

## Liquid state machine を用いた タイミング制御システムの研究

眞鍋 秀聡<sup>†1</sup> , 田中 繁<sup>†2</sup> , 西野 哲朗<sup>†2</sup>

これまで, Marr-Albus-Ito のパーセプトロン仮説により, 小脳は単純パーセプトロンであると考えられてきた. しかし近年, 小脳はより汎用性の高い計算能力を持つ Liquid state machine と等価であるとする学説が提唱され, タイミング出力をもつ任意の論理演算を学習できることが示唆されている. 本研究では, タイミング制御システムを Liquid state machine を用いて構成し, いくつかのセンサからの複雑な入力情報に基づいて制動を掛ける車両の制動システムに応用可能であることを示した. そして, Liquid state machine における学習の簡便さによって, 製造コストの大幅な削減を可能にすることを示唆した.

### A timing control system by a liquid state machine

HIDEAKI MANABE,<sup>†1</sup> SHIGERU TANAKA<sup>†2</sup>  
and TETSURO NISHINO<sup>†2</sup>

The cerebellum that has been considered to date as a biological counterpart of a simple perceptron is proposed to be reinterpreted to be a liquid state machine that possesses information processing capability more widely applicable than the simple perceptron. In this study, we made a timing controlled safety system of vehicles using complex information from several sensors based on the liquid state machine. We suggest that the production cost of safety systems can be greatly reduced owing to simple learnability of the liquid state machine.

<sup>†1</sup> 国土交通省

Ministry of land, Infrastructure, Transport and Tourism

<sup>†2</sup> 電気通信大学

University of Electro Communications

### 1. はじめに

著者らは脳の機能モデルの1つで, あるインターナルクロックモデル<sup>5)</sup>を基にタイミング学習システム(以下, 既存学習システム)を提案した<sup>13)</sup>. そして, このシステムを実装することで, 神経科学の分野で研究されている瞬目反射の条件付け<sup>1)2)3)</sup>を実機上で模倣可能であることを示した. だが, 既存学習システムは入力を1種類と定義していたため, 複数の入力に関わる場合のタイミングの学習は想定していなかった. さらに, 小脳回路を工学的に実現したとしても, パーセプトロン仮説により, XORのような線形分離不可能な情報処理には機能しないとされてきた. しかし, 2007年に小脳が万能の計算能力を持つ教師付学習機械, Liquid state machine(LSM)<sup>6)</sup>と等価のネットワークである可能性が示された<sup>4)</sup>. これによって, 学習可能なタイミング学習システムを4)で提案されたモデル(小脳LSMモデル)に基づいて構成することで, これまで実現できなかった線形分離不可能な情報処理能力も実現できる可能性が見えてきた.

現在, 工学の分野では車両の状態や周辺状況を多数のセンサで判断し, ドライバへの警告や自動制御による運転支援を行う車両制御システムが実用化され始めている. そのうちの1つがプリクラッシュセーフティ<sup>16)17)</sup>である. プリクラッシュセーフティとは, 車両が周辺情報から事前に衝突を予知し, 衝突に対して身構えることによって, 被害を軽減する技術である. 現在, プリクラッシュセーフティは官民間問わず様々な研究機関で研究が進められている<sup>14)</sup>が, コストや認識能力等, 未だ多くの課題が山積している<sup>11)</sup>. これらの課題の解決のため, 単一のセンサだけでは得られない車両周辺の環境に対して, 様々な特性を持つセンサを複数組み合わせることで対応するセンサフュージョン技術が注目されている<sup>10)</sup>. 現在, センサ情報は個々のアプリケーション専用のチップが個別に収集している. しかしこの手法では, センサの追加や変更には専用チップを新たに作り直さねば対応できない. このため, 今後のセンサ技術の進歩に伴う開発コストの増大が懸念される. また, 新技術によるセンサの追加・変更に対して直ちに対応することにも困難が予想される. このような開発コストに関する問題を解決するため, 様々なセンサ情報を統合的に取り扱い, かつセンサの追加・変更に対応できるシステムの開発も進められている<sup>15)</sup>.

