はニューラルコンピュータの45個の出力により決定され、大変効率が悪い。

ところで、ニューラルコンピュータの特徴を最大限に生かすためには、本当の意味の並列演算を行う専用ハードウェアが必要になる。しかし、ニューラルコンピュータを電子回路によりその構造通りに実現しようとする、配線の複雑化という問題が発生する。デジタル回路を用いた場合には、回路の複雑化という問題が更に加わる<sup>(8)</sup>。筆者の一人は、これらの問題を解決するため、ベクトルの各成分をフーリエ係数とするフーリエ級数信号<sup>(9) - (12)</sup>を用いたアナログ方式のニューラルコンピュータ用基本素子 Folthret (Fourier series-type learning threshold element)<sup>(13) - (15)</sup>を提案した。Folthret は、1) 入力線が2本で済む、2) 入力荷重和の計算や結合荷重の変更が簡単に行える、3) どのような複雑な回路網構造を持ったニューラルコンピュータも簡単な配線で実現できる等の特徴を持っている。

その後、配線の複雑化の一つの解決法として、ベクトルの各成分を周波数領域ではなく時間領域に割り当てることによる、ベクトルを1本の信号線上に乗せて処理を行う時分割多重方式のニューラルコンピュータが現れてきた<sup>(16) - (18)</sup>。これは、各素子にパルスあるいはパルス列が時分割で順々に入力されるので、学習機能を持たせようとする、入力信号を結合荷重の非変更時と変更時に2度与えなければならない。また、混合型回路網を実現する場合には、入力信号を時間軸上で選択しなければならず、制御が面倒になる。入力信号を選択し易くするためにアドレスを用いれば、制御は簡単になるが、その代わり配線が複雑化するし、結合荷重用メモリの容量を大きくしなければならない。更に、デジタルパルスを用いたときには、信号線は実際には1本ではなく、ビット数分だけ複数本並列に並べた形になり、配線はやや複雑になる。アナログパルスを用いたときには、インパルス性雑音に対し Folthret よりも影響を受け易い。

以上述べたように、Folthret はニューラルコンピュータをハードウェア化する上でいくつかの有利な点を持っており、時分割多重方式と比べても優れた点がある。ただ、この Folthret は離散時間型であり、学習自動車に用いるためには、連続時間型が望ましい。

そこで本論文では、先ず連続時間 Folthret を新たに提案し、これを電子回路化する。次に、電子回路化した連続時間 Folthret を用いてニューラルコンピュータを構成し、これを一人乗りの電気自動車に搭載して学習自動車を製作する。但し、ニューラルコンピュータの出力は1個で、自律走行時にはこの出力のみで舵取操作を行わせる。最後に、製作した学習自動車で行走実験を行う。すなわち、ニューラルコンピュータに運転者の舵取操作を

学習させ、学習後に自律走行性能を走行経路によって調べ、連続時間 Folthret で構成した1個のアナログ出力のみを持つニューラルコンピュータの舵取操作の自動化に対する有効性を検討する。

## 2. 連続時間 Folthret

### 2.1 連続時間学習しきい素子

連続時間 Folthret は、図1に示す  $n+1$  入力の連続時間学習しきい素子を元に構成される。但し、連続時間で変化するのは入力信号  $x_i (i=1, 2, \dots, n)$ 、出力信号  $z$ 、教師信号  $y$  だけで、結合荷重  $w_i (i=1, 2, \dots, n+1)$  については学習期間に離散時間で変化する。 $\tau$  は離散時間で、 $0, 1, 2, \dots$  の整数値をとり、 $w_i^{(\tau-1)}$  が  $w_i^{(\tau)}$  に切り替えられる時刻を連続時間で表したものを  $\lambda^{(\tau)}$  とする。 $\lambda^{(0)}$  は0である。入力信号、出力信号、教師信号はすべて非負である。 $x_{n+1}$  は特別な入力信号で、常時1か常時0のいずれかである。しきい値  $h$  は固定である。




図1 連続時間学習しきい素子

入出力関係は、(1)式に示す入力荷重和  $u(t)$  を用いると、(3)式のように表される。従って、この素子は、 $x_{n+1}$  が0の場合にはしきい値が  $h$ 、 $x_{n+1}$  が1の場合にはしきい値が  $h - w_{n+1}^{(\tau)}$  の  $n$  入力連続時間型学習しきい素子と等価になる。

$$u(t) = \sum_{i=1}^n w_i^{(\tau)} x_i(t) + w_{n+1}^{(\tau)} x_{n+1} \quad (1)$$

$$(t \geq 0; \tau = 0, 1, \dots)$$

$$\mu \frac{d}{dt} s(t) = -s(t) + u(t) - h \quad (2)$$

$$z(t) = f(s(t)) \quad (3)$$

$$(t \geq 0)$$

ここで、 $f(\cdot)$  は出力関数、 $g(\cdot)$  は  $u$  を独立変数、 $z$  を従属変数としたときの出力関数である。出力関数  $f(\cdot)$  としては、離散情報型では単位ステップ関数、連続情報型ではランプ関数、区分線形関数、ロジスティック

