

階層形神経回路網と線形信号処理法の信号分類能力の比較

原 一 之†† 中 山 謙 二††

本論文では、階層形神経回路網（階層形 NN）の信号分類能力について理論的検討とシミュレーションによる検証、およびフーリエ変換やフィルタ等を用いる線形な信号処理による信号分類と比較する。観測区間が短く、すなわち、サンプル数が少なく、雑音が混入している離散時間信号を周波数成分により分類する問題を対象とする。このような信号の周波数解析は困難であり、従来方法ではその分解能力には限界がある。一方、近年、階層形 NN が信号解析の方面に応用されその有効性が示されている。しかし、そのメカニズムについての検討は十分ではない。本論文では、サンプル数が限られている信号の分類問題を周波数分析ではなく、パターン分類としてとらえる。 N サンプルから成る信号を N 次元ベクトルとし、 N 次元空間に分布する信号ベクトルの分類を N 次元空間における領域形成に帰着し、その自由度という観点から分類能力を評価した。この点から、階層形 NN は基本的に領域形成の自由度が高く、また、既知データによる学習により、その領域形成を最適化できることを明らかにした。一方、線形信号処理法は周波数成分の抽出等のモデルを想定しているため、領域形成という観点からは制約が大きいことを示した。以上の解析結果を検証するために、多周波信号の分類問題のシミュレーションを行った。信号は 2 つのクラスに分かれ、同じクラスの信号は同一の周波数成分を有し、振幅と位相は乱数で決められる。信号のサンプル数 = 10 の場合、雑音混入あり/なしにかかわらず階層形 NN の分類能力が高く、20 サンプルでは、雑音混入の場合に階層形 NN の優位性が確認された。また、実際の多周波信号であるダイヤルトーン検出についても同様の結果が得られ、本論文における解析結果の妥当性が立証された。

Comparison of Signal Classification Performance between Multilayer Neural Networks and Linear Signal Processing Methods

KAZUYUKI HARAT†† and KENJI NAKAYAMA††

In this paper, signal classification performance of multilayer neural networks (MLNNs) is investigated theoretically and experimentally. Furthermore, it is compared to linear signal processing (SP) methods, including Fourier transform, filters, pattern matching, and so on. The signal of interest is observed and sampled in a very short interval, thus, it has a small number of samples. The signals with and without noise are used. The very short length signals have distorted frequency components, and are difficult to be detected. Recently, the MLNNs have been applied to signal processing and detection. The MLNNs have good performance in some cases. However, theoretical analysis for their signal detection performance have not been well investigated. The signal detection with a limited number of samples is reduced to a pattern classification problem. The signal with N samples is considered as an N -dimensional vector. The pattern classification problem in an N -dimensional space is considered as subspace formulation, or space division by hyperplanes. Classification performance is evaluated based on a degree of freedom for subspace formulation. It is analyzed that the MLNNs have a high degree of freedom for dividing the N -dimensional space, and each subspaces can be optimize through a supervised learning. On the other hand, the linear SP methods are based on some models which extract frequency components, so, they do not have a degree of freedom of formulating the subspace in the N -dimensional space. The above analytical results are verified through computer simulation of multi-frequency signal classification, and its real application, dial-tone signal detection. When 10~20 sample signals are employed and computational load is limited to the same amount, the MLNNs have higher probabilities of signal classification than those of the conventional methods. When the number of samples and computational load are not limited, their performance are almost the same.

† 金沢大学大学院自然科学研究科

Graduate School of Natural Science and Technology,
Kanazawa University

†† 富山職業能力開発短期大学校

Toyama Polytechnic College

††† 金沢大学 工学部電気・情報工学科

Faculty of Engineering, Kanazawa University

1. はじめに

近年、階層形神経回路網（階層形 NN と略す）¹⁾は、信号検出^{2)~6)}、ディジタル復調^{7)~10)}、および帯域制限された信号の分類^{11),12)}等の信号処理にも応用され、パターン分類や非線形な処理が必要な場合には、従来の線形な信号処理法に比べて処理能力が高いことも報告されている。さらに、統計的手法やクラスタリング法との比較も多く行われている。たとえば、特定の問題に対して分類能力^{13),14)}、ネットワーク構造の複雑さ¹⁵⁾、計算量¹⁶⁾についての比較が行われ、構造のコンパクトさ、分類能力の高さなどにおいて、階層形 NN の優位性が示されている。しかし、これらは、主にシミュレーション実験に基づく検証であり、階層形 NN の信号分類能力のメカニズムに対する理論的検討は十分ではない。

本論文では、階層形 NN の信号分類能力について理論的検討とシミュレーションによる検証、およびフーリエ変換やフィルタ等を用いる線形な信号処理法による信号分類との比較を行う。特に、観測区間が短く、したがって、信号のサンプル数が少なく、雑音が混入している離散時間信号を周波数成分により分類する問題を対象とする。一般に、このような信号の周波数解析は困難であり、従来方法ではその分解能力には限界がある。また、このような問題は実用的にも意味があり、各種計測、信号処理、ディジタル通信、および画像の実時間処理等において必要とされる。

本論文では、サンプル数が限られ、雑音が混入している信号の分類問題を周波数解析という立場ではなく、パターン分類の問題としてとらえる。観測された信号のサンプル数を N 個とするとき、この信号を N 次元ベクトルと見なす。信号分類は、同じクラスに属する信号ベクトルが同じ領域に属するように N 次元空間を分割すること、すなわち、領域形成することに相当する。したがって、信号分類能力は N 次元空間における領域形成の自由度に帰着できる。このような観点から階層形 NN の信号分類能力を理論的に評価し、また、線形信号処理法との比較を行う。

シミュレーション実験では、複数のクラスの多周波信号を用いて階層形 NN と線形信号処理法の信号分類能力を評価する。各クラスの多周波信号の周波数は固定であるが、各周波数成分の振幅と位相はランダムに設定して多くの信号を生成する。これらの信号は学習用とテスト用に分けられる。階層形 NN は学習データを用いて誤差逆伝播法により学習され、その後テストデータを用いて信号分類能力を評価する。また、信

号に含まれる周波数に関する情報はサンプル数に依存しているため、信号のサンプル数と分類能力の関係に基づいて階層形 NN と線形信号処理法の比較を行う。さらに、処理に必要な計算量と分類能力の観点からも比較を行う。実際の多周波信号として、ブッシュ式電話のキーに対応するダイヤルトーンを用いて評価を行う。以上のシミュレーション実験を通して、本論文の理論検討の結果を検証する。

2. 階層形神経回路網によるパターン分類

本章では、階層形神経回路網（NN）によるパターン分類のメカニズムについて解析し、さらに、4 章では N 次元空間における領域形成の自由度について検討し、線形信号処理法との比較も行う。

2.1 階層形神経回路網の構成

本論文で対象とする階層形 NN は入力層、隠れ層（1 層）、出力層からなるネットワークである。本論文における議論は、より多層の NN に対しても同様に展開できるので、一般性を失わない。

入力層は N 個、隠れ層は J 個、出力層は K 個のユニットから構成され、 N および K は各々入力信号のサンプル数および分類するクラス数と同じに設定する。したがって、1 個の信号は N 次元ベクトルで表され、教師信号は 1 つのクラスに対して 1 個の出力ユニットのみが活性、他のすべてのユニットは不活性となる。すべての信号は $p = 1 \sim P$ 個のクラスから成り、各クラスには $m = 1 \sim M$ 個の N 次元信号があるとする。第 p グループの m 番目の入力信号を $x_{pm} = \{x_{pm}(n), n = n_0 \sim n_0 + N - 1\}$ と表す。ここで、 n_0 は観測の始点である。 N サンプルの信号は並列に入力層に入力され、 n 番目のユニットには $x_{pm}(n_0 + N - 1 - n)$ が入力される。隠れ層の第 j 番目のユニットの入力ポテンシャルを net_j とする。これは、次式のように入力信号と入力層・隠れ層間の結合荷重 w_{nj} の積和で計算される。

$$net_j = \sum_{n=0}^{N-1} w_{nj} x_{pm}(n_0 + N - 1 - n) + \theta_j \quad (1)$$

ここで、 θ_j は第 j 番目の隠れユニットのバイアスである。このユニットの出力は隠れ層の活性化関数 $f_H(\cdot)$ を用いて次式で計算される。

$$y_j = f_H(net_j) \quad (2)$$

出力層に関しても同様に計算される。出力層の第 k 番目のユニットの入力ポテンシャルを net_k 、出力を y_k 、第 j 番目の隠れユニットから第 k 番目の出力ユニットまでの結合荷重を w_{jk} 、出力ユニットの活性化