本研究では, 小脳LSMモデルに基づいた, 新たなタイミング制御システムを提案する. そして, 本システムが複数のセンサ入力に対して, 適切なタイミングでブレーキを掛けるように学習することが可能であることを示す. さらに, 本システムを用いることで, 様々なセンサ情報を統合的に取り扱い, かつセンサの追加・変更に対応できることを確認す

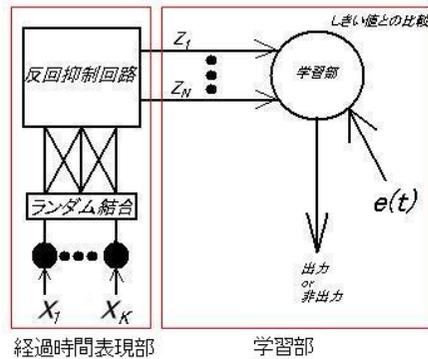


図 1 提案するタイミング制御システム  
Fig.1 A proposed timing control system

る．それにより，提案するシステムがブリクラッシュセーフティへの適用に有効であることを示す．

## 2. 提案する新たなタイミング制御システム

この節では，本論文で提案するタイミング制御システムの詳細について述べる．

### 2.1 提案するシステムの概要

タイミング制御システムの構造を，図 1 に示す．時刻生成部に入力ベクトル  $x$  が与えられると，各時刻  $0 \leq t \leq T$  において  $N$  個の出力  $z(t) = (z_1(t), \dots, z_N(t))$  からなるパターンを学習部に出力する．学習部はそのパターンを入力として，特定のパターンが与えられた場合に出力を行うよう学習する．このシステムのタイミング学習は任意の入力  $x$  と，学習したいタイミングに命令信号  $e_i(t)$  の組をただ一度与えるだけで完了する．結果的にこのシステムは， $x$  の入力列が時刻生成部に与えられてから，学習部に  $e(t) = 1(t = (t_1, \dots, t_L))$ ， $L$ ：学習するタイミングの個数）が与えられるまでのタイミング  $t$  を学習する．学習部の数を  $M$  とすると，このシステムは  $K$  入力  $M$  出力のネットワークとなる．ここで，小脳 LSM モデルにおける外部入力  $x$  は，各要素ごとにセンサに結線され，そのセンサからの出力を要素とした  $K$  ビットベクトルであると仮定した．このように捉えることで，複数のセンサからの入力に適応可能なシステムを構築することができる．

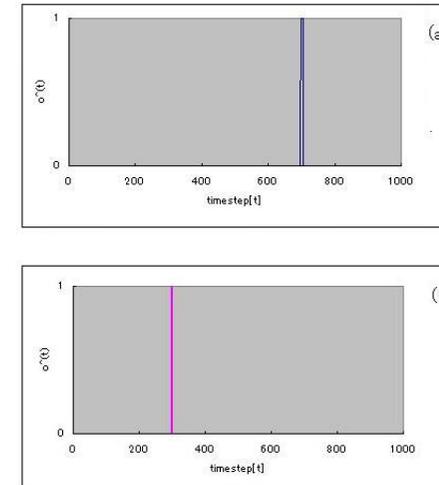


図 2 タイミング学習後のシステムの入出力パターン (a) :  $t=0$  から  $x_1 = (0; 0; 0; 0; 0; 0; 1)$  を入力し，命令信号を  $t = 700$  で与えてタイミング学習を行なった後， $x_1$  を入力した場合のシステムの入出力パターン．(b) :  $t=0$  から  $x_2 = (0; 0; 0; 0; 0; 0; 1; 0)$  を入力し，命令信号を  $t = 300$  で与えてタイミング学習を行なった後， $x_2$  を入力した場合のシステムの入出力パターン．

Fig. 2 Outputs of the system after learning. (a) : An output pattern in response to  $x_1 = (0; 0; 0; 0; 0; 0; 1)$  after the learning in which instruction signal was given to the model 700 steps after the onset of input  $x_1$ . (b) : An output pattern in response to  $x_2 = (0; 0; 0; 0; 0; 0; 1; 0)$  after the learning in which instruction signal was given to the model 300 steps after the onset of input  $x_2$ .

