

## 聴覚情報処理システムのためのパルスニューロンモデルを用いた競合学習ニューラルネットワーク

黒柳 奨<sup>†a)</sup> 岩田 彰<sup>††</sup>

A Competitive Learning Neural Network for Auditory Information Processing Using the Pulsed Neuron Model

Susumu KUROYANAGI<sup>†a)</sup> and Akira IWATA<sup>††</sup>

あらまし 本論文ではハードウェア化に適したパルスニューロンモデルを用いた聴覚情報処理システムの構築に向けて、パルスニューロンモデルのみから構成される競合学習ネットワークの実現について検討した。そして各競合学習ニューロンの発火状況を調べる状態検出ニューロンを用いることにより、各ニューロンのしきい値を制御する新しい勝者ニューロン決定手法を提案し、本手法を用いた競合学習ネットワークを構築した。動作シミュレーションの結果、提案手法によりパルスニューロンモデルのみを用いることで入力信号の変化に追従した勝者ニューロンの決定が可能であり、聴覚情報処理に適したベクトル量子化が可能であることが確認できた。

キーワード ニューラルネットワーク、パルスニューロンモデル、聴覚情報処理、競合学習、SOM

### 1. ま え が き

人間の聴覚システムは高い性能を有しており、音源定位、音源認識、更には楽曲の認識など様々な機能を実現している。このような聴覚情報処理システムを工学的に応用することは聴覚障害者の補助、自律移動ロボットの環境把握など様々な用途に非常に有益である。脳においては簡易な演算を実行する神経細胞すなわちニューロンが非常に多く集まることで複雑な信号処理を行っている [1]。これらのニューロンはそれぞれ並列に独立した演算を行っており、これにより高速な情報処理を実現している。近年ニューロンによる情報処理を模擬したモデルとして人工ニューラルネットワークに関する研究が広く行われているが、これらではマカロックピッツ (McCulloch Pitts: 以下 MP) タイプのニューロンモデル [2] を主として用いており、実用問題への適用を考えた際には各ニューロン素子における

計算コストが大きいという問題点がある。

一方、聴覚情報処理システムに適したニューロンのモデルとして、パルスニューロン (Pulsed Neuron: 以下 PN) モデルが注目されている [3]。PN モデルは入出力信号としてパルス列を用いるニューロンモデルであり、演算コストが非常に小さく、デジタル回路若しくはアナログ電子回路として容易に実現可能である [4]。我々は、この PN モデルをベースとした汎用的な聴覚情報処理システムの構築に関する研究を行っている。この手法ではシステムの初段に設置された音-パルス変換器以降の処理をすべて並列に動作する PN モデルで処理することを目標としており、これにより並列動作性を生かした非常に高速な演算を小規模なハードウェアコスト上に実現できると考えられる。これまでの研究の結果、我々は上記システムを実現するために必要な部位として、音-パルス列変換モデル [5] 及び PN モデルによる各種特徴量抽出モデル [6], [7], 時間変化を含まない特徴量に対して特異的に発火する PN モデルの、教師あり学習による獲得 [8] などを実現しており、音-パルス変換部と多数の PN モデルを用いることで、入力信号のスペクトルパターンの違いを特定の PN モデルの発火として検出できることを確認している [7]。

<sup>†</sup> 名古屋工業大学大学院, 名古屋市

Graduate School of Engineering, Nagoya Institute of Technology, Gokiso-cho, Showa-ku, Nagoya-shi, 466-8555 Japan

<sup>††</sup> 名古屋工業大学, 名古屋市

Nagoya Institute of Technology, Gokiso-cho, Showa-ku, Nagoya-shi, 466-8555 Japan

a) E-mail: bw@nitech.ac.jp

これらの成果より聴覚情報処理システムを構築し、実用課題に適用することを考えた場合、実環境における音種の多様性によりパターン分類のために膨大な種類の特徴量が必要となること、そしてある特定のカテゴリに分類されるべき入力信号群においても変動、ノイズが多く含まれることが容易に推測される。このため安定した分類識別を行うためにはシステムが入力信号の変動に対する安定性を持ち、また膨大な次元数の特徴量を扱いやすい数次元のパターンへ変換できることが望ましい。

そこで、本論文では我々の提案する聴覚情報処理システムにおける、多次元ベクトルの次元圧縮、代表ベクトルを用いたパターン変動の吸収を目的として、PNモデルのみを用いたベクトル量子化ネットワークの構築を検討した。ニューラルネットワークによるベクトル量子化手法としては、Kohonen [9] により競合学習を用いた教師なし学習モデルが提案されており、その改良型モデルである自己組織化マップ (Self-Organizing Maps: 以下 SOM) とともに広く適用されている。しかし、従来の Kohonen 学習モデルは PN モデルに対して適用が困難であり、我々の目的である PN モデルの並列実行による高速な演算システムには不適合である。そこで本論文では、競合学習アルゴリズムの実装方法を検討することにより、PN モデルのみによる Kohonen の競合学習ネットワークの実現を行った。

