

TR-I-0107

ニューラルネットワークによる
予測モデルを用いた音韻認識

**Phoneme Recognition
Using Neural Prediction Models**

遠藤 隆、田村 震一、中村 雅己
*Takashi Endo, Shinichi Tamura and
Masami Nakamura*

1989.8.31

概要

ニューラル予測モデル(NPM)のBDG音韻認識への応用についての実験を行った。NPMではいくつかのニューラルネットが分担して音韻の予測を行っているが、BDG音韻の構造に合った分担を行っており、認識率についても92.46%と悪くない結果を得た。またテストデータに対する認識率がトレーニングデータに対する認識率と比べてもあまり低下しなかった。また、ニューラルネットの隠れ層の出力関数に線形関数を使ったNPMについても実験を行い、性能を評価した。

ATR Interpreting Telephony Research Laboratories
ATR 自動翻訳電話研究所

© ATR Interpreting Telephony Research Laboratories
© ATR 自動翻訳電話研究所

1.はじめに

近年、ニューラルネットワークを音声情報処理の研究に利用することが盛んに行われ、音声認識の分野では時間遅れ神経回路網(TDNN)[1]等の新しい認識モデルが提案され、評価が行われている。そのなかで最近提案された「ニューラル予測モデル(Neural Prediction Model、NPM)」[2]を用いて、B、D、G音韻の認識実験を行った。また、NPMでは予測に用いるニューラルネットは隠れ層の出力関数に非線形(シグモイド関数)関数を用いて非線形予測を行っているが、それを線形($y=x$)に替えて線形予測で認識を行った場合、どの程度まで性能が変わるのか見てみる。

2.ニューラルモデル予測モデルを用いた音韻認識

ニューラルネット予測モデルとは入力音声の特徴ベクトルを n 個のニューラルネットに分担して予測するモデルで、入力音声の特徴ベクトル時系列を n 個の部分に分割し、その部分ごとに各ニューラルネットワークが分担して予測を行う。予測された特徴ベクトルと入力された特徴ベクトルの距離の2乗を全フレームにわたって加えたものを予測誤差と定義し、特徴ベクトル時系列の分割は予測誤差が最小になるように分割する。また、ニューラルネットの受け持つべき部分は0番目のネットの受け持つ部分はデータの先頭から1番目の部分、1番目のネットの受け持つべき部分はその次、と順番が決まっています、1つのネットは最低1フレームを予測しなければならず、途中のニューラルネットを使わずに飛ばすことができない。したがって分割はDPを用いて決定することができる。

予測に用いられるニューラルネットにはfeed-forward型とrecurrent型の二つがあり、feedforward型は時刻 $t-1$ までの有限個の特徴ベクトルを入力として時刻 t の特徴ベクトルを予測する。recurrent型は時刻 $t-1$ の特徴ベクトルと時刻 $t-1$ での隠れ層の出力値を入力として、時刻 t での特徴ベクトルを求める。通常、隠れ層の出力関数はシグモイド関数を用い、出力層では線形($y=x$)を用いる。

NPMを用いて認識をする場合は、認識対象のカテゴリー数だけのNPMを用意し、各々のカテゴリーのNPMはある入力音声について各々のカテゴリーのNPMで予測を行い、予測誤差が最小となるNPMのカテゴリーを認識結果とする。

3. 認識実験による評価

3.1 実験条件

実験に使用したデータはATRのデータベースの一部である、NHKのアナウンサーが防音室で発生した5240単語を16ビット20KHzでサンプリングしたものを12KHzにダウンサンプリングし、256ポイントのハミング窓をかけてFFTを行った後、特徴パラメータとして10ms毎に16次元のメルスケールのFFT出力に変換した。データの切り出しはスペクトログラムに基づいてラベラーが目視で位置を決めたB,D,Gと母音の境界が中心になるように15フレーム分を取り出してきた。入力の値は15フレーム分で平均値0.0、最大値1.0、最小値-1.0に正規化されている。このうち学習データとしては偶数番目の単語中から抽出したデータを用い、テストデータとして奇数番目の単語から抽出したデータを用いた。

このようにして学習データはBA、DA、GAの認識実験についてはBA:53個、DA:90個、GA:96個でB、D、Gの認識実験ではそれぞれ261個づつを用意した。テストデータとしてはBA、DA、GAの実験ではBA:66個、DA:81個、GA:96個を用意した。B、D、Gの実験ではそれぞれ251個づつ用意した。

3.2 実験方法

今回の実験ではfeed-forward型の、入力層、隠れ層1層、出力層からなる3層のニューラルネット5個で構成されたNPMを用いた。カテゴリとしてはB、D、G(もしくはBA、DA、GA)の3つがあるので、NPMは各々のカテゴリ毎に1つ用意し、合計3個のNPMを用いた。隠れ層のユニット数は10個である。入力時刻 $t-2$ 、 $t-1$ の2フレーム分の特徴ベクトル(16次元メルスケールFFT)を入力して時刻 t のフレームの特徴ベクトルの予測を行っている。ニューラルネットの学習にはDCP法[3]を用いた。学習の初期の段階においては極端な時間軸の伸縮が起こる可能性を回避するために、DPマッチングの際に整合窓によってDPパスに制限を加えた。この整合窓幅は全ての実験に際して共通である。整合窓幅を表1に示す。