## 3. 検証実験

前節にて構築したシステムの能力を検証するため，複数の検証実験を行った．まず始めに，本タイミング制御システムに異なる入力  $x$  を与え，それぞれ異なるタイミングを学習させた場合のモデルの挙動を確認した．その結果，このシステムは，入力ごとにそれぞれ異なるタイミングを正しく学習できた．検証結果を図 2 に示す．

次に，作成したタイミング制御システムが複数のセンサ入力に対し，XOR または OR に対応する動作が可能であることを検証した．その結果，このシステムは複数のセンサ入力に対し，XOR を正しく学習できることを確認した．検証結果を図 3 に示す．

次に，入力ベクトルの要素に実数値が含まれる場合の本システムの動作を検証した．現

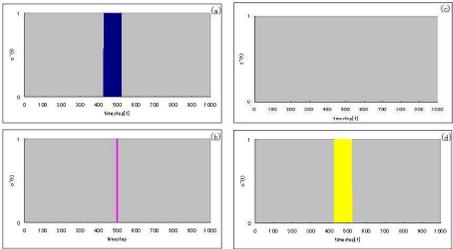


図 3 タイミング学習後のシステムの出力  $\delta(t)$  (a) :  $t=0$  から  $\mathbf{x}_1 = (0; 0; 0; 0; 0; 0; 1)$  を入力し、命令信号を  $t = 500$  で与えてタイミング学習を行わせた後、 $\mathbf{x}_1$  を入力した場合のシステムの出力パターン . (b) :  $t=0$  から  $\mathbf{x}_2 = (0; 0; 0; 0; 0; 1; 0)$  を入力し、命令信号を  $t = 500$  で与えてタイミング学習を行わせた後、 $\mathbf{x}_2$  を入力した場合のシステムの出力パターン . (c) : タイミング学習を行わなかった入力  $\mathbf{x}_3 = (0; 0; 0; 0; 0; 1; 1)$  を与えた場合のシステムの出力パターン . (d) :  $\mathbf{x}_3$  でも  $\mathbf{x}_1$  と  $\mathbf{x}_2$  同様に  $t=500$  でタイミング学習を行わせた後、再度入力  $\mathbf{x}_3$  を与えた場合のシステムの出力パターン

Fig.3 Outputs of the system after learning.(a) : An output pattern in response to  $\mathbf{x}_1 = (0; 0; 0; 0; 0; 0; 1)$  after the learning in which instruction signal was given to the model 500 steps after the onset of input  $\mathbf{x}_1$ . (b) : An output pattern in response to  $\mathbf{x}_2 = (0; 0; 0; 0; 0; 1; 0)$  after the learning in which instruction signal was given to the model 500 steps after the onset of input  $\mathbf{x}_2$ . (c) : An output pattern in response to  $\mathbf{x}_3 = (0; 0; 0; 0; 0; 1; 1)$  that was not used for the learning. (d) : An output pattern in response to  $\mathbf{x}_3$  after the learning using  $\mathbf{x}_3$  as well as  $\mathbf{x}_1$  and  $\mathbf{x}_2$  .

在、時刻生成部への入力ベクトルは、全ての要素がブール値と定められている . しかし、実機での利用を考えた場合、距離センサや重量センサ等のアナログ値入力にも対応する必要がある . アナログ値入力に対応する方法として、以下の 2 通りが考えられる .