## 2. 聴覚における情報処理

聴覚情報処理機構の概略は数々の生理学実験により次第に明らかとなってきた [1], [10], [11]。

この聴覚情報処理をソフトウェアの観点から見た場合、以下のように考えることができる。入力信号は周波数ごとの信号に分解された後、それぞれの振幅の包絡線が検出され、この情報を神経パルスと呼ばれるパルス列に変換して脳に送られている。そして、脳内の神経細胞によってパルス列の On, Off, 数量変化など様々な特徴量が並列に抽出される。これら複数の特徴量は上位の細胞層へと送られ、神経細胞による階層的な信号処理を重ねながら次第に複雑な特徴量の抽出が行われていく。また、聴覚情報処理をハードウェアとして見た場合、その特徴は生体パルス列を入出力情報として用いる神経細胞を基本ユニットとして用いていることにある。脳は独立して機能する膨大な数の神経細胞を並列に用いることで高速な演算を可能としている。

これらの知見をもとに我々は聴覚情報処理システムについて以下のような流れを想定している。1次元信号 (音圧) の時間変化であった入力信号は、まず周波数ごとの情報に変換されたのち信号の強度に反比例したパルス間隔をもつパルス列に変換される。このパルス列から PN モデル群により音の On, Off, AM, FM 変化など時間的变化特徴が独立して並列に抽出され、次第に空間的な信号 (複数の特徴検出ユニットの出力) へと変換される。そして最終的に時系列信号を空間的な発火パターンの順序変化として扱うことができるようになる。

筆者らの手法と同様に音を特徴抽出により空間パターンに変換して扱う手法として Hopfield による音声認識システムが提案されている [12]。この手法は各周波数成分の強度をパルスの位相に変換し、特定の位相パターンを検出する PNN により入力音を識別するものである。Hopfield はパルス頻度変調と比較して高速で解像度の高い識別ができることを報告している。しかし、筆者らはシステムの初段に設置した音-パルス変換器の出力を用いて音の認識だけでなく音源定位など聴覚系で行われている多様な情報処理を統合するシステムを目標としており、パルス頻度変調されたパルス列を用いることが最適であると考えられる。ただし、筆者らは近年多く報告されているパルス位相変調による情報処理能力を否定するものではない。提案するシステムにおいても多段の階層処理を通ったパルス信号では、保持する情報が特徴量の強度から特定特徴の有無へと変化していくことは必須であり、上位層においては必然的にパルスの位相を扱うことになると考えられる。生体における神経情報処理システムにおいても神経パルスの頻度変調説と位相変調説は相反するものではなく、末梢系における頻度変調と中枢系における位相変調が有機的に用いられているのであろう。

## 3. パルスニューロンモデル

前章で述べたシステムのメリットを最大限に生かすためには、各種特徴抽出を並列に行うことが不可欠であり、そのためには各処理ユニットにおける演算コストがなるべく小さいことが望ましい。つまり簡易な演算のみを行い、かつ独立して動作する基本ユニットの集合としてシステムを構築することが理想である。従来、人間の脳機能の工学的応用に関する研究では MP タイプのニューロンモデルが広く用いられてきた。しかし、このモデルは多次元ベクトルの内積演算を主と

しており、単一のニューロンモデルを考えた場合でも計算コストが大きいという問題点がある。

これに対し、入出力信号として神経パルスを模擬したパルス列を用いるニューロンモデル、すなわちパルスニューロン (Pulsed Neuron: 以下 PN) モデルは、乗算回路を必要としないため演算コストが非常に小さく、想定するシステムの基本ユニットとして最適であると考えられる。本論文で用いる PN モデルの模式図を図 1 に示す。この図において、前段の  $n$  番目のパルスニューロンからのパルス  $x_n(t) = 1$  が到着すると、その部分の局所膜電位  $p_n(t)$  が結合重み  $w_n$  分上昇し、その後時定数  $\tau$  で静止電位まで減衰する。PN モデルの内部電位  $I(t)$  はその時刻の各局所膜電位の総和として表される。ニューロンはこの内部電位がしきい値  $TH$  を超えたとき発火 (出力パルスを発生) する。ただし神経細胞には発火に関する不応期  $RP$  が存在するため、本モデルにおいてもある発火から  $RP$  の間は内部電位がしきい値を超えた場合でも発火はしない。

PN モデルの振舞いは時定数  $\tau$  によって大きく変化する。 $\tau$  が入力パルス列の最小パルス間隔  $T_P$  に対して小さい場合は膜電位の時間的な加算は起きず、PN モデルは入力パルスの空間的な同時到着を扱うことになる。一方、 $\tau$  が  $T_P$  に対して十分大きい場合は、各シナプスにおける膜電位の時間的な加算により入力パルス頻度を内部電位の大きさとして表現することが可能となる。このとき、頻度情報の時間分解能は  $\tau$  によって決定される。

PN モデルは各ニューロン間のデータ転送路が単線で済むためハードウェア上に複数のニューロンモデルを実装する際に非常に有利である。また、伝達する信号が頻度変調されたパルスのストリームであるため、

各ニューロンは基本的に非同期独立に演算が可能であり、大多数のニューロンを実装した場合にも厳密な同期処理を行う必要はないという特徴をもつ。

#### 4. パルスニューロンのための競合学習ネットワーク

本論文は我々の考える聴覚情報処理システムに導入すべく、PN モデルのためのベクトル量子化ネットワークを提案するものである。その手法としては現在ニューラルネットワークの応用例として広く用いられている Kohonen の競合学習則 [9] の PN モデルへの適用を考えるものとする。このベクトル量子化ネットワークを用いることにより、入力信号より生成された空間的な発火パターンを 1 または 2 次元の代表ベクトル群にマッピングする。また聴覚信号は時系列信号であるため、信号の変化に追従して勝者ニューロンが自動的に変化するよう検討を行う。