関数を $f_O(\cdot)$ とすると、

$$net_k = \sum_{j=0}^{J-1} w_{jk} y_j + \theta_k \quad (3)$$

$$y_k = f_O(net_k) \quad (4)$$

となる。

結合荷重の学習は教師あり学習を前提とする。具体的には、誤差逆伝播法を用いる。そのため、活性化関数 $f_H(\cdot)$, $f_O(\cdot)$ は微分可能な関数とする。

2.2 階層形神経回路網によるパターン分類

階層形 NN では、入力層に提示した信号を隠れ層で中間的な分類を行い、さらにその出力を出力層で所望のクラスに分類する。ここでは、このような過程でどのような分類が行われているかを解析する。さらに、パターン分類の自由度については、4 章で詳しく検討する。

階層形 NN は、式(1), (3) による線形結合と、式(2), (4) による非線形変換の組合せで構成される。そこで、まず、1 個のユニットによるパターンの線形分類について述べる¹⁷⁾。入力パターンを $x_{pm} = \{x_{pm}(n), n = 0 \sim N-1\}$, 結合荷重を $w = \{w_n, n = 0 \sim N-1\}$, ユニットのバイアスを θ とする。2 つのクラス X_1 , X_2 に属するパターンを分類するためには次の式(5)を満たす w と θ が存在する必要がある。

$$\left. \begin{array}{l} x_{pm} \in X_1, \sum_{n=0}^{N-1} w_n x_{pm}(n) + \theta > 0 \\ x_{pm} \in X_2, \sum_{n=0}^{N-1} w_n x_{pm}(n) + \theta < 0 \end{array} \right\} \quad (5)$$

ここで、式(2), (4) に対応する非線形関数は、不連続関数を含む単調増加関数を前提にしている。たとえば、式(6) に示す、しきい値 0 の線形しきい値関数がこれに相当する。 y はユニット出力である。

$$y = \left\{ \begin{array}{ll} 1, & \sum_{n=0}^{N-1} w_n x_{pm}(n) + \theta > 0 \\ 0, & \sum_{n=0}^{N-1} w_n x_{pm}(n) + \theta < 0 \end{array} \right. \quad (6)$$

式(5)の右側の不等式は、 N 次元空間を 1 つの超平面 $\sum_{n=0}^{N-1} w_n x_{pm}(n) + \theta = 0$ によって 2 つの領域に分割することを表している。同時に、式(5) に示すように、クラス X_1 , X_2 に属するパターンに対して、これらの不等式を満たす w と θ が存在すれば、2 つのクラス X_1 , X_2 に属するパターンの分布する領域が 1 つの超平面で分離されることを表している。このようなパターン集合は線形分離可能であるといわれる。

2.1 節で述べた階層形 NN では、活性化関数として微分可能な関数を用いる。たとえば、式(7) で表されるシグモイド関数等が用いられる。

$$f(net) = \frac{1}{1 + e^{-net}} \quad (7)$$

$f(net)$ は $[0, 1]$ のアナログ値を出力するが、単調増加関数であり、式(8) のように、出力のしきい値を 0.5 とすれば、式(5) を分離条件として用いることができる。

$$y \left\{ \begin{array}{ll} > 0.5, & \sum_{n=0}^{N-1} w_n x_{pm}(n) + \theta > 0 \\ < 0.5, & \sum_{n=0}^{N-1} w_n x_{pm}(n) + \theta < 0 \end{array} \right. \quad (8)$$

1 個の隠れユニットの出力におけるパターン分類は式(5) の議論とまったく同じである。すなわち、隠れユニット 1 個によりすべてのパターンが 2 分類される。一般のパターン分類は線形分離可能であるとは限らないから、この層における分類では正確なパターン分類は保証されない。 J 個の隠れユニットがある場合、パターンは最大 2^J 個のサブクラスに分類される。このサブクラスの領域は、入力層・隠れ層間の結合荷重によって構成される超平面の組合せによって形成される。

一方、式(5) の入力を階層形 NN の隠れ層出力に、出力を出力層の 1 ユニットの出力に対応させることにより、出力ユニット 1 個により、隠れ層の出力パターンが 2 分類されることが分かる。つまり、隠れ層の出力でいくつかのサブクラスに分割された領域は出力ユニット 1 個で 2 つの領域に統合される。隠れ層の出力で線形分離可能なサブクラスに分離されていれば、出力層で正確なパターン分類が可能となる。階層形 NN 全体の領域形成に対する自由度については 4 章で論じる。

3. 線形信号処理法による信号分類

線形信号処理法による信号分類を、パターン分類という観点から概観し、その信号分類能力および分類方法を示す。線形信号処理法は、パターン分類法ではないが、これらはパターン分類と見なせる信号処理に使われている。

3.1 パターンマッチング法

パターンマッチング法を用いたパターン分類法は、テンプレートパターンと入力パターンとの距離を測定し、入力パターンに最も近いテンプレートパターンの属するクラスに入力パターンを分類する。この方法は最近傍法¹⁹⁾と呼ばれる。テンプレートと入力パターンとの距離尺度として、ユークリッド距離、マハラノビスの一般化距離²⁰⁾などが用いられる。

ユークリッド距離は、テンプレートの分布に偏りがある場合などには分類能力が低下する。一方、マハラノビスの一般化距離では式(9) に示すように、階層形 NN の学習データに相当するパターンの共分散行列 C で

距離を正規化しているため、ユークリッド距離よりパターンの分布の影響が少なく、分類能力が優れている。

$$\tilde{d}_p^2 = (\mathbf{x} - \boldsymbol{\mu}_p)^t \mathbf{C}_p^{-1} (\mathbf{x} - \boldsymbol{\mu}_p) \quad (9)$$

ここで、 \mathbf{C}_p は第 p クラスの階層形 NN の学習データに相当するパターンの共分散行列、 $\boldsymbol{\mu}_p$ が第 p クラスのテンプレートで、階層形 NN における学習データに相当するパターンの平均パターンとなっている。 \mathbf{x} は入力パターンである。

有名なパターンマッチング法として、 k 平均法^{21),22)} や Gaussian Classifier¹⁹⁾があるが、 k 平均法は、テンプレートの数が十分多いときの最近傍法と同等、Gaussian Classifier は、最近傍法においてマハラノビスの一般化距離を距離尺度とした場合と同等の能力と考えられる。したがって、本論文ではパターンマッチング法のうち、ユークリッド距離、マハラノビスの一般化距離を用いた方法について議論する。

3.2 周波数解析法

周波数解析法として、フーリエ変換、またはフィルタ²³⁾を用いたパターン分類が可能である。フーリエ変換では、第 p クラスに含まれる周波数での振幅が他のクラスに含まれる周波数での振幅より大きければその信号を第 p クラスに、フィルタでは各クラスに含まれる周波数を抽出するフィルタバンクを作り、最も出力の大きいクラスに信号を分類する。このとき入力信号の周波数成分は、フーリエ変換ではフーリエ核、フィルタ法では、抽出したい周波数にピークを持つよう設計したフィルタ係数との内積により抽出する。これらの方法は周波数情報を用いるため、信号の周波数が既知でない分類では、あらかじめ信号について、周波数成分を推定する前処理が必要である。

周波数成分の抽出時の内積計算で用いられるフーリエ核、またはフィルタ係数は、パターン分類におけるテンプレートパターンに対応する。ただし、これらがパターン分類法と異なる点は、テンプレートの選び方の自由度が低い点である。これについては、4.2 節で説明する。

3.3 スペクトル推定法

最大エントロピー法 (Maximum Entropy Method: MEM)²³⁾ はスペクトル推定法の 1 つで、観測区間の短い信号からでも高い周波数分解能を実現できる方法である。本方法は基本的にはフィルタと同様であるが、AR (auto-regressive) モデルを導入し、未知のラグを持つ自己相関系列を予測することにより、フィルタより高い分解能を実現している。分類法はフィルタを用いたパターン分類と同様である。