ク関数等が用いられる。

結合荷重  $w_i^{(\tau)}$  ( $i=1, 2, \dots, n$ ) の変更は,  $\lambda^{(\tau)}$  から  $\lambda_i^{(\tau+1)}$  までの間の時刻  $\alpha^{(\tau)}$  において, (4) 式のようになされる。 $w_{n+1}^{(\tau)}$  については (5) 式のように変更されるが, これは実質的には  $x_{n+1}$  が 1 のときにだけ起きる。この場合, 等価な  $n$  入力連続時間学習しきい素子で考えると,  $w_{n+1}^{(\tau)}$  の変更はしきい値の変更を実現することになる。

$$w_i^{(\tau+1)} = aw_i^{(\tau)} + cr(\alpha^{(\tau)})x_i(\alpha^{(\tau)}) \quad (4)$$

$$(i=1, 2, \dots, n; \tau=0, 1, \dots)$$

$$w_{n+1}^{(\tau+1)} = aw_{n+1}^{(\tau)} + cr(\alpha^{(\tau)})x_{n+1} \quad (5)$$

$$(\tau=0, 1, \dots)$$

ここで,  $a$  は減衰定数で, 0 から 1 までの実数値をとる。 $c$  は学習定数,  $r$  は学習信号である。 $r$  は学習期間中は, 表 1 に示すように, 学習法の種類によってそれぞれ異

表 1 学習法と学習信号

学習法の種類	学習信号 $r(t)$ の計算式
Hebb 学習法	$z(t)$
膜電位学習法	$u(t)$
相関学習法	$y(t)$
誤り訂正学習法	$y(t) - z(t)$
直交学習法	$y(t) - u(t)$

なった形の計算式で与えられ, 学習期間後は常に 0 となる。但し, この表にあげてある学習法は, どれも離散情報型と連続情報型の両方に適用できるものとする。また, 誤り訂正学習法ではしきい値も変更するので, その場合  $x_{n+1}$  を 1, そのほかの学習法ではしきい値は固定であるので,  $x_{n+1}$  を 0 とする。なお, 図 1 では省略してあるが, 階層型回路網では誤差逆伝播学習法が特に有効である。

## 2.2 原理

連続時間 Folthret は, 以上述べた連続時間学習しきい素子をフーリエ級数信号により実現したニューラルコンピュータ用基本素子で, 七つの部分から構成される。但し, 誤差逆伝播学習法を適用する場合には, Folthret の回路構成がその他の学習法の場合とかなり異なるので, 本論文では誤差逆伝播学習法を除いた学習法のみを考える。

入力荷重和計算部は, (5) 式と (6) 式に示すフーリエ級数信号  $F_x(t)$ ,  $F_w(t)$  を乗算し, これを低域フィルタ

に通す。その結果, (7) 式のように  $U(t)$  が求められる。このとき, 低域フィルタの時定数  $\mu$  がフーリエ級数信号の周期  $T$  よりも相当長く, 入力信号に変化が認められるまでの時間に比べて短ければ,  $U(t)$  は近似的に  $u(t)$  に等しくなる。

$$F_x(t) = \sum_{i=1}^{n+1} x_i(t) \sin\left(\left[\frac{k+i}{2}\right]\omega t + \sigma_A \frac{\pi}{2}\right) \quad (t \geq 0) \quad (5)$$

$$F_w(t) = \sum_{i=1}^{n+1} w_i^{(\tau)} \sin\left(\left[\frac{k+i}{2}\right]\omega t + \sigma_A \frac{\pi}{2}\right) \quad (t \geq 0; \tau = 0, 1, \dots) \quad (6)$$

$$A = k + i - 1$$

$$\sigma_A = \begin{cases} 0 : A \text{ が奇数} \\ 1 : A \text{ が偶数} \end{cases}$$

$$s(t) = \frac{2}{\mu} \exp\left(-\frac{t}{\mu}\right) \int_0^t \{F_w(t')F_x(t') - h\} \exp\left(\frac{t'}{\mu}\right) dt' \quad (t \geq 0) \quad (7)$$

ここで,  $k$  は任意の自然数,  $[\ ]$  はガウス記号である。 $\omega$  はフーリエ級数信号の基本角周波数である。 $\lambda^{(\tau)}$  ( $\tau = 0, 1, \dots$ ) は周期  $T$  の整数倍とする。