以下に、入力信号に対する評価値の算出方法、勝者ニューロンの決定方法、結合重みの更新方法に大別して提案手法の詳細について述べる。

##### 4.1 入力信号に対する評価値：内積型 SOM

Kohonen の競合学習においては、一般に各ニューロンの評価値として入力ベクトルとニューロンの結合重みのユークリッド距離が用いられている。しかし、この演算は PN モデルの基本演算である重み付き加算では実現が困難である。PN モデルの基本演算との親和性の高い評価値としては同じく Kohonen の提案する内積型の評価値がある [9]。この手法においては各ニューロンは評価値として入力ベクトルと参照ベクトル (結合重みの表すベクトル) の内積値  $EV$  を計算する。参照ベクトルを  $w$ 、入力ベクトルを  $x$  とし、両ベクトルのなす角を  $\theta$  とすると  $EV = w \cdot x = \cos(\theta)|w||x|$  であり、ニューロンの参照ベクトルのノルムを一定値と仮定するならば、この値は入力ベクトルと各参照ベクトルのなす角が小さいほど大きな値となる。よって参照ベクトルのノルムを正規化するならば、各ニューロンの内部電位は入力ベクトルと類似した結合重みをもつニューロンにおいて最大となり、これを直接評価値として用いることが可能となる。そこで本論文では PN モデルを用いた競合学習ネットワークとしてこの内積型の評価手法を用いることとし、各ニューロンの内部電位により勝者ニューロンを決定する。ただし、本手法では角度を評価値として用いているため、入力ベクトルのノルムの違いを扱うことはできない。

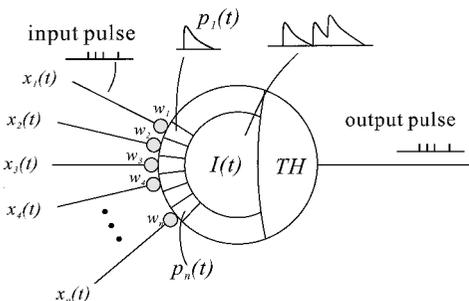


図 1 パルスニューロンモデル  
Fig. 1 A pulsed neuron model.

#### 4.2 勝者ニューロンの決定

Kohonen の競合学習においては最も評価値の高かったニューロンを勝者ニューロンとし、このニューロンのみに対して結合重みの更新が行われる。従来の Kohonen の競合学習ネットワークにおいては、各ニューロンにおいて計算された評価値をそのままニューロンの外へ出力しており、評価値の最大値を検索するためには何らかの外部モジュールが不可欠である。PN モデルにおいては、各ニューロンの内部電位  $I$  を外部に出力するためには大幅なモデルの変更が必要であり、また各ニューロンの出力が入力と同様のパルス列であるという PN モデルの利点を損なうことになるため適当ではない。更に最大値の検索が完了するまでの間は各ニューロンモデルの動作を待ち状態にする必要があり、PN モデルの独立動作性を損なうことになってしまう。

PN モデルに適用可能な勝者ニューロンの決定方法としては、Kohonen が側抑制結合と自己フィードバック結合をもつ神経回路網により勝者を決定できることを示しており [9]、二見ら [13]、井口ら [14] はこの手法をもとに、各ニューロン同士に側抑制結合をもたせ、お互いの出力を打ち消し合うことで最も内部電位の高かったニューロンだけが勝ち残る手法を提案している。しかし、この手法はフィードバック結合によりネットワークの安定点を求める方法であり、これら論文においても入力パターンが時々刻々と変化する場合の入力パターンへの追従性に関しては議論をしていない。また各抑制結合量などのパラメータの設定によっては、一つのニューロンも発火しない状況やある特定のニューロンの発火に収束してしまう状況が起きることは容易に推測できる。また、ネットワーク内のニューロンの数に変更された場合にもそのつど多数のパラメータを調整する必要がある。

この問題は勝者ニューロンを決定するためにニューロンの内部電位自身を変化させていることに原因があると考えられる。この場合内部電位はニューロン間の相対的な評価値の差を表しているにすぎず、もはや入力信号と参照ベクトルの相関を表現してはいない。このため、あるニューロンが勝者と決定された後に入力信号が変化した場合、ニューロンの内部値が入力信号の変化に追従しなくなる可能性が非常に高いのである。

勝者ニューロンを決定するために必要なのは最も評価値の高いニューロンを検索することであるが、これは最も高い評価値をもったニューロンだけが発火する

状況を維持することに置き換えることができる。つまり、内部電位を変化させるのではなく、各ニューロンのしきい値を同時に同じ量だけ変化させることにより、一つのニューロンの内部電位だけがしきい値を超えている状況を維持することで競合学習は可能である。