スペクトル推定精度の高い方法として、MUSIC (Multiple Signal Classification)²⁴⁾ があるが、30 dB 程度の SNR (Signal Noise Ratio) しか許容できないため、本論文で扱う雑音加算信号の SNR を許容できない。したがって、本論文では最大エントロピー法について議論する。

以上より、本論文では、パターンマッチング法のうち、ユークリッド距離およびマハラノビスの一般化距離を用いた方法、周波数解析法のうち、フーリエ変換による方法とフィルタによる方法、スペクトル推定法として最大エントロピー法を比較対象とする。

4. パターン分類の自由度の比較

階層形 NN のパターン分類の自由度の解析を、出力層での領域形成の自由度に基づいて解析する。また、線形信号処理法のパターン分類の自由度についても同様の解析を行い、比較を行う。

4.1 階層形神経回路網の領域形成の自由度の解析

本節では、階層形 NN によるパターン分類の自由度を解析するため、隠れ層出力で線形分離可能なサブクラスの組合せの数を求める。隠れ層出力で線形分離可能であれば、サブクラスは隠れ層・出力層間の結合荷重によって形成される超平面により正確にパターン分類される。したがって、隠れ層出力で線形分離可能なサブクラスの組合せの数を求ることは、パターン分類のための N 次元空間の分割、すなわち、領域形成の自由度を求ることと等価である。

Cover らは、單一ユニット¹⁷⁾や階層形 NN の隠れ層初段²⁵⁾に対し、確率的な意味において 2 分類可能なランダムパターン数を求めており、本論文では決定論的な解析を行う。

解析にあたって、階層形 NN の活性化関数は線形しきい値関数であると想定する。これは、2.2 節での解析における議論と同様である。活性化関数として、線形しきい値関数の代わりに微分可能なシグモイド関数等を用いることにより、形成されるクラス領域はいずれも、領域形成のための超平面の数は同じである。詳しくは、4.1 節の最後に議論する。領域そのものは教師あり学習により調整可能であり、超平面の数が同じであれば、領域形成の自由度も同じになる。ここでの議論を容易にするために線形しきい値関数を用いることにする。

以下、入力ユニットが 2 個、隠れユニットが 2 個、出力ユニットが 1 個の階層形 NN を用いた 2 次元入力信号の集合 \mathbf{X} の 2 分類問題を対象とし、領域形成の自由度を解析する。

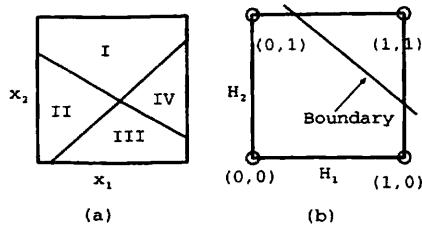


図 1 隠れユニット 2 個の場合の領域形成. (a) 入力空間でのサブクラス領域, (b) 隠れ層空間でのクラス境界

Fig. 1 Signal detection region of MLNN with two hidden units. (a) Sub-class regions in input space. (b) Class boundary in hidden unit output space.

式(5)より、隠れユニット 1 個により、全信号 X は 2 個の領域に分割される。したがって、隠れユニットが 2 個の場合、入力空間は、入力層・隠れ層間の結合荷重で形成される超平面により、図 1(a)のような 4 領域に分割される。この図で、2 本の実線は入力層・隠れ層間の結合荷重により形成される超平面である。

4 個の領域は、1 個の出力ユニットで 2 個の領域に統合されるため、4 個の領域の組合せによってできる 2 個の領域が、線形分離可能でなければならない。一般に隠れユニットの数を J 個とすると、階層形 NN は 2^J 個のパターンの組合せから線形分離可能な組合せを用いて領域を形成する自由度を持つ。図 1(a)において、線形分離可能な組合せは、領域 (I, III) を 1 つのクラス、領域 (II, IV) を他のクラスとするような組合せである²⁶⁾。これ以外の組合せであれば、超平面 1 つで 2 つの領域に統合することができる。なお、以下では、解析を容易にするため、入力空間ではなく、隠れ層の出力空間で解析を行う。

隠れ層の各ユニットの活性化関数をしきい値関数としたため、隠れユニットの出力は 1 または 0 となる。したがって、隠れユニットの出力は、 H_1, H_2 を 1 番目、2 番目の隠れユニット出力とすると、 $(H_1, H_2) = \{(0,0), (0,1), (1,0), (1,1)\}$ の 4 パターンとなる。これら 4 パターンは、結合荷重が実数なので、隠れユニット空間を実数空間として扱えば、図 1(b)のように、 R^2 の隠れ層出力空間内の、1 辺の長さが 1 の四辺形の頂点となる。また、クラスの境界は、たとえば図 1(b) 中の直線である。出力ユニットで線形分離可能な領域の組合せの数を求める問題は、四辺形の頂点を線形分離する超平面の数を求める問題に帰着できる。

超平面が四辺形の中心を通らない場合は、出力ユニットにバイアスを用いた場合に相当する。そこでまず、出力ユニットにバイアスを用いた場合について解析する。分離する頂点 (パターン) の総数が 2, 3, および 4 個の場合について数える。これは分類するパターン

数がつねに 4 個とは限らないからである。頂点の総数が 2 個である場合、4 頂点から 2 個を選ぶ組合せと、そのうち 2 個の中から 1 個を 1 つのクラスとして選ぶ方法があるので、 ${}_4C_2 \times {}_2C_1 = 12$ 通りの組合せが可能である。ここで、 ${}_mC_n$ は m 個の中から n 個を選ぶ組合せの数で、 ${}_mC_n = m!/(n!(m-n)!)$ である。頂点の総数が 3 個の場合、 ${}_4C_3 \times \{{}_3C_1 + {}_3C_2\} = 24$ 通りが可能な組合せの数である。頂点の総数が 4 個の場合、 ${}_4C_4 \times \{{}_4C_1 + ({}_4C_2 - 2) + {}_4C_3\} = 12$ 通りである。ここで、頂点を 2 個ずつに分離する場合、図 1(a)でも説明したように、頂点が排他的 OR の関係の場合は線形分離できないため、2 を引いている。

以上で数えた総計 $12 + 24 + 12 = 48$ が分離可能な組合せの数である。これらすべての組合せ 50 通り ($48 + 2$ (線形分離不可能な組合せ)) に対する線形分離可能な組合せの割合は、 $48/50 = 0.96$ となり、領域形成の自由度が高いことが分かる。

一方、出力ユニットにバイアスを使用しない場合、上記と同様にその組合せの数を求めることができる。この場合、超平面は四辺形の中心を通らなければならぬため、対角の 2 つの頂点を同じクラスに分類することはできない。したがって、バイアスを使用した場合に比べ、組合せの数が減少する。2 頂点の分離では ${}_4C_2 \times {}_2C_1 = 12$ 通り、3 頂点では ${}_4C_3 \times \{({}_3C_1 - 1) + ({}_3C_2 - 1)\} = 16$ 通り、すべての頂点の場合で、 ${}_4C_4 \times {}_4C_2 - 2 = 4$ 通りとなり、総計 32 通りとなる。全組合せに対する線形分離可能な組合せの数は、 $32/50 = 0.64$ となり、領域形成の自由度は低下する。一般的な階層形 NN では、バイアスを前提としているため、前者の $48/50 = 0.96$ を仮定することができ、高い自由度を確保できる。

次に、シグモイド関数を活性化関数として用いた場合について考える。隠れ層出力は、図 2 の灰色で表されるように、各頂点付近に分布するようになる。このとき、各頂点からの分布範囲が直線で分離でき、したがって線形しきい値関数の議論を適用できる分布の限界 r は、各頂点からの出力の分布が同じであると仮定すると、1 つの頂点を中心とする半径 r の円と、これに接する直線より求まり、 $r = 0.42$ である。この値は、各頂点の分布の限界 0.5 に近い値である。さらに、学習後の隠れユニット出力は、1 または 0 付近に収束する傾向があり¹⁸⁾、出力の分散は小さいと仮定できる。あるいは、出力の分散が小さいという仮定を設けても階層形 NN のパターン分類能力は劣化しない。これら 2 つの特性により、シグモイド関数を用いたときの領域形成の自由度は、線形しきい値関数を用いた

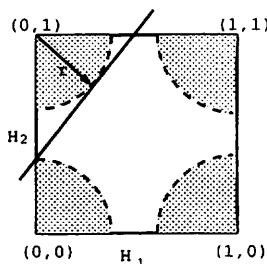


図2 シグモイド関数の場合の隠れユニット出力の分散
Fig. 2 Distribution of hidden unit outputs with Sigmoid function.