- (1) A/D コンバータを用いて、センサからのアナログデータを必要精度のバイナリデータに変換する
  - (2) 入力ベクトルの各要素に必要精度の実数値を与えられるよう拡張する
- (1) の実現は容易であるが、(2) については、実数値を各要素に与えた場合のシステムの挙動について調査する必要がある . 今回構成したシステムでは、ある入力ベクトル  $\mathbf{x}$  と正のスカラー倍だけ異なる  $\alpha\mathbf{x}$  を与えた場合には、時刻経過表現部が同一のパターンを生成してしまうため、 $\mathbf{x}$  と  $\alpha\mathbf{x}$  を識別することができないことを確認した . 以上のことから、アナログ値への対応は (1) の手法を用いるのが適切であると考えられる . しかし手法 (1) の場合、精度と取り扱えるセンサ数とがトレードオフの関係となることに注意が必要である .

#### 4. ブリクラッシュセーフティへの適用

この節では、システムの実機制御への適用可能性の証明を行う . 現在、小脳 LSM モデルは FPGA によるチップが試みられており<sup>12)</sup>、FPGA 上に実装する場合、実時間での制御にも対応できる処理速度を実現できることが明らかとなっている . 本研究では、現在実用化され、研究も著しいブリクラッシュセーフティについて、本研究にて提案するタイミング制御システムが適用可能であるかを検証する .

##### 4.1 既存のブリクラッシュセーフティ

###### 4.1.1 センサ

一般的にブリクラッシュセーフティに用いられているセンサは大別して次の 4 種類が挙げられる<sup>16)17)</sup> .

- (1) 自車速度センサ：車両の走行速度を感知する
- (2) 接近速度センサ：自車と障害物との相対速度を感知する
- (3) 距離センサ：前方の障害物を感知する
- (4) 補助センサ：運転者の余所見や居眠り又は車体のふらつき等、事故の原因となり得る情報を感知する

主な制御は (1) ~ (3) によって判断され、(4) のセンサはその補助的な役割を果たす . これらのセンサのうち、(1),(2),(3) はアナログ値を取り扱うセンサである . よって、これらセンサがどれほどの精度で取り扱われているのか調査し、必要な入力センサ数を算定した .

第一に自車速度センサは、『5km/h 未満』『5km/h 以上、15km/h 未満』『15km/h 以上、30km/h 未満』『30km/h 以上』の 4 段階で判断していた . よって、必要な入力ビット数は 2 ビットである .

次に、接近速度センサについて調査したところ、『15km/h 未満』『15km/h 以上、30km/h 未満』『30km/h 以上』の 3 段階での判断だった . したがって、この場合でも、必要な入力ビットは 2 ビットとなる .

第三に距離センサは、各メーカー共に『遠い』『近い』『接近 (衝突寸前)』の 3 段階で判断をしていた . よって、必要な入力ビット数はやはり 2 ビットである .

最後に、補助センサについて検討を行う . 現在、補助センサは各自動車メーカーごとに異なるが、多くのメーカーで採用されている以下の 2 つについて対応するものとした .

- (1) ドライブモニター：運転者の余所見及び居眠りをまぶたの開閉から検知する
- (2) ふらつき感知センサ：走行中の車体のふらつきを感知する

これら 2 つのセンサは情報を 0 または 1 のブール値で取り扱われる。

以上から、一般的なプリクラッシュセーフティーに用いられているセンサ情報は、今回提案したシステムの入力ビット数 ( $K=8$ ) の組み合わせで表現することができる。本研究では、自転車速度センサからの情報を  $x_1, x_2$ 、接近速度センサからの情報を  $x_3, x_4$ 、距離センサからの情報を  $x_5, x_6$ 、ドライバモニタからの情報を  $x_7$ 、ふらつき感知センサからの情報を  $x_8$  で表現する 8 ビットベクトル  $\mathbf{x}=(x_1; x_2; x_3; x_4; x_5; x_6; x_7; x_8)$  を入力として表現した。

#### 4.1.2 アプリケーション

次に、プリクラッシュセーフティーの出力として用いられているアプリケーションについて調査した結果、現在実装されているアプリケーションには、以下の 4 種類が挙げられる。