そこで、本論文では PN モデルのための競合学習手法として外部に数個の状態検出ニューロンをもうけることにより各ニューロンのしきい値を制御する方法を提案する。これら状態検出ニューロンの発火状況に応じて各競合学習ニューロンのしきい値を一律に変化させることで、ただ一つの競合学習ニューロンが発火する状況を保持し、これにより勝者ニューロンを決定する。このため、提案法では各競合学習ニューロンの内部電位は入力信号と参照ベクトルの相関値を常に保持することが可能となり、入力信号が変化した場合にもその変化に追従することができる。図 2 に提案手法を用いた競合学習ネットワークの模式図を示す。状態検出ニューロンとしては、競合学習層のニューロンが一つも発火していないときに発火する「無発火検出 (No-Firing Detection: 以下 NFD) ニューロン」と、競合学習層のニューロンが二つ以上発火しているときに発火する「複数発火検出 (Multi-Firing Detection: 以下 MFD) ニューロン」の二つを用いた。これら状態検出ニューロンは図 1 で示した PN モデルと同じものであり、それぞれ結合重み、膜電位減衰時定数、しきい値を変更することで実現している。これにより、特別なモジュールを用いることなく、PN モデルのみを用いて競合学習ネットワークを構築することが可能

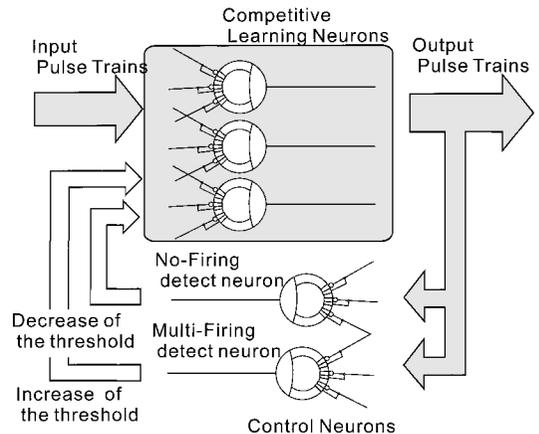


図 2 競合学習ニューラルネットワーク  
Fig. 2 The competitive learning neural network.

となる．NFD ニューロンが発火したときには，各競合学習ニューロンがより発火しやすいように一律しきい値を下げ，逆に MFD ニューロンが発火した場合には各競合学習ニューロンのしきい値を一律に上げることでより少ない数のニューロンが発火するように制御する．しきい値変化は各競合学習ニューロンにおける状態検出ニューロンからの結合重みとして実現が可能であり，この結合に対する膜電位減衰の時定数を十分に大きくすることで実質定数として用いることができる．いずれの制御ニューロンも，発火条件は競合学習層のニューロンの数によらず一定であるので，提案手法はネットワーク規模が変更されても同じ制御ニューロンを用いることが可能であるという利点をもつ．

#### 4.3 結合重みの更新

結合重みの更新は，上記ネットワークにおいて発火したニューロンを勝者ニューロンと考え，各ニューロンが発火した場合に実行することとする．学習すべき入力パターンの表現法としては，結合重みを 1 に固定したシナプスにおける局所膜電位，入力膜電位  $p_i$  を用いる．図 3 に図 1 に対して学習に必要な要素を加えた競合学習用パルスニューロンモデルを示す．入力パルス列数は  $n$  である．この図において，「無発火検出ニューロン」からの結合重み  $w_{no}$  がしきい値の減少変化量に相当し，「複数発火検出ニューロン」からの結合重み  $w_{mlt}$  がしきい値の上昇変化量に相当する．ただし，それぞれは内部電位の変化量として実現しているため，符号が逆転し， $w_{no} > 0$ ， $w_{mlt} < 0$  である．各膜電位  $p_i$  の結合重みはそれぞれ 1 である．今システムをサンプリング周波数  $F_s$  の離散時間系とし， $\Delta t = 1/F_s$ ，時刻  $t$  における NFD，MFD ニューロンの出力をそれぞれ  $y_{ndf}(t)$ ， $y_{mdf}(t)$  とする．前

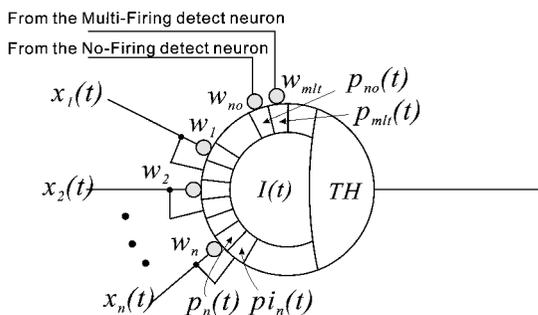


図 3 競合学習用パルスニューロンモデル

Fig. 3 The pulsed neuron model for competitive learning.

述のように NFD，MFD ニューロンに対する膜電位  $p_{no}(t)$ ， $p_{mlt}(t)$  の減衰時定数が十分大きいと仮定すると，時刻  $t + \Delta t$  における競合学習ニューロンの内部電位  $I(t + \Delta t)$  は次式のように記述できる．

$$I(t + \Delta t) = \sum_{i=1}^n \{e^{-\Delta t/\tau} \cdot p_i(t) + w_n \cdot x_i(t + \Delta t)\} + p_{no}(t) + w_{no} \cdot y_{ndf}(t + \Delta t) + p_{mlt}(t) + w_{mlt} \cdot y_{mdf}(t + \Delta t) \quad (1)$$

各ニューロンの結合重みにおいてそのノルムが正規化されることを前提とすれば，時刻  $u$  における勝者ニューロンつまり発火したニューロンにおける結合重みの更新は次式で表すことができる．

$$w_i(u + \Delta t) = w_i(u) + \alpha(u) \cdot p_i(u) \quad (1 \leq i \leq n, 0 \leq \alpha(u)) \quad (2)$$