場合と同程度であると考えられる。

以上の解析より、階層形NNは領域形成の自由度、すなわち超平面の数（結合荷重の種類）は、隠れユニット2個に対して $48/50 = 0.96$ と多いため、入力パターンが広くかつ複雑に分布している場合にも、柔軟にクラスの領域を形成できる。このような領域の形成が可能となるのは、活性化関数の非線形性と隠れ層を用いる階層構造に起因している。

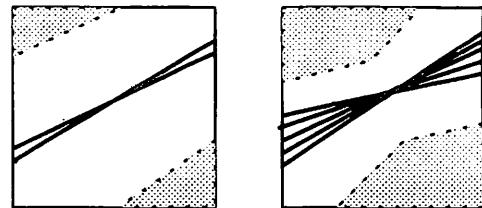
一方、階層形NNによる分類はノンパラメトリックな手法であり、かつ、教師あり学習を用いて入力パターンとクラスの関係を学習するため¹⁾、学習の収束性は必ずしも保証されない。また、クラスの領域は、主に学習パターンより決定されるため、学習データの分布が全データの分布に比べて偏っている場合、分類能力は劣化する。すなわち、階層形NNの能力は学習データの選択と学習法にも依存している。

4.2 線形信号処理法の領域形成の自由度の解析

周波数解析の方法として代表的なフーリエ変換とフィルタ法、また、パターン分類の観点からパターンマッチング法について考える。周波数成分の抽出という観点からフーリエ変換もフィルタの一種であるため、ここでは、フィルタ法を対象とする。また、フィルタ法は狭帯域フィルタを用いることにより、高い分解能が得られる方法である。

観測区間が長く、サンプル数が多い時系列信号の周波数特性は原信号の特性に近いため、正確な周波数解析が可能である。信号に含まれる周波数成分を狭帯域の帯域通過フィルタ（BPF）を用いて解析する場合、信号に含まれる周波数成分と含まれない成分ではフィルタ出力においてレベル差がある。さらに、狭帯域BPFの出力は定常応答としては近似的に正弦波形と見なせるため、信号に含まれる成分とそうでない成分は狭帯域BPFの出力を数サンプル用いて識別することができる。

いま、入力信号が第 p クラスに属する場合、このケ



(a) FIR filter with two output samples (b) FIR filter with five output samples
Fig. 3 Conceptual figure of signal detection regions of FIR filter.

ラスと、それ以外のクラス（第 p' クラスと表す）のフィルタ出力 $y_p(n)$, $y_{p'}(n)$ は次の不等式を満足する。

$$\sum_{n=0}^{K_l-1} |y_p(n)| \gg \max_{p \neq p'} \sum_{n=0}^{K_l-1} |y_{p'}(n)| \quad (10)$$

ここで、 K_l はフィルタ出力のサンプル数である。さらに、適当なしきい値 α を決めると、この条件は次のように表せる。

$$\sum_{n=0}^{K_l-1} |y_p(n)| = \sum_{n=0}^{K_l-1} \left| \sum_{k=0}^{N-1} x(k) h_p(n-k) \right| > \alpha. \quad (11)$$

$h_p(n)$ は第 p クラスの信号を抽出する狭帯域BPFのインパルス応答である。この式の右辺の不等式は N 次元空間のある領域を形成し、第 p クラスの信号がその領域に含まれていることを示している。 $N = 2$ 次元の場合の概念図を図3(a)に示す。図中の2本の直線（実線）が式(11)における線形結合部分 = 0とした次の式で表される直線である。一般の N 次元空間では、この直線は超平面となる。

$$\sum_{k=0}^{N-1} x(k) h_p(n-k) = 0, n_0 \leq n \leq n_0 + K_l - 1 \quad (12)$$

式(12)で表される直線の式は、連続する N 個のフィルタ係数（インパルス応答） $h_p(n-k)$, $k = 0 \sim N-1$ から構成される。 K_l 本の直線はフィルタ係数を時間軸方向に1サンプルずつシフトして得られるが、狭帯域フィルタでは、フィルタ次数を N_f としたとき、 $N_f \gg K_l$ ならば、 N サンプルから成るフィルタ係数の相関性が高くなる（付録A.3 参照）。図3(a)は概念的に2本の直線の相関性が高いことを表している。

フィルタの振幅特性のピークを与える周波数と信号に含まれる1つの周波数が一致する場合、フィルタ係数（インパルス応答）と信号の対応する周波数成分の

相関性が高くそれらの内積が大きくなる。式(11)の絶対値の内部は信号 $x(k)$ とフィルタ係数 $h_p(n - k)$ の内積であり、信号が BPF の通過域の周波数成分を含む場合は、この内積が大きくなる。そのような信号は、図 3(a) の 2 次元空間では、直線から離れた領域に分布することになる。灰色の部分がその領域である。

信号の周波数が BPF の通過域にはない場合は、信号とフィルタ係数との相関性は小さく、フィルタ出力も小さい。したがって、図 3(a)においては、直線に近い領域に分布する。白い部分がその領域である。言い換えれば、サンプル数が多い信号は図 3(a)のように分布し、この領域は少ない直線で形成されるため、フィルタ出力の少ないサンプルを用いて識別が可能であることになる。

次に、観測区間が狭く、サンプル数が少ない信号について考える。この場合は、有限区間の信号が有する周波数特性が原信号から歪む。時間領域と周波数領域における不確定性原理より、一般に急峻な周波数特性が緩やかな特性に変化する。たとえば、信号に含まれる周波数成分と含まれない成分の差が小さくなる。このため、これらの周波数成分を識別するためには、フィルタ出力の多くのサンプルを用いて各周波数成分の大きさ(レベル)をより正確に評価する必要がある。出力のサンプル数を K_h として式で表現すると次のようになる。

$$\sum_{n=0}^{K_h-1} |y_p(n)| > \alpha. \quad (13)$$

ここで、 $K_h > K_l$ である。式(13)を満たす信号ベクトルは 2 次元空間では図 3(b) の灰色の領域のように分布する。 K_h 本の直線は K_l 本に比べれば、直線間の類似性が低くなり、幅広く分布する。図 3(b) も図 3(a) 同様に直線の相関性が低いことを概念的に表すものである。

上記のことは、次のようにも説明できる。サンプル数の少ない信号は同じクラス内でも波形の相関性が低くなり、サンプル数が多い信号に比べて、N 次元空間内に広く、かつ不規則に分布するようになる。これらを識別するために、出力レベル評価に使用するフィルタ出力のサンプル数を増やすことにより、フィルタで形成される領域も広くする必要がある。

ここで問題となるのが、フィルタ出力のサンプル数を増やすことにより、フィルタで形成される N 次元空間内の領域の自由度がどの程度高くなるかという点である。これは、フィルタ係数(インパルス応答)から連続する N サンプルを抽出し、これを

$\mathbf{h}_p(n_0) = [h_p(n_0), \dots, h_p(n_0 + N - 1)]$ としたとき、 K_h 個のパターン $\mathbf{h}_p(n_0) \sim \mathbf{h}_p(n_0 + K_h - 1)$ 間の相関性によって決まる。明らかに、これらは独立ではなく、従属性がある。特に、FIR フィルタで狭帯域フィルタを構成する場合はフィルタ次数が非常に高くなる。フィルタ次数を N_f としたとき、 N_f/N , N_f/K_h が大きいほど $\mathbf{h}_p(n_0) \sim \mathbf{h}_p(n_0 + K_h - 1)$ 間の相関性も高くなる(付録 A.3 参照)。これらの相関性が高いということは、信号検出のための領域形成の自由度が低くなることを意味している。