実験は、大きく分けてつぎの2つについて行った。

・後続母音を/A/に限定したBA,DA,GAの認識実験

・後続母音を限定しないB,D,G音韻の認識実験

3.3 後続母音を/A/に限った時の認識実験

3.3.1 予測誤差と認識率

NPMによる認識は互いに独立して学習を行ったNPMの予測誤差の比較によって行われるため、それぞれのNPMの予測誤差を揃える必要があるのかどうかを確かめるため、他のNPMとは無関係に予測誤差が最小になるまで学習を行った場合と、予測誤差が各カテゴリーのNPMでほぼ等しくできる最小の値まで学習をやめた場合とでどちらの認識率がよいかの実験を行った。ここでいう予測誤差とはBAのトレーニングデータに対するBAのNPMの平均予測誤差、GAのトレーニングデータに対するGAのNPMの平均予測誤差、DAのトレーニングデータに対するDAのNPMの平均予測誤差を指している。

3.3.1.1 学習方法

学習データをBA53個、DA90個、GA96個用意して、まずは各カテゴリーのNPMの予測誤差を下げられるところまでさがりまで学習を行った。つぎに予測誤差を揃えた学習を行うために、それらのNPMのなかで予測誤差が最大のものを選び、その他のカテゴリーのNPMをその予測誤差とほぼ等しいところまで学習を行った。学習には最初から全ての学習データを与えて学習を行った。1つのカテゴリーのNPMについて約10時間から12時間ほど学習に時間がかかった。

3.3.1.2 実験結果

表2~9の様な結果が得られた。表中の予測誤差とはは出力層の1ユニット当りの予測誤差である。予測誤差を揃えると、BAの認識率がぐっと下がる。これは予測誤差を揃えるために、BAは学習を途中で打ち切られてしまったため、十分BAを予測できるまで学習が進まなかったためと思われる。従って、予測誤差を揃えることよりもニューラルネットを十分学習させ、おのこのNPMの予測を確かなものとする方が認識率の向上につながると思われる。しかし、どちらの場合でもテストデータに対するBAの認識率が他と比べてだいぶ悪い。表5および表9を見るとBAをBAのNPMで予測されたときの予測誤差の平均値が、DAのNPMで予測させたときの予測誤差の平均値と近い値であることから、BAとDAがうまく識別できないためと思われる。

3.3.2 データ数と認識率

3.3.1 の実験結果ではBAの認識率が悪かったが、その実験ではBの学習データの数が他と比べて半分程度しかなかった。それがBAの認識率の低下の原因になっているかどうかを調べるため、学習データの個数をすべて53個に揃えて学習を行い、認識実験を行った。

3.3.2.1 学習方法

学習データの数を53個に揃えて、BA,DA,GAの全てのNPMについて学習をやり直した。また、リンクウエイトの初期値は前の実験とは異なるものを用いた。学習は最初から全ての学習データを与えて行き、これ以上予測誤差が下がらないところまで学習を行った。

3.3.2.2 結果

その結果を表10~13に示す。これをみるとBAとDAの認識率は近い値となっているが、GAの認識率はBA、DAとくらべてだいぶ良い。したがってBAの認識率が低い理由は学習データの数だけではないものと思われる。またBAのNPMの予測誤差を表4と表12で見比べると、同じ学習データを用いたにも関わらず、だいぶ異なっていることがわかる。これは初期のリンクウエイトの値が異なったため、異なるローカルミニマムに陥ったものと思われる。また、ネットワークの学習方法によってもローカルミニマムへの陥り方が異なっていた。この実験では最初から全ての学習データを与えて学習を行ったが、試しに最初は10個の学習データを与え、徐々に増やしていくという方法で学習させたところ、トレーニングデータに対する平均予測誤差がBAでは0.019079、DAでは0.020690という大きな値のところでもローカルミニマムに陥ってしまった。従って、学習の際ははじめから全てのデータによって学習するか、徐々に増やしていく方法をとる場合でも極端に少ない学習データからスタートしない方がよいと思われる。

3.3.3 ニューラルネットの予測分担

つぎに、各カテゴリーのNPMのニューラルネットが音韻のどの部分の予測を受け持っているのかを、トレーニングデータのいくつかについて見てみたのが図1~3である。各図の下に振られている数字はその部分の予測を担当したニューラルネット番号である。ここで用いたNPMは認識率の一番よかった、学習データをすべて使い予測誤差を下げるまで下げたNPMである。これらを見るとどのカテゴリーのNPMでも0番は切り出しデータの前の音韻の後端及びバズバー、1番のネットがバズバー、2番で破裂、3番母音への遷移及び母

音、4番母音といったようにきれいに役割分担がなされているのがわかる。ところで、この図を見ると最後の4番のニューラルネットはほとんど役割を果たしていないように見える。そこでこの4番のニューラルネットを除いて、0番から3番までの4つのニューラルネットだけでNPMを構成し認識実験を行ったところ、表14~17の様な結果が得られた。認識率について表2~3と表14~15を比較するとネットワークを5個用いていたときと比べて認識率が落ちていないことから、4番のニューラルネットは予測にあまり貢献していないことがわかる。また、平均予測誤差について表4~5と表16~17を比較すると予測誤差がさがっていることから、4番のニューラルネットは予測に全く役に立っていないものと思われる。これはおそらく学習の初期の段階の整合窓によって3番と4番のニューラルネットが母音の予測に割り当てられ、ほとんど定常状態にある母音部分の予測にはニューラルネットは1つで十分で、4番のニューラルネットはあまり使われることなく学習回数が少なくなってしまい、学習が進まず、予測がうまく行われないためと思われる。従って、NPMに効率よく予測を行わせるためには学習の初期の整合窓は認識対象の性質に合わせて適切にほどこしてやらなければならない。