各更新の後，結合重みはノルムが 1 となるよう正規化される．

入力パルス列によって発生する内部電位の総量，つまり入力ベクトルのノルムが大きく変動する場合，この変動量を吸収するためにしきい値の変化が生じることになり，結果としてしきい値の変化が入力ベクトルの方向変化に追従できない場合がある．そこで，内部電位  $I(t)$  に対して，入力膜電位  $p_i$  の総和を一定の比率  $\beta_{pi}$  ( $0 \leq \beta_{pi} \leq 1$ ) であらかじめ差し引くことで，入力信号のノルム変動に対する内部電位の変化を抑える方法を導入した．これは状態検出ニューロンによって行われる制御がある種のフィードバック制御として働くのに対して，フィードフォワード制御的に働く機構と考えることができる．この制御機構はニューロンのしきい値に対してのみ働き，内部電位及び結合重みの更新量に対しては影響を及ぼさない．

これまで述べてきた結合重みの更新を勝者ニューロンの近傍のニューロンに対しても適用することにより，SOM アルゴリズムを実現することが可能である．後述のシミュレーションにおいては，すべての競合学習ニューロンを有効に学習に参加させるため，そして学習後の結合重みの評価を容易にするために SOM アルゴリズムを適用することとする．

## 5. 学習シミュレーション

本章では計算機上のシミュレーションにより提案手法の動作を検証する．なお，本論文においては競合学習ネットワークの入力データにおける最小パルス間隔

$T_P$  は各ニューロンの不応期  $RP$  に等しいものとする．ある PN モデルの出力パルス列における不応期は，そのまま次段の PN モデルの入力データの最小パルス間隔に相当する．このため，ハードウェアへの実装を考えた場合，これら二つの値は同一値にそろえておくことが望ましい．また各競合学習ニューロン及び制御ニューロンは同一の PN モデルを用いて，実現することを想定し，いずれのニューロンも同じ不応期  $RP$  をもつものとする．

5.1 簡易パターンによる学習動作及び時間分解能の検証

提案するネットワークを用いることで競合学習が可能であり，入力の変化に追従して勝者ニューロンが自動的に変化すること，そして学習後入力パターンに類似の結合重みが形成されることを確認するため学習実験を行った．図 4 に学習に用いた入力パターンを  $5 \times 5$  のマトリックスで示す．それぞれ各マスは入力パルスの発火頻度を表しており，黒いマスは発火頻度 1000 回/s の状態を表し，白いマスは 0 回/s の発火を表す．学習後の結合重みの確認を容易にするため，それぞれ 0 から 9 の数字を模したパターンとしている．このパターンをそれぞれ 100 ms ずつ提示し，計 1 秒の学習データを用いた．サンプリング周波数は 48 kHz である．競合学習ニューロンは 6 個用意し，結合重みの初期値を乱数により与え，SOM アルゴリズムにより 2000 回の学習を行った．近傍ニューロンに関しては，1000 回の学習で半径が 0，つまり自身のみが学習対象となるように学習回数が増えるにつれて線形に範囲を狭めていく．ニューロンは 1 次元上に配置しているとし，終端が存在しないようにループ上に配置している．実験に用いた各種パラメータを表 1 に示す．

学習実験結果を図 5，図 6 及び表 2 に示す．図 5 は学習に用いた入力データ (a) 及び学習後のネットワークに対してあらためてデータを入力したときの各競合学習ニューロンの発火の様子 (b) である．横軸に時間を，縦軸にニューロンを示し，横軸の目盛は入力パターンの変化時刻に一致している．それぞれのマスは 10 ms 当りのニューロンの発火頻度を濃淡で表してい

る．この結果より各入力パターンごとに特定のニューロンが発火しており，また入力パターンの変化後およそ 10 ms の時間ずれで出力ニューロンが変化していることが分かる．この時間ずれの原因としては表 1 に示したように各競合学習ニューロンの局所膜電位の減衰時定数  $\tau$  が 10 ms に設定されているため，前の入力パターンの影響が 10 ms 程度残ってしまうためであると考えられ，理論的に説明可能なずれであるといえる．図 6 は学習後の各ニューロンの結合重みである．

表 1 ニューロンの各種パラメータ  
Table 1 The parameters of the neurons.

[共通パラメータ]	
不応期 $RP$	1 ms
[競合学習ニューロン]	
ニューロン数	6
しきい値 $TH$	0.0
学習係数 $\alpha$	$1 \times 10^{-6}$
膜電位減衰の時定数 $\tau$	10 ms
学習回数	2000
学習半径の収束回数	1000
$w_{no}$	1.0
$w_{mit}$	-1.0
$\beta_{pi}$	0.23
[無発火検出ニューロン]	
各競合学習ニューロンに対する結合重み	-1.0
しきい値	-0.01
膜電位減衰の時定数 $\tau_{no}$	1 ms
[複数発火検出ニューロン]	
各競合学習ニューロンに対する結合重み	1.0
しきい値	2.0
膜電位減衰の時定数 $\tau_{mit}$	1 ms

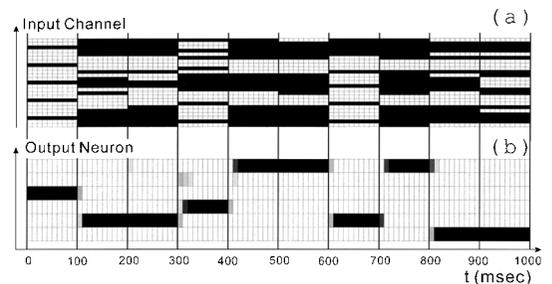


図 5 入力パルス列及び競合学習後の各ニューロンの発火の様子  
Fig.5 The input pulse trains and the firing of the neurons after learning.