出力関数実現部は出力関数  $g(\cdot)$  を実現する部分で,  $u(t)$  を  $z(t)$  に変換する。出力変換部は,  $z(t)$  を (8) 式のように  $P(t)$  に変換する。 $P(t)$  は,  $F_x(t)$  の一部として他の連続時間 Folthret に入力される。

$$P(t) = z(t)\zeta(t) \quad (t \geq 0) \quad (8)$$

ここで,  $\zeta(t)$  は交流信号で, ニューラルコンピュータを構成する回路網を相互結合型や階層型とする場合には振幅 1 の正弦波信号, 混合型とする場合には一般に係数がすべて 1 のフーリエ級数信号となる。

教師信号計算部は, 各連続時間 Folthret の教師信号をフーリエ係数としたフーリエ級数信号  $F_v(t)$  を振幅 1 の正弦波信号  $\xi(t)$  と乗算し, これを低域フィルタに通す。その結果, (9) 式に示す  $Y(t)$  が求められる。このとき, 低域フィルタの時定数  $\nu$  がフーリエ級数信号の周期  $T$  よりも相当長く, 教師信号に変化が認められるまでの時間に比べて短ければ,  $Y(t)$  は近似的に  $y(t)$  に等しくなる。

$$Y(t) = \frac{2}{\nu} \exp\left(-\frac{t}{\nu}\right) \int_0^t \xi(t')F_v(t') \exp\left(\frac{t'}{\nu}\right) dt' \quad (9)$$

$$\doteq y(t) \quad (t \geq 0)$$

学習信号計算部は、 $u(t)$ ,  $z(t)$ ,  $y(t)$  に基づいて学習信号  $r(t)$  を求める。結合荷重変更部は、この  $r(t)$  を用いて (10) 式のように  $F_w(t)$  を変更することにより、(3) 式と (4) 式に示す  $n + 1$  個の結合荷重の変更を一度に実現する。但し、 $s^{(\tau)}$  は  $\lambda^{(\tau+1)} - T$  とし、 $r(t)$  と  $x(t)$  の時間的な変化はフーリエ級数信号に比べて緩やかであるとする。

$$\Phi_w(t) = aF_w(t) + cr(t)F_x(t) \quad (10)$$

$$(\lambda^{(\tau+1)} - T \leq t < \lambda^{(\tau+1)})$$

結合荷重用メモリ部は1周期分の信号を保持する2個のメモリが並列に接続され、一方のメモリから  $F_w(t)$  が時刻  $\lambda^{(\tau)}$  から  $\lambda^{(\tau+1)}$  までの間繰り返し読み出されると、他方のメモリには  $\Phi_w(t)$  が時刻  $\lambda^{(\tau+1)} - T$  から  $\lambda^{(\tau+1)}$  までの間1周期分だけ書き込まれる。書き込みが完了すると、読み出しと書き込みの役割が逆転し、 $\Phi_w(t)$  が次の1単位時間の間繰り返し読み出され、 $F_w(t)$  として使用される。学習期間中二つのメモリの役割はこのように交互に切り替わるが、学習期間後は切り替えは行われず、一つのメモリ内の信号が常に読み出される。

以上述べた連続時間 Folthret では、2本の入力線を通して  $F_x(t)$ ,  $F_y(t)$  が入力され、2本の出力線を通して  $z(t)$  と  $P(t)$  が出力される。従って、回路網を実現するときには、離散時間 Folthret の場合と同様、 $F_x(t)$  を伝送する  $X$  信号線と  $F_y(t)$  を伝送する  $Y$  信号線に沿って連続時間 Folthret を1列に並べ、 $F_x(t)$  用入力線と  $P(t)$  用出力線を  $X$  信号線に接続し、 $F_y(t)$  用入力線を  $Y$  信号線に接続する。

### 3. 電子回路化

#### 3.1 方法

連続時間 Folthret の電子回路化において、減衰定数  $a$  は1、しきい値  $h$  は0、出力関数  $g(\cdot)$  はランプ関数、

学習法は誤り訂正学習法とする。また、電子回路化した場合にはドリフト等の問題が生じるので、教師信号と出力信号の差の絶対値が  $\varepsilon$  以下のときは学習信号を0とする。すなわち、学習信号を (11) 式のように与える。

$$r(t) = \phi_0(y(t) - z(t)) \quad (11)$$

$$(t \geq 0)$$

$$\phi_0(\theta) = \begin{cases} \theta & (\theta < -\varepsilon, \varepsilon < \theta) \\ 0 & (-\varepsilon \leq \theta \leq \varepsilon) \end{cases}$$