3.3.4 NPMが予測したベクトル

次に、各NPMによって予測された特徴ベクトルを観察すると、あるカテゴリーのデータをそのデータのカテゴリーとは別のカテゴリーのNPMによって予測させても比較的オリジナルのデータと近い予測がえられるのがわかる(図4~6)。ここでニューラルネット、特に母音やバズバー部分の予測を受け持っているニューラルネットが予測を行わずに入力されたデータをほとんどそのまま出力している可能性が考えられたので、各ニューラルネットにいくつかのパターンを入力して出力結果を観察してみた。その結果が図7~9である。各図の左が入力で、右が出力である。出力の見方は下にかいてあるBA,DA,GAがカテゴリーを示している。その上の数字はそのカテゴリーのNPMの何番目のニューラルネットが予測したものかを示していて、この数字は図1~3でのニューラルネット番号と対応している。これを見てみるといずれのニューラルネットにおいても、入力そのまま出力されることはないことが確かめられた。このことより、少なくともなんらかの予測を行っていることがわかった。

3.4 後続母音を限定しないときの認識実験

後続母音を指定しない場合については隠れ層の出力関数がシグモイド関数のものと線形関数($y=x$)の2つのNPMについて実験を行った。実験に用いたNPM

の構成はBA,DA,GAの認識実験に用いたものと隠れ層の出力関数以外は同様である。

3.4.1 学習方法

シグモイド版では最初はB,D,Gそれぞれ70個ずつから学習をはじめ、7個ずつ学習データを増やしてゆき、最終的にB,D,Gそれぞれ261個のデータで学習を行った。線形版ではローカルミニマムの危険性がないので、最初7個ずつのデータから始めて、3個ずつ学習データを増やして行った。最終的にはB,D,Gそれぞれ261個のデータについて学習を行わせた。

3.4.2 結果

時間の関係上、学習が最後まで、すなわちこれ以上予測誤差が下がらないところまで行えたのはシグモイド関数のGのNPMだけであったことをはじめにおことわりしておく。シグモイド版の実験結果を表18~21に、線形版の実行結果を表22~25に示す。まだニューラルネットの学習が終了していないので最終的にどうなるかはわからないが現時点では、出力関数にシグモイド関数を用いた方が多少認識率がよい。また、シグモイド版ではテストデータに対する認識率がトレーニングデータに対する認識率と比べてほとんど低下していない。また平均予測誤差について表20~21と表24~25を比較するとDに対する予測誤差がGのNPMで一番大きく、ついでB、Dという順番で値も似通っているがDの認識率ではだいぶ異なる。

3.4.3 ニューラルネットの予測分担

各ニューラルネットが音韻のどの部分を予測しているかをトレーニングデータのいくつかについて観察すると、シグモイド版は図10~12、線形版は図13~15の様になる。シグモイドの場合も線形の場合も0番のネットがバズバー及び切り出し部分の前の音韻の後端及びバズバー、1番がバズバー、2番が破裂、3番母音への遷移、4番が母音の部分の予測を受け持っている。シグモイド版のD(図8)の中央と右のデータは認識では誤認識をしているが、ニューラルネットの予測分担はそれほどずれてはいない。

シグモイド版のNPMがシグモイド関数のどの部分を使っているかを見るために、隠れ層の入力値のヒストグラムを各NPMにトレーニングデータを33個予測させた際の2番目と3番目のニューラルネットの隠れ層への入力ヒストグラムを図16~図18に示す。図を見てわかるように、非線形領域が使われており、おそらくこれによって非線形予測を行っているものと思われる。

3.4.4 NPMの予測した特徴ベクトル

次に各NPMが予測した特徴ベクトルを観察する。シグモイド版が予測したものを図19~21に、また線形版が予測したものを図22~24に示す。これを見ると、シグモイド版ではD(図17)、線形版ではBとDがデータのカテゴリ以外の他のNPMで予測しても似たような特徴ベクトルが得られるのがわかる。そこでBA、DA、GAの時と同様、あるパターンを入力して出力を観察したところ(図25~27)、シグモイド版ではあまり意味のないパターンが出てきたが、線形版では各々のニューラルネットが予測を受け持っている部分の特徴ベクトルと似たパターンが出力されているのに気が付く。これをみると線形版のNPMでは予測というよりも、パターン想起を行っているように思える。したがって表面上、予測誤差やニューラルネットの予測分担は似ているが、予測の過程ではだいぶ異なる処理になっているものと思われる。

4. 考察

NPMによるBDG音韻認識はシグモイド関数版の認識率で92.46%と良好で、また学習データに対する認識率とくらべてテストデータの認識率があまり低下していないため、学習の一般化が行われていることがわかった。また、NPMの各ニューラルネットの予測分担が音韻の構造をうまく分担していることがわかった。線形版についても87.83%と予想したよりもよい値であった。それと問題点として学習に時間がかかることがわかった。