図 4 学習に用いた 25 次元パターン  
Fig. 4 The input patterns for the learning simulation.

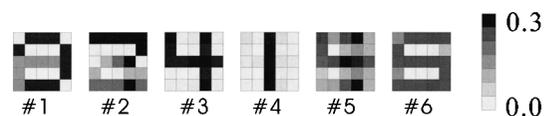


図 6 競合学習後の結合重み  
Fig.6 The connection weights of the neurons.

値の大きさをそれぞれ濃淡で表している．また表 2 に入力パターンと各ニューロンの結合重みのなす角の余弦を示した．この表中において，各入力パターンに対して最も大きい余弦の値を太字で示してある．図 6 及び表 2 より，提案手法による学習の結果各ニューロンが入力パターンを結合重みのパターンとして獲得しており，またニューロン#1 とニューロン#6 も隣接する関係にあるので，それぞれ類似度の高い結合重み同士が近傍に位置していることが分かる．このことから提案する勝者ニューロンの決定方式が有効であり，またこれによりベクトル量子化が可能であることが確認できた．なお，図 5 においてニューロン#5 が発火しておらず，表 2 においても本ニューロンが一度も最大余弦値をもっていない．これは SOM アルゴリズムにおいては各ニューロンが位相関係を保ったまま量子化誤差を減少させるため，入力空間中に入力パターンが遍在する場合に一度も発火しないニューロンが生成されてしまう，いわゆるデッドノードという現象が起きていると考えられる．

次に入力信号の時間変化に対する提案手法の追従性を検証した．図 7 に各パターンの提示時間を 20 ms，10 ms と変化させた場合の学習実験結果を示す．ただし，学習の進捗をそろえるため同じ入力パターンを繰り返すことで，それぞれ 1 s の学習データを用いた．図 7 は，それぞれ各パターンの提示時間を 20 ms とした場合の入力データ (1a) 及び学習後のネットワークの出力 (1b)，各パターンの提示時間を 10 ms とした場合の入力データ (2a) 及び学習後のネットワークの出力 (2b) を 1 周期分示している．図 7 (1a)，(1b) では横軸の目盛が提示パターンの変化時刻を示しており，また図 7 (2a)，(2b) では各マスごとに提示パターン

が変化している．この結果より，提示時間を 20 ms とした場合には入力パターンの変化に追従して発火するニューロンが明確に変化しており，学習が成功していることが分かる．ただし，パターンの提示条件の違いにより 100 ms の学習結果とは異なる学習結果となっている．入力パターンの変化と出力ニューロンの変化間の時間ずれは図 5 と同様に約 10 ms であり，これは競合学習ニューロンの局所膜電位の減衰時定数  $\tau$  が 10 ms に設定されていることに起因すると考えられる．

一方，提示時間を 10 ms とした場合には入力パターンの変化に対して発火するニューロンが明確に変化をしていない．また最初の 30 ms を除いて単一のニューロンが明確に発火するには至っておらず，入力信号の時間変化に追従できていないことが分かる．紙面の都合により詳細は省略するが，この場合学習後の結合重みについてはどのニューロンも類似した参照ベクトルを維持しており，学習に失敗していることが分かった．提示時間 10 ms において学習が失敗したのは，提示パターンの時間変化にニューロンの時間分解能が追従できなかったためと考えられ，理論的に妥当な限界と考えられる．

以上の実験において，更に時間分解能を上げるためには  $\tau$  をより小さな値に設定すればよい．しかし，3. において述べたように，競合学習ニューロンにおいて入力データの頻度情報を扱うためには  $\tau \gg T_P$  が成り立つ必要がある．また，本章の冒頭で述べたように本論文においては  $T_P = RP$  を仮定しているため，これらパラメータの間には  $\tau \gg T_P = RP$  という関係が成り立つことになる．このため， $\tau$  を小さくすると

表 2 入力パターンと結合重みベクトルのなす角の余弦  
Table 2 The cosine of angles between input patterns and connection weights.

digit	neuron					
	#1	#2	#3	#4	#5	#6
1	0.33	0.33	0.17	<b>0.99</b>	0.47	0.33
2	0.73	<b>0.95</b>	0.52	0.41	0.79	0.86
3	0.76	<b>0.96</b>	0.46	0.42	0.77	0.84
4	0.54	0.50	<b>1.00</b>	0.23	0.85	0.64
5	0.83	0.83	0.70	0.41	0.90	<b>0.98</b>
6	0.87	0.78	0.63	0.40	0.85	<b>0.98</b>
7	0.55	<b>0.84</b>	0.54	0.21	0.65	0.57
8	0.89	0.88	0.67	0.39	0.89	<b>0.98</b>
9	<b>0.95</b>	0.77	0.61	0.43	0.83	0.87
0	<b>0.93</b>	0.63	0.47	0.32	0.68	0.77