このように、フィルタ法の場合、N 次元空間で信号を検出する領域を形成する超平面はフィルタ係数(インパルス応答)で決まり、複数の超平面はフィルタの特性に基づく相関性を有する。これは、周波数成分を狭帯域フィルタで抽出するというモデル化による制約である。したがって、この方法は信号のサンプル数が多く、相関性を有する信号(パターン)の識別には有效であるが、サンプル数が少なく、相関性の低い、不規則な信号(パターン)の識別に対しては、N 次元空間における領域形成の自由度が制約されることから有效ではないといえる。

パターンマッチング法の場合は、テンプレートがフィルタ係数に相当する。テンプレートの選択は自由であるから、領域形成の自由度は高い。しかし、ユークリッド距離、またはマハラノビスの一般化距離で評価するため、信号が分布する領域が凸領域であれば少ないテンプレートで領域形成が可能であるが、複雑に入り組んだ領域を形成する場合は多くのテンプレートを必要とするという問題がある。

以上の議論について、次の第 5 章で多くの例を用いたシミュレーションにより検証する。

5. コンピュータシミュレーション

5.1 多周波信号

本節では、多周波信号の分類を対象としてシミュレーションを行う。特に、異なるクラスで周波数が相互に配置され、正弦波形の振幅や位相がランダムに決められている波形を用いる。これは、波形として見た場合、クラス内の類似性が低く、クラス間の相違も小さくなり、パターン分類としては難しい問題となる。

ここで使用される多周波信号 $x_{pm}(n)$ はクラス数 $P = 2$ 、各クラスが $R = 3$ の周波数成分を持つ正弦波の和で構成される。

$$x_{pm}(n) = \sum_{r=1}^R A_{mr} \sin(\omega_{pr} n T + \phi_{mr}) \quad (14)$$

ここで $p = 1 \sim P$, $\omega_{pr} = 2\pi f_{pr}$, f_{pr} は第 p クラスの r 番目の周波数成分である。振幅 A_{mr} は $(0, 1]$ の乱数、位相 ϕ_{mr} は $[0, 2\pi)$ の乱数である。添え字の m はクラス内の m 番目の信号を、 T はサンプリング間隔を表す。クラス 1 の信号の周波数成分は 1, 2, 3 Hz, クラス 2 の周波数成分は 1.5, 2.5, 3.5 Hz である。サンプリング周波数は 10 Hz とした。クラスに含まれる周波数とサンプリング周波数の比が一定であれば、他の周波数でも同様に扱うことができる。

階層形 NN では 200 個/クラスの信号を学習用に、1800 個/クラスの信号をテストデータ、つまり分類能力評価用データとして使用する。線形信号処理法のパラメータは上記の信号を用いないであらかじめ設計されるため、すべての信号 ($200 + 1800 = 2000$ 個/クラス) をテストデータとして使用する。

耐雑音特性を評価するために、雑音加算信号を用いる。雑音は $[-0.5, 0.5]$ の一様乱数とする。この場合の信号対雑音比は 6.5 dB である。

5.2 階層形神経回路網の構成

前節における解析の場合と同様に隠れ層が 1 層の階層形 NN を用いる。隠れユニット数の決定に関しては文献 27), 28) 等にあるような最適化が多く研究されているが、本論文は階層形 NN の構造の最適化を目的としないため、テストデータに対して分類能力が高く、かつ隠れユニットが少なくなるように経験的に決定した。その結果、隠れユニットは 3 個とした。出力ユニットは信号のクラス数と同数とした。これは、1 つのクラスに 1 つの出力ユニットを割り当てるもので、教師信号は 1 つの出力ユニットのみ 1 で他は 0 とする。

5.3 階層形神経回路網の学習および分類

学習には誤差逆伝搬法¹⁾を用いる。学習率 η と慣性項係数 α は、それぞれ経験的に 0.1, 0.8 とした。学習は出力層での 2 乗平均誤差が 0.01 以下になった時点で終了する。学習時のデータはランダムに提示した。

階層形 NN を用いた分類率は、学習で用いた信号に対してほぼ 100% の分類が可能であるため、テスト信号に対して求めた。ここで分類率はテスト信号の総数に対して正しく分類された信号の数の比である。信号の分類は最大値検出で行った。すなわち、出力が最大である出力ユニットに対応するクラスに分類する。

5.4 線形信号処理法の設計および分類

線形信号処理法の設計については付録 A.1 に示す。線形信号処理法による分類法は 3 章で述べた方法を用いる。しかし、フーリエ変換、最大エントロピー法では、次の判定基準を用いて分類を行う。

判定基準 周波数 f_{pr} , $p = 1 \sim P$, $r = 1 \sim R$ にお

ける入力信号の振幅を $A(f_{pr})$ と表すとき、振幅がクラス間で最大となる周波数 f_{pr} , $r = 1 \sim R$ が最も多いクラスにその信号を分類する。

5.5 規格化された計算量の導入

計算量を表す量として、規格化された計算量 (Normalized Computational Complexity: NCC) を用いる。NCC は、計算量の異なる分類法の分類能力を、同一計算量において比較するために用いる。

各手法の NCC の計算方法を付録 A.2 に、NCC の具体的な値を表 8, 表 9 に示す。ここで、フィルタ法で特定の周波数を抑圧するもの (FIR2 と表記) の NCC は、分類数であり、マハラノビスの一般化距離を用いたパターンマッチング法では、分類数とパターンの次元の積で与えられる。したがって、これらが決定されると、NCC は不变となる。付録 A.2 表 8, 表 9 より、信号のサンプル数が 10 で 2 分類の場合、FIR2 では $NCC = 2$ 、マハラノビスの一般化距離を用いたパターンマッチング法では $NCC = 20$ である。同条件下における階層形 NN は $NCC = 3.6$ である。そこで、FIR2 については、計算量が制限された場合についてのみ、また、マハラノビスの一般化距離を用いたパターン分類法は、計算量が制限されない場合のみを比較対象とする。

5.6 多周波信号分類結果

計算機シミュレーションは、線形信号処理法の計算量が階層形 NN と同等に制限された場合と、制限されない場合について行った。

表 1 に、計算量が制限された場合の分類率を示す。単位はパーセントである。計算量が制限された場合は、線形信号処理法の計算量を階層形 NN に合わせる。しかし、まったく同じにはできないため、できるだけ近い値を用いる (付録 A.2 の表 8 を参照)。

また、フーリエ変換、最大エントロピー法 (MEM) は付録 A.2 より、観測周波数が 1 クラスあたり 1 個に制限される。そこで、2 クラスの観測周波数の組合せ $3C_1 \times 3C_1 = 9$ 個それぞれに対して分類率を算出し、その平均を表に示した。表中、階層形 NN は MLNN, FIR フィルタで特定の周波数の振幅を抽出するものを FIR1, 抑圧するものを FIR2, フーリエ変換法を Fourier, パターン分類法のうち、ユークリッド距離を用いた方法を Euclid, マハラノビスの一般化距離を用いた方法を MGD, 最大エントロピー法を MEM と略記している。

表 1 より、階層形 NN は信号のサンプル数や雑音を加算する、しないにかかわらず、分類率が高い。一方、線形信号処理法では 20 サンプルの方が高い分類

表 1 計算量が制限された場合の分類率 [%]

Table 1 Probability of exact signal classification in percentage when computation is limited.

Methods	<i>N</i> = 10		<i>N</i> = 20	
	NFS	NS	NFS	NS
MLNN	97.6	85.4	97.4	90.6
FIR1	4.7	3.7	100	87.5
FIR2	100	50.3	100	51.3
Fourier	56.1	53.6	77.9	76.7
Euclid	49.6	52.1	59.4	62.0
MGD	-	-	-	-
MEM	60.8	56.8	87.7	87.3

N: Number of samples

NFS: Noise Free Signal, NS: Noisy Signal

表 2 計算量が制限されない場合の分類率 [%]

Table 2 Probability of exact signal classification in percentage when computation is not limited.