5. 結び

学習時間がたくさんかかる原因としては、DPを行う際に全てのDPのノードについてニューラルネットで予測を行っていることに原因がある。学習が進んでくると、最適パスがデータごとにだんだん安定してくるので、ある程度学習が進んで来たらDPパスを求める際、全てのノードについて学習を行うのではなく、前回の最適パスの近辺のノードについてのみ計算を行えば、計算量をかなり減らすことができる。また、BDGを認識するだけなら、後続母音の予測誤差はあまり重要ではないので、NPMの各ニューロンの予測誤差に異なる重みをつけて評価したらどうなるかを試してみたい。

謝辞

1カ月間ご助言、ご面倒をみていただいた沢井秀文さん、宮武正典さん、北岡みゆきさん、川端豪さん、その他音声情報処理研究室の皆さんおよび、京都工芸繊維大学の石島さん、に感謝致します。

参考文献

[1]鹿野、中村、田村、ワイベル.,ニューラルネットワークの音声情報処理への応用,日本音響学会誌44巻10号(1988)pp.798~804

[2]磯.ニューラルネットワークによる予測モデルを用いた音声認識.,電子情報通信学会技術研究報告,SP89-23,1989年6月22日

[3]中村雅己、鹿野清宏.,英文テキストデータからのニューラルネットによる単語列予測モデルの検討,信学技報,SP88-26(June,1988)