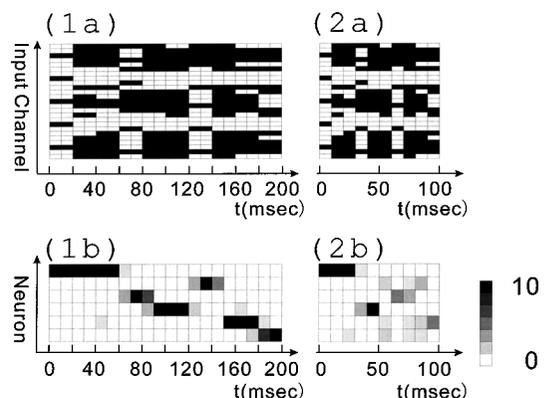


図 7 提示時間の短縮学習による出力発火の変化  
Fig. 7 The firing of the neurons with shorter projections.

いうことは結果的にシステム全体のサンプリング周波数を上げることで時間分解能を向上させるのと同義となってしまう。以上より提案手法の時間分解能は入力データの最小パルス間隔  $T_P$  の 10 倍程度であると考えることができる。

我々のこれまでの実験結果から可聴音を対象とする場合には入力信号の強度変化の分解能は 10 ms 程度でよいことが分かっており [5], [7], これより最小パルス間隔は 1 ms 程度でよいことになる。これは現存するハードウェアの動作クロックに対して十分長い間隔であり、提案手法は我々の想定する聴覚情報処理システムとして十分な時間分解能を有することが分かる。

5.2 連続変化データによる量子化分解能の検証

前節では提案手法の時間軸方向の分解能について検証を行った。本節では連続的に変化する入力パターンを用いて、入力パターンの量子化分解能を検証する。一般的に同数の参照ベクトルによって均等に分布した同数の入力ベクトルを量子化する場合、次元数が少ない程ベクトル間の角度が狭くなり各ニューロンにおける評価値の差が少なくなる。また内積型の評価法を用いる本手法では 1 次元データの量子化は行えない。そこで本実験では量子化分解能の検証用として 2 次元の連続頻度変化パルス列パターンの量子化課題を用いた。入力信号はそれぞれ時刻  $t$  における瞬時発火頻度  $FR_1(t), FR_2(t)$  がそれぞれ  $|\cos(\frac{2\pi t}{T})|, |\sin(\frac{2\pi t}{T})|$  で与えられるとし、この逆数より瞬時発火間隔  $FI_1(t), FI_2(t)$  を求め、前回の発火から  $FI_n(t)$  経過した場合にパルスを生成した。ただし最小パルス間隔  $T_P = 1 \text{ ms}$  である。時間分解能の限界の影響を防ぐため頻度関数の周期  $T$  は 20 s と十分長くした。サンプリング周波数は 48 kHz である。学習データとしては 10 s のデータを用いた。競合学習ニューロン数を 5 個, 10 個, 20 個として実験を行った。競合学習ニューロン数が増えるほど量子化誤差を減らすことが可能となるが、各ニューロンの内部電位の差が少なくなるため勝者ニューロンを決定することが難しくなると思われる。競合学習ニューロンの各種パラメータを表 3 に示す。なお、各制御ニューロンについては前述の学習実験と全く同じパラメータのものを用いており、詳細は表 1 を参照されたい。

図 8 に学習実験の結果を示す。上から順にそれぞれ入力データ (a), 競合学習ニューロンの数を 5 個 (b), 10 個 (c), 20 個 (d) としたときの学習後のネットワークの出力である。この結果から競合学習ニューロンの

表 3 競合学習ニューロンの各種パラメータ

Table 3 The parameters of the competitive learning neurons.

[競合学習ニューロン]	
しきい値 $TH$	0.0
学習係数 $\alpha$	$1 \times 10^{-7}$
膜電位減衰の時定数 $\tau$	10 ms
学習回数	4000
学習半径の収束回数	2000
$w_{no}$	0.01
$w_{mt}$	-0.01
$\beta_{pi}$	0.7

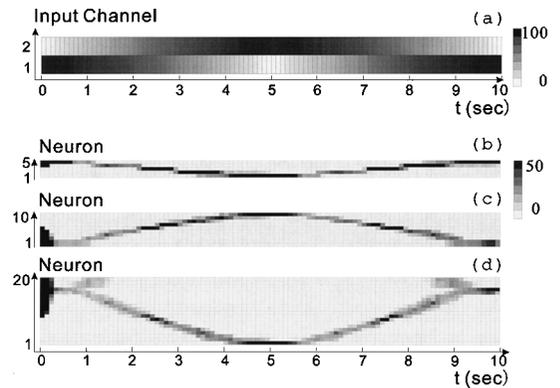


図 8 入力パルス列及び競合学習後の各ニューロンの発火の様子

Fig.8 The input pulse trains and the firing of the neurons after learning.