図2は連続時間 Folthret の電子回路化の方法を示す。図の中の LPF は低域フィルタである。メモリについては、適当なアナログメモリが現在のところまだ開発されていないので、デジタルメモリを用いる。そのため、A/D変換器とD/A変換器が必要になる。これらの変換器は標準化周波数が4MHz、量子化ビット数が8ビット、RAMとROMは8ビットで、容量が4キロバイトとする。従って、各メモリには0.001s分のデータが保持される。そこで、信号の1周期分がメモリに保持されるようにするため、フーリエ級数信号の基本周波数および正弦波信号の周波数を1kHzにする。なお、 $F_x(t)$  と  $F_w(t)$ ,  $F_y(t)$  と  $\xi(t)$  それぞれにおいて同じ周波数の成分を同位相にするため、メモリに書き込まれたデータを同じタイミングでD/A変換する。

入力荷重和計算部は、乗算器と低域フィルタで構成する。低域フィルタには演算増幅器を用い、その時定数はフーリエ級数信号の周期0.001sの10倍すなわち、0.01sとする。

出力関数実現部は、出力関数がランプ関数であるため、ダイオードと演算増幅器により構成する。すなわち、この部分は理想ダイオード回路である。出力変換部は、ROM、D/A変換器、乗算器で構成する。ROMの中には振幅1の正弦波信号  $\zeta(t)$  が保持される。

教師信号計算部は、ROM、D/A変換器、乗算器およ

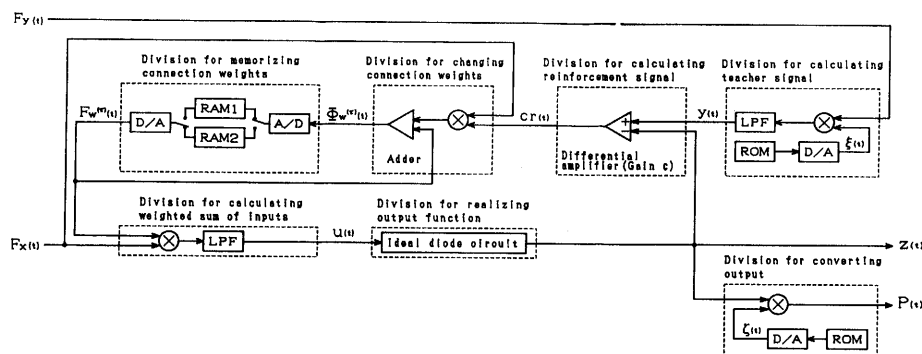


図2 連続時間 Folthret の電子回路化の方法

び低域フィルタで構成する。ROMの中には振幅1の正弦波信号 $\xi(t)$ が保持される。低域フィルタは、入力荷重和計算部で用いるのものと全く同じものを用いる。

学習信号計算部は、誤り訂正学習法の適用を考えているので、差動増幅器を用い、教師信号 $y(t)$ と出力信号 $z(t)$ の差を学習信号 $r(t)$ として出力する。但し、差動増幅器の電圧利得は自由に変えることができるので、これを $c$ として $cr(t)$ を出力させることにする。この場合、 $c\xi$ の電圧値を0.1Vとし、 $cr(t)$ の電圧値の絶対値がこの値以下であれば0が出力されるように、差動増幅器を2個用いて窓比較器とする。

結合荷重変更部は乗算器と加算器で構成する。乗算器では、 $F_x(t)$ と学習信号計算部の出力 $cr(t)$ との積を求める。加算器では、 $F_w(t)$ と乗算器の出力 $cr(t)F_x(t)$ を加算して、 $F_w(t) + cr(t)F_x(t)$ を出力する。

結合荷重用メモリ部は、A/D変換器、D/A変換器および2個のRAMで構成する。2個のRAMのうち的一方は読み出し用、他方は書き込み用である。学習期間においては、これらの役割はタイミングパルスにより切り替わる。タイミングパルスは時刻 $\lambda^{(\tau)}$  ( $\tau=1, 2, \dots$ )で発生し、1単位時間はフーリエ級数信号の周期の1000倍すなわち1sとする。非学習期間においてはタイミングパルスは発生せず、切り替えは行われない。なお、結合荷重用メモリから読み出されるフーリエ級数信号には、A/D変換器や加算器等が原因で位相遅れが生じる。そのため、少し位相を進めて読み出す。

### 3.2 結果

以上述べた方法に従い、アナログ回路とデジタル回路の両方を用いて連続時間 Folthret の電子回路化を行った。出力変換部は乗算型D/A変換器を用いたので、乗算器は使用しなかった。入力荷重和計算部、教師信号計算部、結合荷重変更部については、フーリエ級数信号を扱うので、周波数特性のあまり良くない乗算型D/A変換器は用いず、周波数帯域幅がDC~1MHz、誤差が2%以下、温度ドリフトが0.04%/°C以内のアナログの乗算器用ICを用いた。差動増幅器と加算器は演算増幅器と抵抗で構成した。電子回路化において用いた演算増幅器はすべて同じもので、周波数帯域幅がDC~100kHz、S/Nが60dB以上である。