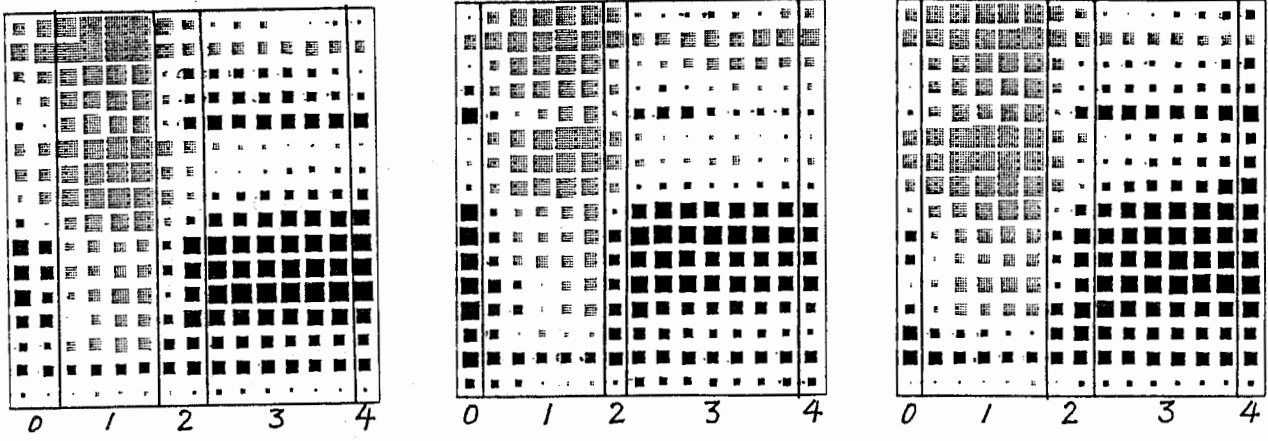


図1 BAのNPMのニューラルネットの予測分担




図2 DAのNPMのニューラルネットの予測分担







図3 GAのNPMのニューラルネットの予測分担




BAのNPMによる予測



入力データBA




DAのNPMによる予測




GAのNPMによる予測


図4 入力データBAに対する各NPMの予測




BAのNPMによる予測



入力データDA




DAのNPMによる予測




GAのNPMによる予測


図5 入力データDAに対する各NPMの予測




BAのNPMによる予測



入力データGA



DAのNPMによる予測



GAのNPMによる予測

図6 入力データGAに対する各NPMの予測

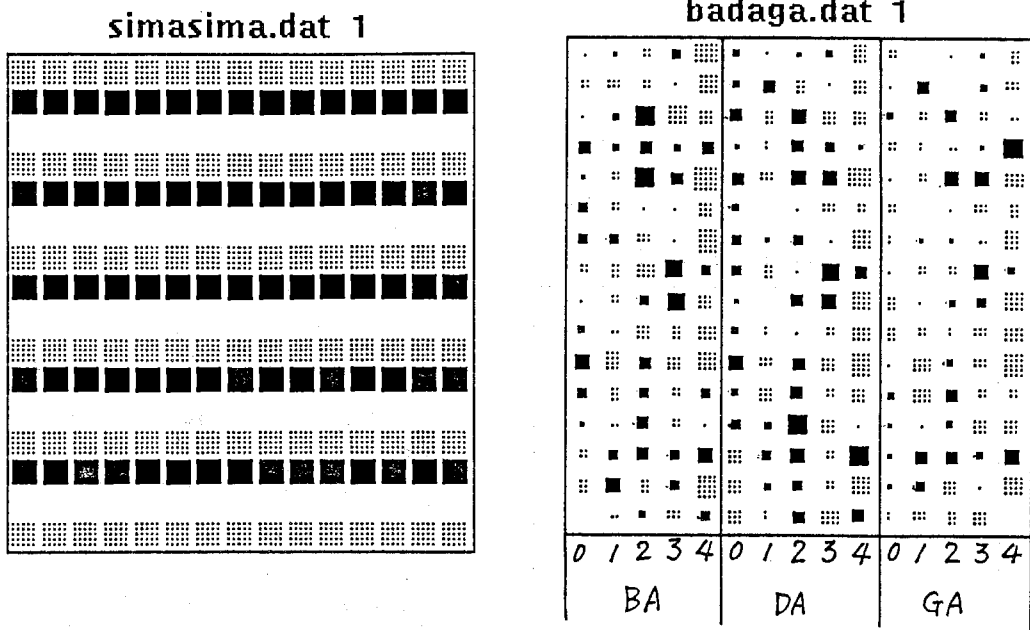


図 7 入力パターン 各ニューラルネットの予測出力

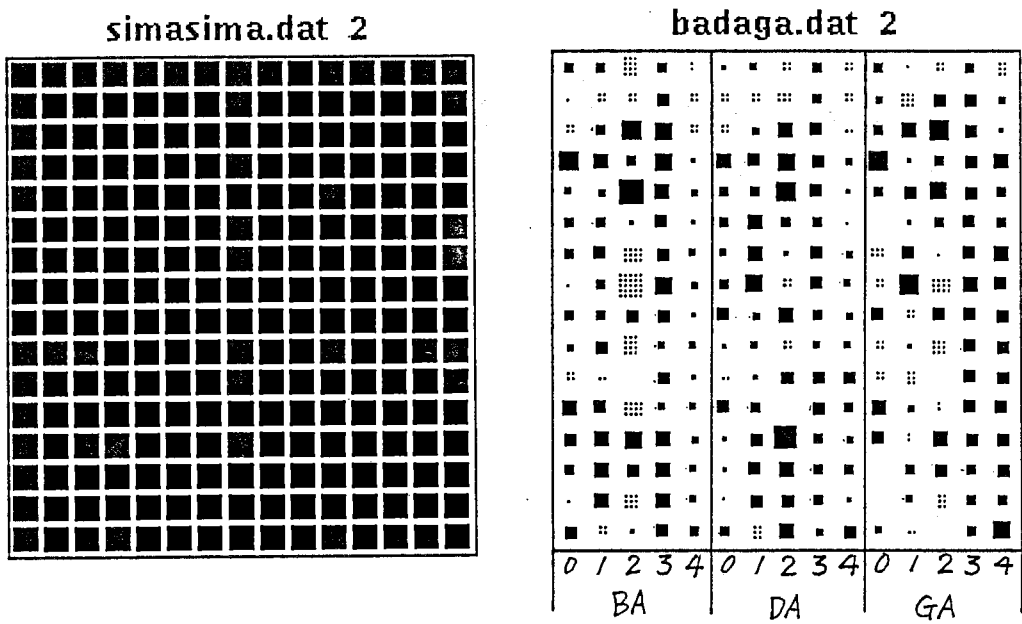



図 8 入力パターン 各ニューラルネットの予測出力

simasima.dat 3



badaga.dat 3

| | | |
|-----------------|-----------------|-----------------|
| · ■ ■ ■ . ■ ■ ■ | · ■ ■ . : ■ ■ ■ | ■ ■ : ■ ■ ■ |
| ■ ■ ■ ■ : ■ ■ ■ | ■ ■ ■ ■ . ■ ■ ■ | : ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ | ■ ■ ■ ■ ■ ■ ■ ■ |
| 0 1 2 3 4 | 0 1 2 3 4 | 0 1 2 3 4 |
| BA | DA | GA |