- (1) 自動ブレーキ：衝突が不可避と判断した場合、緊急ブレーキが起動する
- (2) 運転アシスト：衝突する可能性が高いと判断した場合、ブレーキ圧を高めるなどによって回避操作を支援する
- (3) 警報アラーム：衝突する可能性があるとして判断した場合、アラームによって運転者に危険を知らせる
- (4) シートベルト制御：衝突の可能性が高いと判断された場合、シートベルトを予め巻き上げ、危険に備える

これらはセンサ情報から判断される危険度に応じて動作するものである。本タイミング制御システムでは、学習部ごとに動作する入力及びタイミングを切り分けることができる。本研究では、上記アプリケーションについて、 $M=4$  個の学習部からの出力によって、上記 4 種のアプリケーションを独立に起動させるタイミングを個別に学習させることにした。

#### 4.1.3 センサ情報と動作するアプリケーションの関係

各センサから与えられた情報に応じ、動作するアプリケーションが切り替わる必要がある。現在用いられているセンサ情報の組み合わせと各アプリケーションの対応は、以下の 4 通りである。

- (1) 自動ブレーキは、自転車速度センサが『15km/h 以上』、接近速度センサが『30km/h 以上』、距離センサが『接近』のときに動作する。
- (2) 運転アシストは自転車速度センサが『30km/h 以上』かつ接近速度センサが『30km/h 以上』であり、距離センサが『近い』場合のみ動作する。ここで、距離センサが『接近』の場合、自動ブレーキとの重複による過剰ブレーキを避けるために動作させない。
- (3) 警報アラームは自転車速度センサが『5km/h 以上』かつ接近速度センサが『5km/h 以上』のとき距離センサが『遠い』『近い』『接近』全ての場合においてに動作する。

- (4) シートベルト制御は自転車速度センサが『5km/h 以上』かつ接近速度センサが『30km/h 以上』のとき、距離センサが『遠い』『近い』『接近』全ての場合において動作する。

上記 4 つが各センサとアプリケーションとの基本的な対応となる。ただし、虫や雨などによる誤検知の可能性を考慮し、センサの反応直後ではなく、一定時間センサ出力が持続する場合にアプリケーションが動作することが一般的である。今回は  $t=800$  としてタイミング学習を行い、これに対応することとした。

最後に、補助センサ 2 種についてであるが、多くの実装では、これらセンサが反応した場合、警報アラーム及び運転アシストが通常より早い段階で動作する。今回、警報アラームが動作するセンサ入力の組み合わせに対し、これらセンサが反応している場合には、学習するタイミングを  $t=500$  に変更されるよう設定した。また、運転アシストについては、距離センサが『近い』および『遠い』である場合に対しても、動作するように設定した。

#### 4.2 動作検証

前小節までに確認したセンサとアプリケーションとの関係を基にシステムを構築し、入力ベクトルを用い、各センサごとの組み合わせとアプリケーションの動作を対応付けるよう学習を行った。そして、学習終了後に入力ベクトルの違いに応じ、適切にアプリケーションを動作可能か検証を行った。学習後の警報アラーム結果の一部を図 4 に示す。まず、(a) により、補助センサからの入力がない状態で警報アラームが動作する条件が感知された場合には、警報アラームが  $t=800$  付近から起動することが確認できる。次に、(b) より、補助センサの入力がある場合は、警報アラームが  $t=500$  付近で起動した。そして最後に、(c) より、警報アラームの動作を学習しないセンサ入力の組み合わせの場合、警報アラームは動作しない。

他の入力ベクトルの場合及び他のアプリケーションについても、適切なセンサ入力の組み合わせの場合にのみ、適切なタイミングでアプリケーションが起動可能であることを確認した。