Methods	<i>N</i> = 10		<i>N</i> = 20	
	NFS	NS	NFS	NS
MLNN	100	90.6	100	99.3
FIR1	100	90.5	100	99.8
FIR2	-	-	-	-
Fourier	70.6	65.7	100	94.8
Euclid	86.0	79.5	100	99.5
MGD	100	90.2	100	99.7
MEM	62.9	63.7	97.3	95.4

N: Number of samples

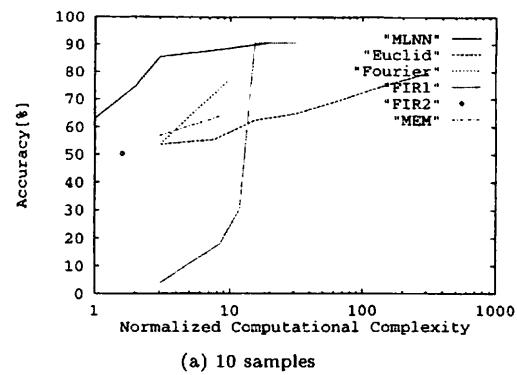
NFS: Noise Free Signal, NS: Noisy Signal

率を得ている。これは、先の解析から予測できるように、10サンプルの場合、信号の非線形性が高いからである。また、信号に雑音を加算しない場合、FIR2がMLNNより高い分類率を得ているが、雑音を加算した場合、分類率は大きく低下している。これは、FIR2は特定の周波数を除去するように設計するが、加算される雑音が一様乱数であるため除去できない、という本質的問題に起因する。

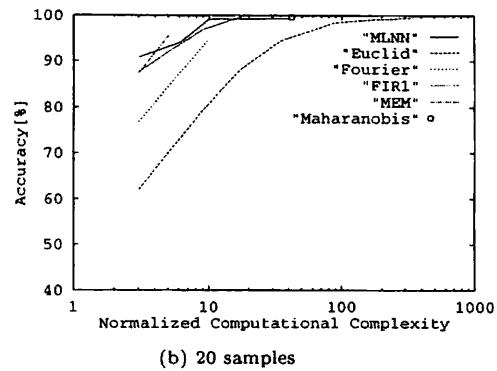
計算量を制限されない場合の結果を表2に示す。この場合、各手法の分類率を高めるように各手法の計算量を増やしている(付録A.2の表9を参照)。ここでは、階層形NNでは隠れユニット数、フィルタ法(FIR1)では出力のサンプル数、フーリエ変換、最大エンタロピー法では観測周波数、およびユークリッド距離を用いたパターン分類法では、テンプレート数を各自増やしている。

表2によれば、いずれの手法においても分類率が改善されており、特にFIR1とMGDが信号のサンプル数=10, 20において階層形NNと同等の高い分類率を示している。

また、階層形NNの隠れ層の活性化関数として、谷形関数⁸⁾を用いた。谷形関数は整流作用があり、信号



(a) 10 samples



(b) 20 samples

図4 階層形NNと線形信号処理法の信号分類率。(a) 10サンプル, (b) 20サンプル

Fig. 4 Classification rates of signal classification by the MLNN method and the linear signal processing methods for (a) 10 samples and (b) 20 samples noisy signal.

レベルの検出に有効である。谷形関数は原理的には、2個のシグモイド関数を用いて実現できる。しかし、学習の収束性の点から谷形関数を直接用いた方が有効である。ここでは、各手法の計算量を制限しないで比較しているため、階層形NNでもシグモイド関数よりも複雑な谷形関数を用いた。

5.7 計算量と分類率

計算量と分類率の関係をさらに詳細に解析する。図4は、各手法の分類率と計算量の関係を示している。横軸がNCC、縦軸が分類率である。分類する信号は雑音を加算したものを用いた。NCCが大きくなるに従って、各手法の分類率が向上するのが分かる。大きなNCCに対して、階層形NNと各線形信号処理法の分類率は同等である。また、NCCが小さくなるに従って、すべての手法の分類率は低下するが、階層形NNの分類率の低下は最も緩やかである。

以上のことから、ここで取りあげた多周波信号は10～20サンプルでも分類のために十分な処理を行なうことを前提とすれば線形な信号処理法にとって十分な周

表3 隠れ層出力層間の結合荷重

Table 3 Connection weights of hidden layer and output layer.

Hidden	Output	
	1st	2nd
1st	-18.95	18.95
2nd	18.27	-18.27
3rd	11.63	-11.63
Bias	-2.0	2.0

波数情報を有しているといえる。しかし、その情報は希薄であり、処理量が制限されると分類率は大幅に低下する。これに対し階層形NNは回路規模が小さい場合でもN次元空間における領域形成の自由度が高いため、分類率は大きく劣化しない。

5.8 階層形神経回路網の信号検出領域

信号のサンプル数が10の場合の階層形NNによって形成された領域を、結合荷重および隠れユニット出力から解析する。シミュレーション結果より、10サンプルの場合に線形信号処理法と分類能力の違いが顕著であるので本解析に用いる学習には雑音を加算した学習信号を200個×2クラス=400個を用いた。

隠れユニットから出力ユニットへの結合荷重を表3に示す。表中で、Outputの1st, 2ndは各々クラス1, 2の信号に対応する出力ユニットである。隠れ層から第1出力ユニット(1st)への結合は-18.95, 18.27, 11.63, -2.0である。隠れ層から第2出力ユニット(2nd)への結合は第1出力ユニット(1st)への結合と極性だけ異なる値になっている。この対称性は、クラス1, 2に対する教師信号(1, 0), (0, 1)の対称性による。

この結合荷重の符号と大きさから、第1出力ユニット(1st)を活性化する隠れユニットの出力パターンは(隠れユニット: 1st, 2nd, 3rd) = (L, H, H), (L, H, L), (L, L, H), (H, H, H)である。ここで、Hは高い出力レベル、Lは低い出力レベルを表す。また、第2出力ユニット(2nd)を活性化する隠れユニットの出力パターンは(隠れユニット: 1st, 2nd, 3rd) = (H, L, L), (H, H, L), (H, L, H)である。この解析と、実際の隠れユニット出力を比較する。表4に実際の隠れユニット出力の分布を示す。

表より、実際の隠れユニット出力パターンでは、第1出力ユニットへは解析の結果得た4パターンのうち2パターンを、第2出力ユニットへは3パターンすべてを使って分類していることが分かる。このように、階層形NNでは隠れ層・出力層間の結合荷重を使って信号検出領域を柔軟に形成していることが確認された。

表4 隠れユニット出力分布

Table 4 Hidden unit output distribution.

Class 1			Class 2			
Hidden unit			NS	Hidden unit		NS
1st	2nd	3rd		1st	2nd	
H	H	H	112	H	H	0
H	H	L	0	H	H	52
H	L	H	0	H	L	109
H	L	L	0	H	L	39
L	H	H	0	L	H	0
L	H	L	0	L	H	0
L	L	H	88	L	L	0
L	L	L	0	L	L	0

NS: number of signals

表5 周波数(Hz)とダイヤルトーンのクラス(1~16)の対応。
周波数は正規化されている。

Table 5 Relation between combinations of frequencies in Hz and dial tone classes #1 - #16. Frequencies are normalized.

	1.209	1.366	1.477	1.633
0.697	#1	#2	#3	#4
0.770	#5	#6	#7	#8
0.852	#9	#10	#11	#12
0.941	#13	#14	#15	#16

6. ダイヤルトーン認識

ダイヤルトーン認識²⁹⁾は、プッシュ式電話において、ボタンを押したときに発生する信号の周波数から押されたダイヤルを識別するものである。ここで使用される信号は多周波信号である。

ダイヤルトーン信号の周波数は、高い周波数と低い周波数から成る。低い周波数には0.697, 0.770, 0.852, 0.941Hzが、高い周波数には1.209, 1.366, 1.477, 1.633Hzが含まれる。これらの周波数はサンプリング周波数4Hzで正規化されている。

上記の2種類の周波数からそれぞれ1つの周波数を組み合わせ、 $4 \times 4 = 16$ 個の信号クラスを作る。1つの信号クラスが1つのダイヤルキーに対応する。表5にその対応関係を示す。前述の多周波信号との違いは、1つの周波数が複数の信号クラスに含まれていることである。1つの周波数では信号クラスが特定できないため、より難しい分類問題である。信号は式(14)により発生する。各周波数の振幅、位相、信号のサンプル数、各信号クラスの信号の数等は多周波信号の分類の場合と同じである。

6.1 階層形神経回路網による分類

表6にテスト信号に対する計算量が制限された場合の分類率を示す。隠れユニット数は50個である。信号のサンプル数が20サンプルの場合の方が10サンプ

表 6 階層形 NN を用いた場合のダイヤルトーン認識分類率 [%]

Table 6 Classification rates in percentage of dial tone recognition using MLNN method.