図 9 入力パターン 各ニューラルネットの予測出力




図 1 0 B (シグモイド版) のNPMのニューラルネットの予測分担

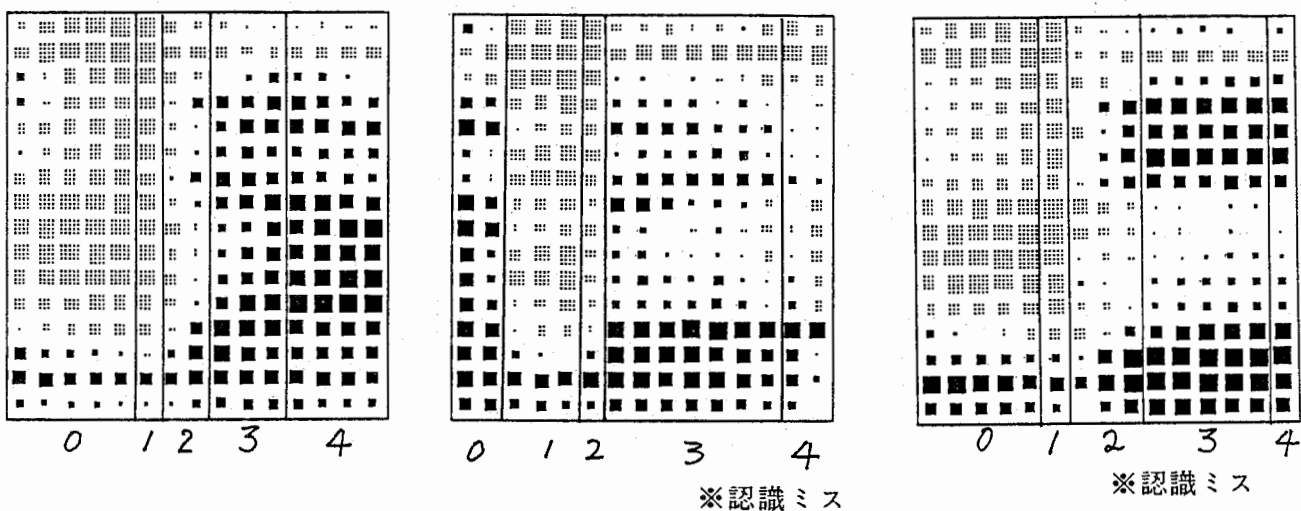


図 1 1 D (シグモイド版) のNPMのニューラルネットの予測分担

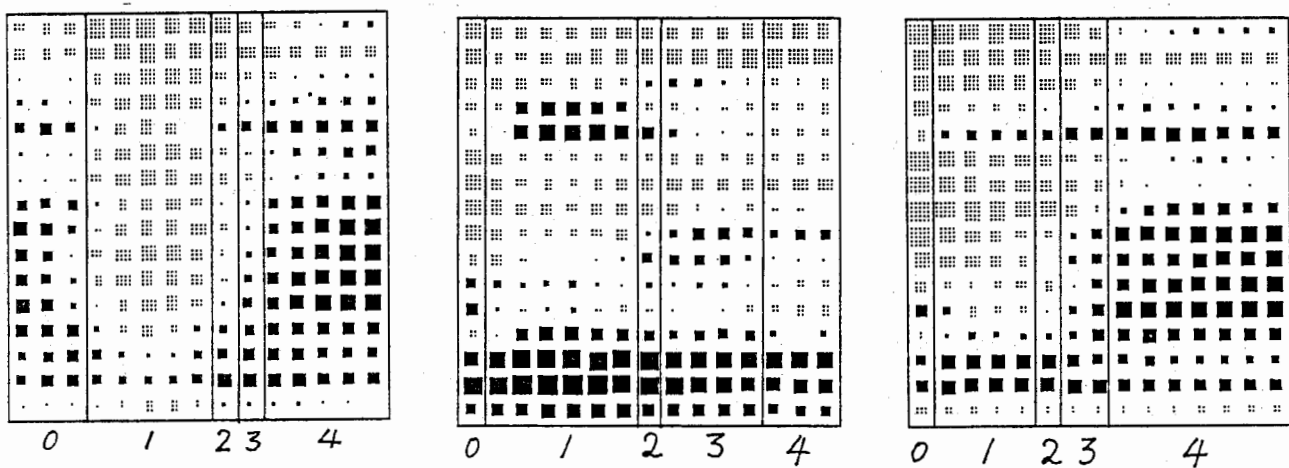


図 1 2 G (シグモイド版) のNPMのニューラルネットの予測分担




図13 B (線形版) のNPMのニューラルネットの予測分担




図14 D (線形版) のNPMのニューラルネットの予測分担






図15 G (線形版) のNPMのニューラルネットの予測分担




2 番ニューラルネット




3 番ニューラルネット

図16 BのNPMのネットワーク




2 番ニューラルネット




3 番ニューラルネット

図17 DのNPMのネットワーク




2 番ニューラルネット

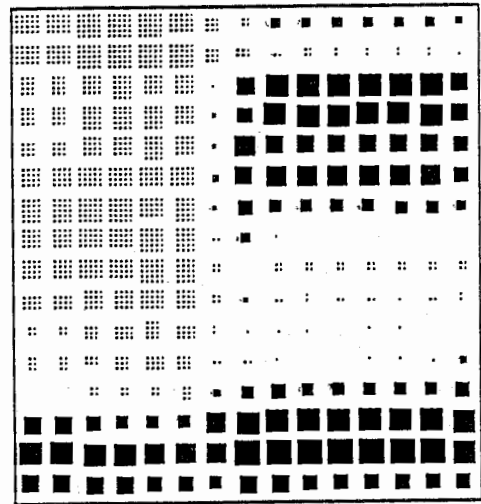


3 番ニューラルネット


図18 GのNPMのネットワーク




入力データ B



BのNPMによる予測




DのNPMによる予測




GのNPMによる予測

図19 入力データ Bに対する各NPMの予測


(シグモイド)



BのNPMによる予測




入力データ D




DのNPMによる予測

図20 入力データ Dに対する各NPMの予測


(シグモイド)




GのNPMによる予測




BのNPMによる予測



入力データ G




DのNPMによる予測




GのNPMによる予測

図21 入力データ Gに対する各NPMの予測


(シグモイド)



BのNPMによる予測




入力データ B




DのNPMによる予測


図22 入力データ B に対する各NPMの予測 (線形)