使用したICの数はアナログとデジタル両方合わせて43個となった。基板は23cm×16cmの大きさのものを使用した。メモリ関係の部品が基板の約2/3を占有した。これはデジタルメモリを使用したためと、A/D変換器やD/A変換器が必要になったためである。図3は電子回路化した連続時間 Folthret である。




図3 電子回路化した連続時間 Folthret

### 3.3 考察

電子回路化した連続時間 Folthret において使用可能な入力信号の数は、主として周波数特性とS/Nにより制限される。電子回路化に用いた回路部品の中では演算増幅器の高域遮断周波数が一番低く、100kHzである。各回路部品のS/Nが十分高いとすれば、フーリエ級数信号の基本周波数が1kHzの場合、使用可能な入力信号の数は最大200と推定される。従って、今後この数を更に大きくするには、高域遮断周波数とS/Nがより高い回路部品を用いることが必要になる。

処理速度は、原理的にはフーリエ級数信号の基本周波数が高いほど上がる。しかし、各回路部品には動作時間や周波数特性があり、これらにより処理速度は制限される。従って、動作時間がもっと短く、高域遮断周波数がより高い回路部品を用いることが、処理速度を上げるために先ず必要になる。

学習能力は、 $F_w(t)$ に混入した雑音とその低下を引き起こすので、主としてS/Nにより制限される。電子回路化に用いた回路部品の中でS/Nが最も低いのはA/D変換器とD/A変換器である。これは量子化ビット数が8ビットと小さいためである。従って、量子化ビット数のより大きなA/D変換器とD/A変換器を用いれば、学習能力の低下が抑えられるであろう。

回路規模は、部品自体の大きさや部品数によって決まるが、現段階ではデジタルメモリを使わざるを得なかったため、少し大きなものになった。回路の小規模化にはアナログメモリの使用がどうしても必要になってくる。CCDは離散時間ではあるがアナログ値を直接記憶できるので、遅延回路用CCDの記憶容量を更に大きくし、転送部をループにする等の変更を行えば、連続時間 Folthret のメモリとして有効であろう。

## 4. 学習自動車

### 4.1 原理

人間が一人乗車できる学習自動車を連続時間Folthretを用いて製作する。但し、簡単のため運転操作は始動操作、舵取操作および停止操作の三つだけとし、始動操作と停止操作は人間が行う。舵取操作は、学習期間においては人間が行い、ニューラルコンピュータにはこれを学習させる。学習期間後の自律走行時はニューラルコンピュータが舵取操作を行う。

図4は学習自動車の原理を示す。

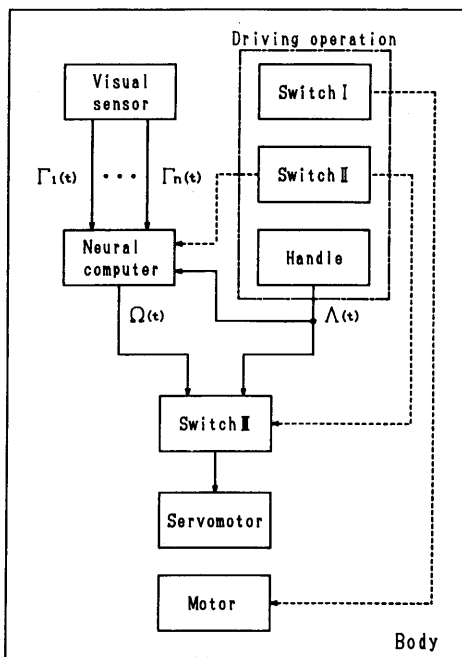


図4 学習自動車の原理

本体は、動力モータ、舵取用サーボモータ、スイッチⅢから成る。スイッチⅢは、ハンドルの切り角 $\Lambda(t)$ とニューラルコンピュータ部の出力信号 $\Omega(t)$ のいずれかを選択し、それを舵取用サーボモータに送る。

運転操作部は、自動車の始動と停止を行うスイッチⅠ、学習モードと非学習モードとを切り替えるスイッチⅡ、舵取を行うハンドルから成る。 $\Lambda(t)$ は、運転者がハンドルを右に切ったとき正の値、左に切ったとき負の値、ハンドルを右にも左にも切らないとき0となる。学習期間においては、スイッチⅡは学習モードに切り替えられ、スイッチⅢは $\Lambda(t)$ を選択し、ニューラルコンピュータ部は学習状態になる。自律走行時は、スイッチⅡは非学習モードに切り替えられ、スイッチⅢは $\Omega(t)$ を選択し、ニューラルコンピュータ部は非学習状態になる。