Signal Sample	Class. Rate
10	90.6
20	95.7

表 7 FIR1 フィルタを用いた場合のダイヤルトーン認識分類率 [%]

Table 7 Classification rates in percentage of dial tone recognition using FIR1 method.

Signal Samples	Output Samples	Class. Rate
10	LT	14
	NLT	200
20	LT	10
	NLT	200

LT: Computation is limited

NLT: Computation is not limited

ルの場合に比べて、分類率が高い。しかし、どちらの場合にも分類率は高い。結果から、複雑な分類問題も階層 NN を用いることで、少ない計算量で精度の高い分類が行えることが分かる。

6.2 フィルタによる分類

ダイヤルトーン認識に実際使用されている線形信号処理法として FIR1 フィルタを用いて分類率を検証した。ここでは 1 つの周波数を抽出するフィルタを周波数の数だけ用意したフィルタバンクを用いた。したがって、フィルタは 8 個用いる。ダイヤルトーン信号の分類は次のように行った。第 p クラスに含まれる周波数を抽出する 2 個のフィルタ出力が、他のフィルタの出力より大きいとき、第 p クラスに分類する。フィルタの次数は 1000 次とした。

計算量が制限された場合のフィルタ出力のサンプル数は、信号のサンプル数が 10 の場合は 14, 20 サンプルでは 10 とした。計算量が制限されない場合は、200 サンプル以上にサンプル数を増加しても分類率は変化しないことを確認し、200 サンプルとした。表 7 に結果を示す。

表中の Output samples は、フィルタの出力のレベル計算に使われる出力サンプル数である。表より、計算量の制限や、サンプル数にかかわらず、分類率は階層形 NN を用いた場合より低い。20 サンプルの場合でも分類率が低いが、これは、信号が 20 サンプルであっても、ダイヤルトーンの分類に必要な周波数特性に関する情報が十分でないことを意味している。しかし、この問題においても階層形 NN が高い分類率を得ているのは、周波数に関する情報のみでなく、波形としての特徴を抽出し、柔軟なパターン分類を行ってい

るためである。

7. まとめ

階層形 NN による信号分類について、特に、サンプル数が少なく、雑音が混入した信号の周波数成分に基づく分類を対象とし、その分類能力を理論的に評価し、シミュレーション実験により検証した。また、線形信号処理法との比較検討を分類精度、サンプル数、計算量の観点から多角的に行った。信号のサンプル数が非常に少い場合は、信号の有する周波数情報が希薄になるため、信号分類をパターン分類問題としてとらえ、さらに、 N 次元空間の領域形成問題に帰着した。階層形 NN では領域形成に対して高い自由度が保証され、また、既知データを用いた学習により領域形成の最適化が可能であるため、サンプル数が少ない信号に対しても高い分類能力を維持できる。これに対して、線形信号処理法は周波数成分を抽出するというモデルに基づいているため、領域形成を行う超平面が互いに従属関係にあり、パターン分類のための領域形成に制約がある。このため、サンプル数が少ない信号に対しては分類能力が急激に劣化する。また、処理に必要な計算量の点からも階層形 NN が有利であった。ダイヤルトーン等の多周波信号を用いたシミュレーション実験により、以上の検討結果を検証した。

参考文献

- 1) Rumelhart, D.E. and McClelland, J.L., et al.: *Parallel Distributed Processing*, MIT Press (1986).
- 2) Zhan, J. and Li, F.: A Self-organization Neural Network and Detecting Signals, *Proc. WCNN '93, Portland, OR*, Vol.IV, pp.748-751 (1993).
- 3) Vanderbeek, R. and Garper, A.: A Back-propagation Network for Analog Signal Separation in High Environments, *Proc. IJCNN '92, Baltimore, MD*, Vol.I, pp.664-669 (1992).
- 4) Al-Mashouq, K.A. and Reed, I.S.: The Use of Neural Nets to Combine Equalization with Decoding for Severe Intersymbol Interference Channels, *IEEE Trans. Neural Network*, Vol.5, No.6, pp.982-988 (1994).
- 5) Hummels, D.M., Ahmed, W. and Musavi, M.T.: Adaptive Detection of Small Sinusoidal Signals in Non-Gaussian Noise Using an RBF Neural Network, *IEEE Trans. Neural Network*, Vol.6, No.1, pp.214-219 (1995).
- 6) Michalopoulou, Z.H., Nolte, L.W. and Alexandrou, D.: Performance Evaluation of Multilayer

- Perceptrons in Signal Detection and Classification, *IEEE Trans. Neural Network*, Vol.6, No.2, pp.381–386 (1995).
- 7) Veciana, G. and Zakhor, A.: Neural Net-based Continuous Phase Modulation Receivers, *IEEE Trans. Communications*, Vol.40, No.8, pp.1396–1408 (1992).
 - 8) Nakayama, K. and Imai, K.: A Neural Demodulator for Amplitude Shift Keying Signal, *Proc. ICANN '94*, Sorrent, Vol.2, pp.1017–1020 (1994).
 - 9) Hush, D.R. and Horne, B.G.: Progress in Supervised Neural Network, *IEEE Signal Processing Magazine*, pp.8–39 (1993).
 - 10) Bouras, D.P. and Makrakis, D.: Neural-net based Receiver Structures for Single- and Multi-amplitude Signals in Interference Channels, *Proc. IEEE Workshop on Neural Networks for Signal Processing IV*, pp.535–544 (1994).
 - 11) Hara, K. and Nakayama, K.: High Resolution of Multi-frequencies Using Multilayer Networks Trained by Back-propagation Algorithm, *Proc. WCNN '93, Portland, OR*, Vol.IV, pp.675–678 (1993).
 - 12) Hara, K. and Nakayama, K.: Comparison of Activation Functions in Multilayer Neural Network for Pattern Classification, *Proc. ICNN '94, Orlando, FL*, Vol.V, pp.2997–3002 (1994).
 - 13) Tsoi, A.C. and Pearson, R.A.: Comparison of Three Classification Techniques, CART, C4.5 and Multi-layer Perceptrons, *Neural Information Processing System 3*, pp.963–969 (1991).
 - 14) Atlas, L., Cole, R., et al.: Performance Comparison Between Back-propagation Networks and Classification Trees on Three Real-world Applications, *Neural Information Processing System 2*, pp.622–629 (1990).
 - 15) Gish, S.L. and Blanz, W.E.: Comparing the Performance of Connectionist and Statistical Classifiers on a Image Segmentation Problem, *Neural Information Processing System 2*, pp.614–621 (1990).
 - 16) Ng, K. and Lippmann, R.P.: A Comparative Study of the Practical Characteristics of Neural Network and Conventional Pattern Classifiers, *Neural Information Processing Systems 3*, pp.970–976 (1990).
 - 17) Cover, T.M.: Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition, *IEEE Trans. Electric Computers*, Vol. EC-14, pp.326–334 (1965).
 - 18) 中山謙二, 猪股悟, 竹内吉和: 階層形神経回路網のデジタル構成におけるビット数低減方法, 電子情報通信学会論文誌, Vol.J73-D-II, No.8, pp.1336–1345 (1990).
 - 19) Duda, R.O. and Hart, P.E.: *Pattern Classification and Scene Analysis*, Wiley (1973).
 - 20) 奥野忠一, 久米均ほか: 多変量解析法, 日科技連, pp.259–272 (1981).
 - 21) MacQueen, J.B.: Methods for Classification and Analysis of Multivariate Observations, *Proc. Symp. Math. Statist. and Probability, 5th*, pp.281–297, Berkeley, 1 (1967).
 - 22) Anderson, M.R.: *Cluster Analysis for Applications*, pp.162–163, Academic Press (1973).
 - 23) Lim, J.S. and Oppenheim, A.V.: *Advance Topics in Signal Processing*, Prentice-Hall (1992).
 - 24) Schumit, R. and Franks, R.: Multiple DF Signal Processing: An Experimental System, *IEEE Trans. Antennas and Propagation*, Vol.AP-34, pp.281–290 (1986).
 - 25) Kowalczyk, A.: Counting Function Theorem for Multi-layer Networks, *Neural Information Processing System 6*, pp.375–382 (1995).
 - 26) Gibson, G.J. and Cowan, C.F.N.: On the Decision Regions of Multilayer Perceptrons, *Proc. IEEE*, Vol.78, pp.1590–1594 (1990).
 - 27) Sietsma, J. and Dow, R.J.F.: Creating Artificial Neural Networks that Generalize, *Neural Networks*, Vol.4, pp.67–79 (1991).
 - 28) 上田智之, 高橋潔, 森真作: ファジー推論を用いた階層型ニューラルネットワークの構造決定法—不要な結合重みと中間素子の削除, 電子情報通信学会論文誌, Vol.J78-D-II, 10, pp.1479–1490 (1995).
 - 29) 松本泰ほか: 押しボタンダイヤル用信号方式, 研究報, Vol.17, No.11, pp.2411–2445 (1968).
 - 30) Akaike, H.: Power Spectrum Estimation through Auto-regressive Model Fitting, *Ann. Inst. Statist. Math.*, Vol.21, pp.407–419 (1969).
 - 31) Rabiner, L.R. and Gold, B.: *Theory and Application of Digital Signal Processing*, Prentice-Hall (1975).