さらに、運転アシストについて動作の確認を行った。その一部を図 5 に示す。図 5(a),(b) より、学習後に  $x_1$  もしくは  $x_2$  を入力した場合は、学習したタイミングである  $t=800$  付近でのみ  $\hat{o}(t)=1$  となり、それ以外では 0 であることがわかる。そして学習を行っていない、学習後に  $x_3$  を入力した場合を示す図 5(c) は、 $t=500$  付近を含む  $\hat{o}(t)$  が常に 0 であることがわかる。ここで、 $x_1, x_2$  そして  $x_3$  の関係から、図 5(c) は XOR の学習であることが分かる。

以上の結果から、このシステムにより、現行のプリクラッシュシステムで一般的に利用さ

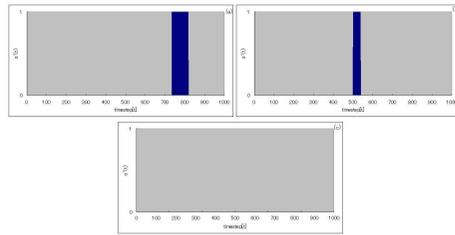


図 4 警報アラームの出力  $\hat{o}(t)$ . (a) :  $t = 0$  から  $\mathbf{x}_1 = (0; 1; 0; 1; 1; 0; 0; 0)$  を入力し、命令信号を  $t = 800$  で与えてタイミング学習を行わせた後、 $\mathbf{x}_1$  を入力した場合のシステムの出力パターン (b) :  $t=0$  から  $\mathbf{x}_2 = (0; 1; 0; 1; 1; 0; 0; 1)$  を入力し、命令信号を  $t = 500$  で与えてタイミング学習を行わせた後、 $\mathbf{x}_2$  を入力した場合のシステムの出力パターン (c) : タイミング学習を行わなかった入力  $\mathbf{x}_3 = (1; 1; 0; 0; 0; 0; 0; 0)$  を与えた場合のシステムの出力パターン .

Fig. 4 Outputs of the system after learning.(a) : An output pattern in response to  $\mathbf{x}_1 = (0; 1; 0; 1; 1; 0; 0; 0)$  after the learning in which instruction signal was given to the model 800 steps after the onset of input  $\mathbf{x}_1$ . (b) : An output pattern in response to  $\mathbf{x}_2 = (0; 1; 0; 1; 1; 0; 0; 1)$  after the learning in which instruction signal was given to the model 500 steps after the onset of input  $\mathbf{x}_2$ . (c) : An output pattern in response to  $\mathbf{x}_3 = (1; 1; 0; 0; 0; 0; 0; 0)$  that was not used for the learning.

れているセンサ情報と仮定した複数の入力を統合的に取り扱って、適切な組み合わせの際にのみ、XOR が関わる場合であっても、適切なタイミングでアプリケーションを起動させることが可能であることを示した .

## 5. おわりに

本研究では、小脳 LSM モデルに基づきタイミング制御システムを構築し、システムの実機特性を検証した . システムの特性をまとめると以下の通りである .

- (1) 複数のセンサからの入力に対し、出力を行うタイミングをそれぞれ任意に学習可能である
- (2) センサ信号に対して XOR でアプリケーションを起動させる場合にも適用可能である
- (3) このシステムでのタイミング学習は、任意の入力  $\mathbf{x}$  ごとに学習したいタイミングで命令信号  $e_i(t)$  の組をただ一度与えるだけで完了する .
- (4) 入力信号が実数値で与えられる場合には、入力ベクトルを必要な精度に応じたビット数のバイナリ信号に変換することで適用可能である
- (5) モデル顆粒細胞数  $N$  を増加させることで、入力識別能力を増強できる
- (6) 学習部を追加することで、複数のタイミングで任意の数の出力させることができる