視覚センサ部は、周囲の情景的画像情報を取り込むためのもので、複数の信号 $\Gamma_1(t)$ ,  $\Gamma_2(t)$ ,  $\dots$ ,  $\Gamma_n(t)$ を出力する。

ニューラルコンピュータ部は、視覚センサ部からの複数の信号と $\Lambda(t)$ の対を入力とし、 $\Omega(t)$ を出力する。学習状態では、 $\Omega(t)$ が $\Lambda(t)$ に近づくように結合荷重が変更される。非学習状態では結合荷重は変更されない。

### 4.2 製作

図5は学習自動車の製作の方法を示す。




図5 学習自動車の製作

本体は、子供用足漕ぎ四輪車を元にして作る。動力用モータには直流モータを用いる。そのため、本体にバッテリーを搭載する。

運転操作部のハンドルにはポテンショメータを取り付け、ハンドルの切れ角 $\Lambda(t)$ を電圧の形で出力する。

視覚センサ部は、本体の前部に運転車の目とほぼ同じ高さになるように取り付け、周囲の情景的画像情報を前、右、左の三方向から取り込む。すなわち、三つの方向それぞれについて、広角レンズにより結んだ像を36本の光ファイバーで受け、これを $6 \times 6$ のフォトトランジスタマトリックス上に送る。各フォトトランジスタは入射光の強さに応じて応答し、その応答が抵抗を通して直流電圧の形で出力される。こうして、周囲の情景が視覚センサ部により電気信号の形で $6 \times 18$ 画素のパターンに変換される。

ニューラルコンピュータ部は、サイズが大きくなるので、4個の車輪を付けた台の上に固定し、本体にこれを引っ張らせる。図6はこの部分の構成を詳しく示したものである。図の中のI/Vは電流/電圧変換器である。

入力インタフェイスは、視覚センサ部の108個の出力信号 $\Gamma_1(t)$ ,  $\Gamma_2(t)$ ,  $\dots$ ,  $\Gamma_{108}(t)$ を回路網の入力信号 $x_1(t)$ ,  $x_2(t)$ ,  $\dots$ ,  $x_{108}(t)$ に変換する。但し、今の場合両者の信号は等しく、108個の緩衝増幅器によりインピーダンス変換を行い、雑音が乗るのを防ぐのが主要な役割である。

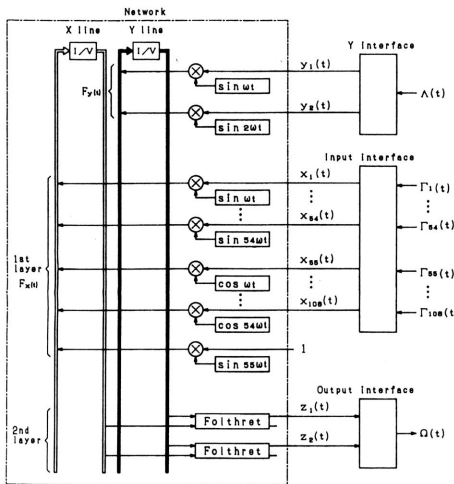


図6 ニューラルコンピュータ

Y インタフェイスは、ハンドルの切り角  $\Lambda(t)$  を、(12)式に示す右切り角  $y_1(t)$  と(13)式に示す左切り角  $y_2(t)$  に変換する。これらは回路網における教師信号となる。関数  $\phi_1(\cdot)$  と  $\phi_2(\cdot)$  は理想ダイオード回路により実現する。

$$y_1(t) = \phi_1(\Lambda(t)) \quad (t \geq 0) \quad (12)$$

$$\phi_1(\theta) = \begin{cases} \theta & (\theta > 0) \\ 0 & (\theta \leq 0) \end{cases}$$

$$y_2(t) = \phi_2(\Lambda(t)) \quad (t \geq 0) \quad (13)$$

$$\phi_2(\theta) = \begin{cases} 0 & (\theta > 0) \\ -\theta & (\theta \leq 0) \end{cases}$$

回路網は1層回路網と2層回路網より成る。1層回路網は教師信号  $y_1(t)$ ,  $y_2(t)$  を教師信号に等しい振幅を持ち、周波数がそれぞれ1 KHzと2 KHzの正弦波信号に変換する。この変換は、正弦波信号を  $\sin j\omega t$  ( $j = 1, 2$ ) の形で保持したROMと乗算型D/A変換器の組により実行される。以上のようにして得られた二つの正弦波信号は電流の形でY信号線に送られ、そこで加算されて  $F_y(t)$  となる。