数に応じてトポロジカルなマッピングが獲得されることが分かる。ただし (d) においては同一の入力に対して 2 個所のニューロンが発火する傾向が見られる。これはネットワークの量子化分解能を超えた数の競合学習ニューロンが存在するために、一部のニューロンが入力空間において折り返されてしまったために起きたものであろう。

前述のように本実験は比較的難易度が高いと考えられる 2 次元の入力データを用いて行ったが、1., 2. で述べたように我々の想定するネットワークにおいては、入力データを多次元パターンとして表現している。今回の実験結果より、2 次元ベクトルに対して角度として 10 分割程度の量子化分解能が得られており、これは実用上十分な能力と考えられる。

以上、本節では学習シミュレーションにより提案手法の有効性を検討した。その結果、提案手法はパルス頻度変調された時系列信号に対して競合学習が可能であり、我々の想定する聴覚情報処理システムのための競合学習ネットワークとして十分な時間分解能、量子

化分解能をもつことが確認された。

## 6. む す び

本論文は PN モデルから構成される聴覚情報処理システムの構築に向けて、PN モデルのみを用いた競合学習ネットワークの実現方法について検討した。そして状態検出ニューロンを用いることにより各ニューロンのしきい値を制御する、新しい勝者ニューロン決定手法を提案した。動作シミュレーションの結果、提案手法を用いることで入力信号の変化に追従した勝者ニューロンの決定が可能であり、聴覚情報処理に適したベクトル量子化が可能であることが確認できた。

PN モデルは演算コストが非常に小さいので電子回路として容易に、かつコンパクトに実装が可能であり、またそれぞれ独立した並列処理が可能である。このため提案手法は LSI, FPGA などに大量の PN モデルを実装しこれらを結線することにより容易に実現が可能である。またこれまでに筆者らが提案している各種特徴抽出ニューロンや教師あり学習ネットワークも同じ PN モデルを用いているため、同一のハードウェア上にこれらすべての機能を実現することが可能である。PN モデルから構成されるニューラルネットワークはコンパクトなハードウェア上で高速な情報処理が可能であり、今後の実用問題への応用が期待される。

謝辞 本研究の一部は堀情報科学振興財団の助成を受けた。記して感謝致します。

## 文 献

- [1] G.M. シェパード (著), 山元大輔 (訳), ニューロバイオロジー (第 2 版), 学会出版センター, 1990.
- [2] W.H. Pitts and W.S. McCulloch, "A logical calculus of the ideas immanent in nervous activity," Bull. Math. Biophysics, vol.5, pp.115-133, 1943.
- [3] W. Maass and C.M. Bishop, Pulsed Neural Networks, MIT Press, 1998.
- [4] 田中愛久, 黒柳 奨, 岩田 彰, "FPGA のためのニューラルネットワークのハードウェア化手法," 信学技報, NC2000-179, 2001.
- [5] 黒柳 奨, 岩田 彰, "音源方向定位聴覚神経系モデルによる ITD, ILD の脳内マッピングの実現," 信学論 (D-II), vol.J79-D-II, no.2, pp.267-276, Feb. 1996.
- [6] 中尾裕之, 黒柳 奨, 岩田 彰, "パルスニューラルネットワークによる音源の方向情報を用いた音像抽出モデル," 信学技報, NC2000-108, 2001.
- [7] 坂口晋也, 黒柳 奨, 岩田 彰, "環境把握のための音源識別システム," 信学技報, NC99-70, 1999.
- [8] 黒柳 奨, 岩田 彰, "パルスニューロンモデルのための教師無し学習則," 信学技報, NC99-69, 1999.
- [9] T. Kohonen, Self-Organizing Maps, Springer-Verlag,

1995.

- [10] 勝木保次, 村田計一, 吉田登美男, 亀田和男, 新版 聴覚と音声, pp.1-240, 電子情報通信学会, 1980.
- [11] J.O. Pickles, An Introduction to the Physiology of Hearing, Academic Press, 1988.
- [12] J.J. Hopfield, "Computing with action potentials," Neural Information Processing System, 10, pp.166-172, MIT Press, 1998.
- [13] 二見亮弘, 星宮 望, "時系列パターンを学習・弁別する神経回路モデル," 信学論 (A), vol.J68-A, no.5, pp.481-488, May 1985.
- [14] 井口尚彦, 福島邦彦, "パルス型神経回路モデルの自己組織化," 信学技報, NC2000-131, 2001.

(平成 15 年 2 月 3 日受付, 9 月 5 日再受付)



黒柳 奨 (正員)

平 3 名工大・電気情報卒。平 5 同大大学院博士前期課程了。平 8 同大学院博士後期課程了。同年名工大・電気情報・助手。平 15 同大大学院・助手, 現在に至る。ニューラルネットワーク, 聴覚情報処理に関する研究に従事。博士(工学)。日本音響学会, 日本神経回路学会, 日本エム・イー学会各会員。



岩田 彰 (正員)

昭 48 名大・工・電気卒。昭 50 同大大学院修士課程了。同年名工大・情報・助手。昭 57 年 4 月より昭 58 年 10 月まで, ドイツ連邦共和国ゲーゼン大学医学部医情報研究所客員研究員。昭 59 名工大・情報・助教授。平 5 同大・電気情報・教授。平 14 同大・副学長, 現在に至る。ニューラルネットワーク, 生体情報処理, 医療情報システム, 情報セキュリティ, インターネットコンテンツ開発技術に関する研究に従事。工博。平 5 年度本会論文賞受賞, 平 10 年度情報処理学会 Best Author 賞受賞。情報処理学会, 日本エム・イー学会, 日本心電図学会, 日本神経回路学会, 日本医療情報学会各会員, IEEE Senior Member。