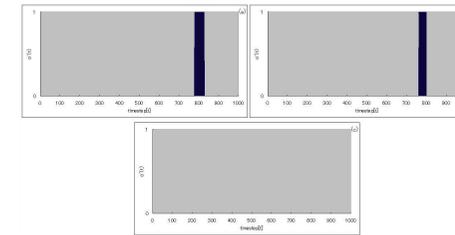


図 5 運転アシストの出力  $\hat{o}(t)$  (a) :  $t = 800$  でタイミング学習を行わせた入力  $\mathbf{x}_1 = (1; 1; 1; 1; 0; 1; 0; 1)$  を与えた場合 (b) :  $t = 800$  でタイミング学習を行わせた入力  $\mathbf{x}_2 = (1; 1; 1; 1; 0; 1; 0; 1)$  を与えた場合 . (c) : タイミング学習を行わなかった入力  $\mathbf{x}_3 = (1; 1; 1; 1; 1; 1; 0; 1)$  を与えた場合 .

Fig. 5 Output of system after learning. (a) : Instruction signal was given to the model 800 steps after the input signal  $\mathbf{x}$  onset at the time of conditioning ( $\mathbf{x} = (1; 1; 1; 1; 0; 1; 0; 1)$ ). (b) : Instruction signal was given to the model 500 steps after the input signal  $\mathbf{x}$  onset at the time of conditioning ( $\mathbf{x} = (1; 1; 1; 1; 0; 1; 0; 1)$ ). (c) : Instruction signal was not given to the model after the input signal  $\mathbf{x}$  onset at the time of conditioning ( $\mathbf{x} = (1; 1; 1; 1; 1; 1; 0; 1)$ ).

これらの特性をもとに、このシステムの実機制御への適用として、プリクラッシュセーフティについて適用可能であるかを検討した結果、現在用いられているセンサ群に対してこれらの情報を統合し、適切なタイミングで特定アプリケーションを動作させることが可能であることを理論的に検証した .

以上の結果を踏まえ、本研究で提案したタイミング制御システムの有用性について議論する .

第一に、本タイミング制御システムは、ある入力ベクトルに対し、複数のタイミングで任意の数を出力するよう学習が可能である . つまり、このシステムは、汎用論理演算装置であると同時に、出力を任意のタイミングで変更することが出来るシステムである . 論理演算素子を使って同じ機能を実現しようとする場合、各論理演算素子ごとにディレイラインを接続する必要がある . 今回提案したシステムは、あらゆる論理演算素子とディレイラインの組み合わせを容易に模倣するような学習が可能である . この特性を利用して、例えば各自動車の出荷時に車種のセンサーシステムと制動システムに合わせて LSM を学習させることにすれば、車種ごとに多種多様なチップを生産する体制は今後不要になると考える . これは、チップの開発費及び開発期間の削減に繋がることから、本システムは既存手法と比較して優位性があると考えられる .

次に、本システムはただ一度、入力ベクトルと出力を行うタイミングを呈示されるだけで、XOR を含むタイミング学習を実現できる . ニューラルネットワークを用いた XOR の

実現は、バックプロパゲーションなど複数存在するが、いずれも学習の複雑さによる学習収束まで時間がかかるという問題があった<sup>9)</sup>。この問題を解決している本システムは、その点に対して優位性があると言える。

第三に、本システムをチップ化することの実現可能性についてを考察する。過去の研究<sup>12)</sup>により、小脳 LSM モデルを FPGA にて実装する際に必要な回路規模が算出されている。今回、プリクラッシュセーフティへの適用に際して用いたパラメータの場合でも、実装に必要な回路規模を持つ FPGA は存在しており、今回提案したシステムを FPGA 上に実装することは十分に可能である。

最後に、チップ化した場合の本システムのリアルタイム性について述べる。現在プリクラッシュセーフティで用いられている距離センサの時間窓はおよそ 100ms<sup>7)</sup> である。一方で、人間が危険を感知してから行動を起こすまでの反応時間はおよそ 660ms であるとされている<sup>8)</sup>。センサ情報取得およびアプリケーションの動作時間をそれぞれ 100ms と仮定した場合、人間の反応速度を上回る動作を行うためには、本システムはおよそ 460ms 以内に処理を行う必要がある。小脳 LSM モデルを FPGA 上に実装した場合の 1 step あたりの計算処理は約 0.81 ms で動作可能である<sup>12)</sup> ことが明らかとなっている。よって、本システムをチップ化した場合、実際のセンサ情報を取り扱い、リアルタイムで処理を行うことは、十分に可能といえる。