2層回路網は109個の信号  $x_1(t)$ ,  $x_2(t)$ ,  $\dots$ ,  $x_{108}(t)$ , 1を入力し、右切り操作作用信号  $z_1(t)$  と左切り操作作用信号  $z_2(t)$  を出力する。第1層は1個の入力信号を受け、それをそのまま出力する109個のニューロンより成る。従って、第1層は109個のROMと乗算型D/A変換器の組で構成され、各入力信号が入力信号に等しい振幅を持った正弦波信号に変換される。始めの54個の

ROMには、正弦波信号が  $\sin j\omega t$  ( $j = 1, 2, 54$ ) の形で、次の54個のROMには  $\cos j\omega t$  ( $j = 1, 2, 54$ ) の形で保持されており、周波数はどちらの場合も1 KHzから54 KHzまで1 KHz間隔で与えられる。最後の1個のROMには、周波数55 KHzの正弦波信号が  $\sin 55\omega t$  の形で保持されている。以上のようにして得られた109個の正弦波信号は電流の形でX信号線に送られ、そこで加算されて  $F_x(t)$  となる。

第2層は2.1で述べた連続時間学習しきい素子モデルで記述される右切り操作作用と左切り操作作用の2個のニューロンより成る。前者は109個の入力信号と  $y_1(t)$  の対を、後者は109個の入力信号と  $y_2(t)$  の対を学習し、それぞれ  $z_1(t)$  と  $z_2(t)$  を出力する。従って、第2層は電子回路化した連続時間Folthret 2個で構成する。 $F_x(t)$  と  $F_y(t)$  は電流/電圧変換器を通して電圧に変換され、それぞれX信号線およびY信号線を通してFolthretに供給される。各Folthretの教師信号計算部のROMには、正弦波信号  $\xi(t)$  が  $\sin j\omega t$  ( $j = 1, 2$ ) の形で保持され、周波数は右切り操作作用の場合1 KHz、左切り操作作用の場合2 KHzである。なお、回路網が2層であるので、出力変換部のROMには信号  $\zeta(t)$  が保持されていない。

出力インタフェイスは差動増幅器で、(14)式のように回路網の出力信号  $z_1(t)$ ,  $z_2(t)$  を  $\Omega(t)$  に変換する。

$$\Omega(t) = z_1(t) - z_2(t) \quad (t \geq 0) \quad (14)$$

図7は製作した学習自動車である。



図7 学習自動車の外観

## 5. 走行実験

### 5.1 方法

製作した学習自動車に人間が一人乗車し、机等の障害物がある実験室内で走行実験を行う。

まず学習期間には、人間が始動操作、舵取操作、停止操作の三つの操作をこの順で行い、図8に示す始点から




図8 学習経路

終点まで約8mのあらかじめ定められた経路を時速約1km/時の速度で走行する。これを1試行とする。1試行における結合荷重の変更回数は、30回程度となる。このような試行をN回行った後、学習期間と同じ位置を始点として、同じ速度で自律走行させる。すなわち、一つの実験はNの試行と1回の自律走行から成る。Nは1から10まで変え、計10回の実験を行う。なお、学習自動車は試行時に毎回同じ経路を走行するので、各試行においてほぼ同一の入力信号と教師信号がニューラルコンピュータに与えられると考えられる。

学習自動車の自律走行性能は、自律走行時における走行経路をあらかじめ定められた経路と比較することにより調べる。なお、Folthretの学習定数cは0.3、結合荷重の初期値はすべて0とする。

### 5.2 結果

図9は実験結果で、10回の実験それぞれにおける自律

走行時での走行経路が破線で示されている。実線はあらかじめ定められた経路である。数字は試行回数Nを表している。

Nが0の場合は全く学習を行わなかったときの経路で、当然のことながら直進する。Nが1から3の場合には、十分な学習が行えず、始点の近くにある机に衝突した。Nが4になると、そのようなことはなくなるが、終点の位置は定められた位置からかなりずれた。Nが5以上になると、走行経路は定められた経路に徐々に近づいていき、Nが10のときには定められた経路とほぼ同じ経路を自律走行できるようになった。このときの終点の位置は、定められた位置から30cm程度ずれただけであった。Nを10より大きくしても自律走行時の走行経路はほとんど変わらなかった。


### 5.3 考察

以上の実験結果から、走行速度一定、単純な情景、比較的狭い室内、静環境の条件下ではあるが、ニューラルコンピュータが1個のアナログ出力しか持たなくても、10回程度の試行を行えば、運転者の舵取操作を学習できることが示された。従って、学習自動車の舵取操作にはニューラルコンピュータの出力は1個で十分であると思われる。これと同時に、連続時間Folthretの有効性についても走行実験より確認できたと考えられる。