GのNPMによる予測




BのNPMによる予測



入力データD




DのNPMによる予測




GのNPMによる予測


図23 入力データDに対する各NPMの予測（線形）




BのNPMによる予測



入力データ G




DのNPMによる予測

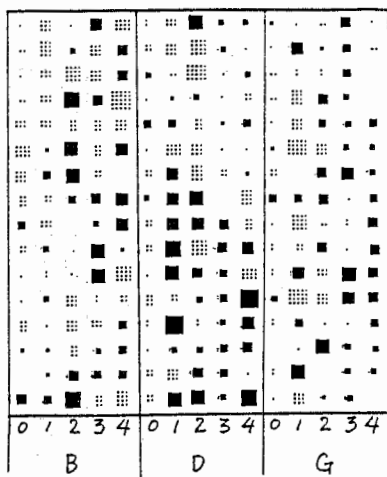


GのNPMによる予測


図24 入力データ G に対する各NPMの予測（線形）



入力




シグモイド版

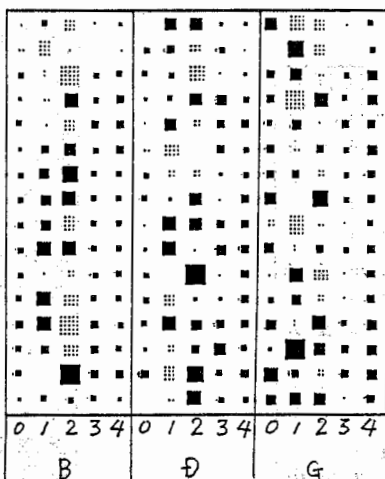


線形版


図25 各ニューラルネットの予測出力



入力




シグモイド版




線形版


図26 各ニューラルネットの予測出力



入力



シグモイド版



線形版

図27 各ニューラルネットの予測出力

表1 整合窓幅

| 学習回数 | 窓幅 |
|---------|-----|
| 1 ~ 10 | 0.5 |
| 11 ~ 20 | 1.0 |
| 21 ~ 30 | 3.0 |

表2 トレーニングデータに対する認識率
 (予測誤差を下げられるだけ下げたNPMの場合)

| | | 認識結果 | | |
|-----|----|---------|---------|---------|
| | | BA | DA | GA |
| データ | BA | 100.00% | 0.00% | 0.00% |
| | DA | 0.00% | 100.00% | 0.00% |
| | GA | 0.00% | 0.00% | 100.00% |

トータル認識率 100.00%

表3 テストデータに対する認識率
 (予測誤差を下げられるだけ下げたNPMの場合)

| | | 認識結果 | | |
|-----|----|--------|--------|---------|
| | | BA | DA | GA |
| データ | BA | 89.39% | 10.61% | 0.00% |
| | DA | 0.00% | 98.77% | 1.23% |
| | GA | 0.00% | 0.00% | 100.00% |

トータル認識率 96.71%

表4 トレーニングデータに対するNPMの平均予測誤差
(予測誤差を下げられるだけ下げたNPMの場合)

| | | NPM | | |
|-----|----|----------|----------|----------|
| | | BA | DA | GA |
| データ | BA | 0.011780 | 0.018979 | 0.025562 |
| | DA | 0.026626 | 0.013359 | 0.025894 |
| | GA | 0.056045 | 0.039386 | 0.013866 |

表5 テストデータに対するNPMの平均予測誤差
(予測誤差を下げられるだけ下げたNPMの場合)

| | | NPM | | |
|-----|----|----------|----------|----------|
| | | BA | DA | GA |
| データ | BA | 0.015012 | 0.019972 | 0.027526 |
| | DA | 0.028463 | 0.015445 | 0.024973 |
| | GA | 0.053043 | 0.036993 | 0.015409 |

表6 トレーニングデータに対する認識率
(予測誤差を揃えたNPMの場合)

| | | 認識結果 | | |
|-----|----|--------|---------|---------|
| | | BA | DA | GA |
| データ | BA | 96.23% | 3.77% | 0.00% |
| | DA | 0.00% | 100.00% | 0.00% |
| | GA | 0.00% | 0.00% | 100.00% |

トータル認識率 99.16%

表7 テストデータに対する認識率
(予測誤差を揃えたNPMの場合)

| | | 認識結果 | | |
|-----|----|--------|--------|---------|
| | | BA | DA | GA |
| データ | BA | 80.30% | 19.70% | 0.00% |
| | DA | 0.00% | 97.53% | 2.47% |
| | GA | 0.00% | 0.00% | 100.00% |

トータル認識率 93.83%

表8 トレーニングデータに対するNPMの平均予測誤差
(予測誤差を揃えたNPMの場合)

| | | NPM | | |
|-----|----|----------|----------|----------|
| | | BA | DA | GA |
| データ | BA | 0.013824 | 0.019307 | 0.025562 |
| | DA | 0.030592 | 0.013868 | 0.025894 |
| | GA | 0.062478 | 0.040491 | 0.013866 |

表9 テストデータに対するNPMの平均予測誤差
(予測誤差を揃えたNPMの場合)

| | | NPM | | |
|-----|----|----------|----------|----------|
| | | BA | DA | GA |
| データ | BA | 0.016992 | 0.020291 | 0.027526 |
| | DA | 0.032478 | 0.015914 | 0.024973 |
| | GA | 0.059139 | 0.038071 | 0.015409 |

表10 トレーニングデータに対する認識率
(学習データ数を53個に揃えたNPMの場合)

| | | 認識結果 | | |
|-----|----|--------|---------|---------|
| | | BA | DA | GA |
| データ | BA | 98.11% | 1.89% | 0.00% |
| | DA | 0.00% | 100.00% | 0.00% |
| | GA | 0.00% | 0.00% | 100.00% |

トータル認識率 99.58%

表11 テストデータに対する認識率
(学習データ数を53個に揃えたNPMの場合)

| | | 認識結果 | | |
|-----|----|--------|--------|--------|
| | | BA | DA | GA |
| データ | BA | 90.91% | 7.58% | 1.52% |
| | DA | 0.00% | 92.59% | 7.14% |
| | GA | 1.04% | 0.00% | 98.96% |

トータル認識率 94.65%

表 1 2 トレーニングデータに対する N P M の平均予測誤差
 (学習データ数を 5 3 個に揃えた N P M の場合)

| | | N P M | | |
|-----|-----|----------|----------|----------|
| | | B A | D A | G A |
| データ | B A | 0.009690 | 0.017395 | 0.025330 |
| | D A | 0.020231 | 0.011351 | 0.020459 |
| | G A | 0.036700 | 0.029732 | 0.010286 |