以上のことから、本システムの有用性を示すことができた。

## 参 考 文 献

- 1) M Ito. "Cerebellum and neural control". New York : Raven Press., 1984;
- 2) Hunter E. Halverson and John H. Freeman, "Ventral lateral geniculate input to the medial pons is necessary for visual eyeblink conditioning in rats" Learn. Mem., 17(2): pp.80 - 85, 2010;
- 3) Mauk MD and Donegan NH (1997). A model of Pavlovian eyelid conditioning based on the synaptic organization of the cerebellum. Learn Mem 3 : 130-158.
- 4) Tadashi Yamazaki and Shigeru Tanaka: "The cerebellum as a liquid state machine", Neural Net-works 20, pp.290-297, 2007.
- 5) Tadashi Yamazaki and Shigeru Tanaka: "Neural Modeling of an Internal Clock", Neural Computation 17, pp.1032-1058, 2005.
- 6) W. Maass, T. Natschlaeger, and H. Markram. Real-time computing without stable states: "A new framework for neural computation based on perturbations", Neural Computation, 14(11):2531-2560, 2002.

- 7) 大杉啓治, 宮内邦宏, 古居信之, 宮越博規: "ACC システム用スキャン式レーザーレーダの開発", デンソーテクニカルレビュー, Vol.6, No.1, pp.43-48, 2001.
- 8) 自動車技術専門委員会, "JISD0802 自動車-前方車両衝突. 警報装置-性能要求事項及び試験手順", 日本工業標準化委員会, 2002.
- 9) 田口 広幸, 山田 浩太郎, 田口 亮, 曾禰 元隆, 飯島 伸一: "誤差逆伝搬学習則における学習停滞の解析", 電子情報通信学会総合大会講演論文集 1996 年. 情報・システム (1), 15, 1996.
- 10) 西垣戸 貴臣, 大塚 裕史, 坂本博史, 大辻信也, "予防安全の高度化を実現するセンサーフュージョン技術", 日立評論 89(8), 654-657, 2007.
- 11) 二宮芳樹, 加藤武男, 小島祥子, "複数センサ情報の融合による走行環境認識技術", R&D Review of Toyota CRDL Vol. 36 No. 3, pp.27-34, 2001.
- 12) 松野香菜子, 本多武尊, 眞鍋秀聡, 田中 繁, 西野哲朗: "FPGA 上に実装した小脳ネットワークモデルにおけるタイミングメカニズムの研究", 電子情報通信学会技術研究報告. NC, ニューロコンピューティング, 109(363), pp. 7-12, 2010.
- 13) 眞鍋秀聡, 西野哲朗, 山崎匡, 田中繁: "インターナルクロックモデルに基づくロボット制御法の実現", 論文誌(トランザクション)数理モデル化と応用, Vol.48 No.SIG19 TOM19, pp139-154, 2007.
- 14) 見市 善紀, "安全・安心: 自動車における運転支援技術の発展について", 精密工学会誌, 75(1), 163-164, 2009.
- 15) 山田 真大, 鎌田 浩典, 佐藤 健哉, 手嶋 茂晴, 高田 広章, "車両制御システムのためのセンサデータ統合管理方式の検討", 電子情報通信学会論文誌 D, 情報・システム J93-D(7), 1189-1201, 2010.
- 16) SUBARU オフィシャルサイト: <http://www.subaru.jp/>
- 17) トヨタ自動車株式会社: [http://www.toyota.co.jp/jpn/tech/safety/technology/technology\\_file/pre\\_crash/](http://www.toyota.co.jp/jpn/tech/safety/technology/technology_file/pre_crash/)