ただ、ニューラルコンピュータのもう一つの特徴である汎化機能については今回の実験では調べられなかった。今後は、汎化機能についても詳細に調べられるような実験環境を設計する必要がある。更に、アクセル操作、ブレーキ操作、始動操作、停止操作、ギア操作等の学習や、実際の道路での走行実験も今後必要である。

## 6. まとめ

本論文では、先ず連続時間Folthretを新たに提案し、これをアナログ回路とデジタル回路の両方を用いて電



(a) N = 0 ~ 5

(b) N = 6 ~ 10

図9 実験結果



子回路化した。次に、これを2個用いて1個のアナログ出力を持つニューラルコンピュータを構成し、一人乗りの電気自動車に搭載することにより、始動操作、舵取操作、停止操作の三つが可能な学習自動車を製作した。最後に、製作した学習自動車に人間が一人乗車し、机等の障害物がある実験室内で走行実験を行った。その結果、学習期間における試行を10回まで増やすと、定められた走行経路とほぼ同じ経路を自律走行できることがわかった。このときの終点の位置は、定められた位置から30 cm程度ずれたただけであった。すなわち、走行速度一定、単純な情景、比較的狭い室内、静環境の条件下ではあるが、製作した学習自動車は運転者の舵取操作を学習できることが確認でき、連続時間 Folthret で構成した1個のアナログ出力を持つニューラルコンピュータの舵取操作の自動化に対する有効性が示された。

今後の課題としては、学習自動車の汎化機能についても調べること、舵取操作以外の運転操作も学習できるようにすること、実際の道路で走行実験を行うこと等が挙げられる。

### 参 考 文 献

- (1) 吉野慶一, 横井博一: "Folthretによる学習自動車", 平元電気学会産業応用部門全大, 739/744 (1989)
- (2) 吉野慶一, 横井博一: Folthretによる学習自動車, 平2電気関係学会九州支部連大, 31 (1990)
- (3) 横井博一: "Folthret回路網による学習自動車", J. KMEC JAPAN, 1-1, 48/49 (1990)
- (4) 吉野慶一, 横井博一: "Folthretによる学習自動車", 信学技報, MBE90-110, 111/116 (1991)
- (5) R. M. H. Cheng, J. W. Xiao and S. LeQuoc: Neuro-morphic Controller for AGV Steering, Proceedings of the 1992 IEEE International Conference on Robotics and Automation, 2057/2062 (1992)
- (6) D. A. Pomerleau: ALVINN: An AUTONOMOUS LAND VEHICLE IN A NEURAL NETWORK, In Advances in Neural Information Processing Systems 1, Morgan Kaufmann, 305/313 (1989)
- (7) D. A. Pomerleau: Efficient Training of Artificial Neural Networks for Autonomous Navigation, Neural Computation, 3-1, 88/97 (1991)
- (8) 阿江忠: VLSI ニューロコンピュータ, 14/15, 共立出版 (1991)
- (9) 横井博一: 情報のフーリエ級数化とその処理, 東邦学誌, 9, 1/11 (1977)
- (10) 横井博一, 日比野省三: フーリエ級数信号による情報の物理的表現, 昭53信学総全大, 1112 (1978)
- (11) 横井博一, 日比野省三: フーリエ級数信号による情報処理, 昭53電学会全大, 1216 (1978)
- (12) 横井博一, 日比野省三: フーリエ級数信号の情報処理への応用, 電学会情報処理研資, IP-78-20, 1/10 (1978)
- (13) 横井博一, 斎藤正男: 新しい学習しきい素子—Folthret一, 信学論(A), J69-A-9, 1173/1175 (1986)
- (14) 横井博一: フーリエ級数型学習しきい素子—Folthret一, 信学論(DII), J75-D-II-1, 146/151 (1992)
- (15) 横井博一: ニューラルコンピュータのための基本素子GH-Folthret, 信学論(DII), J76-D-II-3, 680/688 (1993)
- (16) A. Masaki, Y. Hirai and M. Yamada: Neural networks in CMOS: a case study, Circuits and Devices, 6-4, 12/17 (1990)
- (17) 鈴木真子, 土屋主税, 増本大器, 浅川和男: アナログ・ニューロプロセッサを用いた階層ニューラル・ネットワーク, 信学技報, CPSY90-74, 71/76 (1990)
- (18) L. W. Massengill: MULTIPLEXED, CHARGE-BASED CIRCUITS FOR ANALOG NEURAL SYSTEMS, Proceedings of the International Joint Conference on Neural Networks, 88/91 (1990)