表 1 3 テストデータに対する平均予測誤差
 (学習データ数を 5 3 個に揃えた N P M の場合)

| | | N P M | | |
|-----|-----|----------|----------|----------|
| | | B A | D A | G A |
| データ | B A | 0.011678 | 0.018420 | 0.026147 |
| | D A | 0.021120 | 0.013105 | 0.018490 |
| | G A | 0.036911 | 0.031395 | 0.013991 |

表 1 4 トレーニングデータに対する認識率
 (NPMを構成するニューラルネットを4つに減らした場合)

| | | 認識結果 | | |
|-----|----|---------|---------|---------|
| | | BA | DA | GA |
| データ | BA | 100.00% | 0.00% | 0.00% |
| | DA | 0.00% | 100.00% | 0.00% |
| | GA | 0.00% | 0.00% | 100.00% |

トータル認識率 100.00%

表 1 5 テストデータに対する認識率
 (NPMを構成するニューラルネットを4つに減らした場合)

| | | 認識結果 | | |
|-----|----|--------|--------|---------|
| | | BA | DA | GA |
| データ | BA | 89.39% | 9.09% | 1.52% |
| | DA | 0.00% | 98.77% | 1.23% |
| | GA | 0.00% | 0.00% | 100.00% |

トータル認識率 96.71%

表 1 6 トレーニングデータに対する N P M の平均予測誤差
 (N P M を構成するニューラルネットを 4 つに減らした場合)

| | | N P M | | |
|-----|-----|----------|----------|----------|
| | | B A | D A | G A |
| データ | B A | 0.008644 | 0.016309 | 0.021600 |
| | D A | 0.022046 | 0.009487 | 0.020932 |
| | G A | 0.048158 | 0.032108 | 0.009020 |

表 1 7 テストデータに対する N P M の平均予測誤差
 (N P M を構成するニューラルネットを 4 つに減らした場合)

| | | N P M | | |
|-----|-----|----------|----------|----------|
| | | B A | D A | G A |
| データ | B A | 0.011718 | 0.017072 | 0.023479 |
| | D A | 0.023526 | 0.010991 | 0.019930 |
| | G A | 0.045961 | 0.030320 | 0.010752 |

表18 トレーニングデータに対する認識率
(シグモイド版NPM)

| | | 認識結果 | | |
|-----|---|--------|--------|--------|
| | | B | D | G |
| データ | B | 96.55% | 2.68% | 0.77% |
| | D | 8.05% | 90.42% | 1.53% |
| | G | 5.36% | 2.30% | 92.34% |

トータル認識率 93.10%

表19 テストデータに対する認識率
(シグモイド版NPM)

| | | 認識結果 | | |
|-----|---|--------|--------|--------|
| | | B | D | G |
| データ | B | 95.24% | 3.97% | 0.79% |
| | D | 7.54% | 88.10% | 4.37% |
| | G | 4.76% | 0.79% | 94.05% |

トータル認識率 92.46%

表 2 0 トレーニングデータに対する平均認識誤差
(シグモイド版NPM)

| | | N P M | | |
|-----|---|----------|----------|----------|
| | | B | D | G |
| データ | B | 0.015969 | 0.039493 | 0.032244 |
| | D | 0.020517 | 0.015333 | 0.032322 |
| | G | 0.036684 | 0.057710 | 0.020445 |

表 2 1 テストデータに対する平均認識誤差
(シグモイド版NPM)

| | | N P M | | |
|-----|---|----------|----------|----------|
| | | B | D | G |
| データ | B | 0.016333 | 0.035594 | 0.032297 |
| | D | 0.019059 | 0.014651 | 0.030156 |
| | G | 0.035066 | 0.056846 | 0.020948 |

表 2 2 トレーニングデータに対する認識率
(線形版 N P M)

| | | 認識結果 | | |
|-----|---|--------|--------|--------|
| | | B | D | G |
| データ | B | 83.52% | 11.11% | 5.36% |
| | D | 1.15% | 98.47% | 0.38% |
| | G | 3.45% | 6.13% | 90.42% |

トータル認識率 90.80%

表 2 3 テストデータに対する認識率
(線形版 N P M)

| | | 認識結果 | | |
|-----|---|--------|--------|--------|
| | | B | D | G |
| データ | B | 78.57% | 18.25% | 3.17% |
| | D | 1.59% | 96.43% | 1.98% |
| | G | 5.16% | 6.35% | 88.49% |

トータル認識率 87.83%

表 2 4 トレーニングデータに対する平均認識誤差
(線形版 N P M)

| | | N P M | | |
|-----|---|----------|----------|----------|
| | | B | D | G |
| データ | B | 0.019251 | 0.030336 | 0.031348 |
| | D | 0.024245 | 0.015955 | 0.032037 |
| | G | 0.038715 | 0.046450 | 0.021871 |

表 2 5 トレーニングデータに対する平均認識誤差
(線形版 N P M)

| | | N P M | | |
|-----|---|----------|----------|----------|
| | | B | D | G |
| データ | B | 0.019170 | 0.028443 | 0.030924 |
| | D | 0.022803 | 0.015196 | 0.029048 |
| | G | 0.037920 | 0.044741 | 0.022184 |