付録

A.1 線形信号処理法の設計

線形信号処理法は、計算量が制限されない場合に、その分類率が最も高くなるよう設計した。この節では、FIR1, FIR2, MGD, MEM の設計情報を示す。

(1) FIR フィルタ 1 (FIR1)

FIR1 は FIR (Finite Impulse Response) フィルタで、特定の周波数を抽出する。本論文では図 5 のような振幅特性の 1000 次のインパルス応答を用いた。

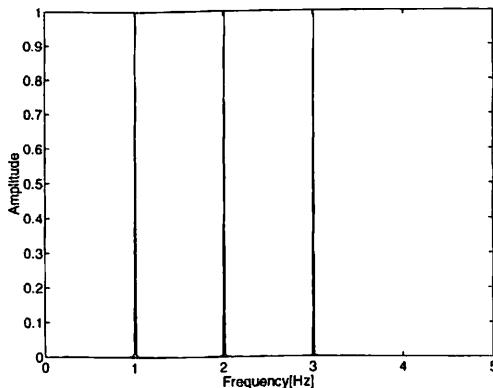


図 5 クラス 1 の周波数を抽出する FIR1 フィルタの振幅特性
Fig. 5 Amplitude response of FIR1 filter designed to extract class 1 signals.

図 5 は 5 章で使用した多周波信号のクラス 1 用フィルタである。このように長いインパルス応答を用いることで、周波数分解能を高めている。振幅のピークは 1, 2, 3 Hz で、帯域幅は 0.02 Hz である。

ある時間サンプル n におけるフィルタ出力 y_p は、次式で計算できる。

$$\begin{aligned} y_p(n) &= \sum_{k=0}^{K-1} x(n-k)h_p(k) \\ &= \sum_{k=0}^{K-1} x(k)h_p(n-k) \\ &= \sum_{k=0}^{N-1} x(k)h_p(n-k), h_p(n-k) = 0, \\ &\quad K \leq n \quad (15) \end{aligned}$$

ここで、 K はフィルタの次数、 N は信号のサンプル数である。式(15)より、 K 次のインパルス応答のうち、信号サンプル数と同数のフィルタ係数が使われる。このように、インパルス長は計算量に影響しない。また、クラス 2 の周波数を抽出するには、クラス 2 の周波数に振幅のピークを持つ振幅特性を用いる。

IIR (Infinite Impulse Response) フィルタも信号分類に用いることが可能であるが、IIR フィルタは帰還ループがあるため、 $n = n_0$ における出力 $y(n_0)$ を求めるために、 $n = 0 \sim n_0$ について計算する必要がある。すなわち、FIR フィルタのように独立に計算できない。したがって、IIR フィルタは FIR フィルタに比べて計算量が多くなるため、本論文では比較対象としない。

(2) FIR フィルタ 2 (FIR2)

FIR フィルタで、特定の周波数を抑圧するタイプで

ある。このタイプのフィルタは信号サンプル数と同数のフィルタ係数を用いるので、10 サンプルの信号では 10 次、20 サンプルの信号で 19 次とした。抑圧周波数は、クラス周波数およびその近傍に配置した。

(3) マハラノビスの一般化距離 (MGD)

分類に用いる信号は式(14)で与えられるため、信号間には相関がある。したがって、式(9)の距離計算で使用する共分散行列は特異行列となる。そこで、本論文では共分散行列を計算するためのパターンに ± 0.001 程度の乱数を加えることにより、共分散行列を正則化した。また、共分散行列は、階層形 NN における学習データに相当するパターンを用いて計算されるが、パターン数が多いほど共分散が正確に求まり、正規化の効果が上がる。そこで、各クラスとも 200 個以上のパターン数に対して分類率がほぼ飽和することを確認し、200 個のパターンを用いて各クラスの共分散行列を計算している。

(4) 最大エントロピー法 (MEM)

最大エントロピー法では、次式で表されるフィルタにより、スペクトルを推定する。

$$P(\omega) \approx \frac{a_0}{\left| 1 + \sum_{k=1}^M a_k e^{-j\omega k} \right|^2} \quad (16)$$

ここで M はフィルタの次数である。 a_0 と $\{a_k\}$ はテンプレートの自己相関系列から求めるフィルタの係数である。次数 M は、赤池の最終予測誤差³⁰⁾から、 $M < (2 \sim 3)\sqrt{N}$ で与えられるので、10 サンプルの信号分類には $M = 7$ 、20 サンプルには $M = 10$ と決定した。

A.2 規格化された計算量 (Normalized Computational Complexity: NCC) の計算方法

NCC は、計算量の異なる分類法の分類能力を、同一計算量において比較するため用いる。各手法の分類能力と計算量を決めるパラメータおよび NCC の計算方法を以下に示す。本文中と同様に信号のサンプル数を N 、クラス数は P とする。NCC では、 N 次元ベクトルの内積計算 1 回を 1 と規格化する。

(1) 階層形 NN を用いたパターン分類法 (MLNN)

階層形 NN の計算量を決めるパラメータは隠れユニット数である。学習が収束したとき、隠れユニットの出力が 0 または 1 に漸近する¹⁸⁾と仮定するとシグモイド関数はしきい値関数と考えられ、計算が不用となる。したがって、シグモイド関数の計算量は NCC から除く。このとき、 $NCC = N_H + (N_H P / N)$ であ

る。ここで、 N_H は隠れユニット数、 P は出力ユニット数である。

(2) FIR フィルタ 1 を用いた周波数解析法 (FIR1)

A.1 節より、FIR1 は信号のサンプル数と同数のフィルタ係数との内積計算で出力を求める。つまり、 $NCC = 1$ で出力が求められる。今、出力のサンプル数を N_O 、クラス数を P とすると、 $NCC = N_O P$ である。パラメータは出力のサンプル数 N_O である。

(3) FIR フィルタ 2 を用いた周波数解析法 (FIR2)

A.1 節より、FIR2 は信号サンプル数と同数のフィルタ係数との内積で出力を計算する。また、出力は、FIR2 の構造より 1 サンプルのみ用いられる。したがって、 $NCC = P$ であり、計算量を決める可変パラメータは存在しない。

(4) フーリエ変換を用いた周波数解析法 (Fourier)

信号 $\{x(n), n = 0 \sim N - 1\}$ のフーリエ変換は次式により与えられる。

$$X(\omega_{pr}) = \sum_{n=0}^{N-1} x(n)e^{-j\omega_{pr}nT} \quad (17)$$

ここで、 ω_{pr} は式(14)で用いたものと同じである。この式で、 $X(\omega_{pr})$ を求めるには、信号のサンプル数と同数のフーリエ核との内積計算が必要であるが、フーリエ核が複素数であるので、実数の内積計算の 2 倍の計算量とする。今、信号の含む周波数の数を R とすると $NCC = 2PR$ で与えられる。パラメータは観測周波数の数 R である。

(5) ユークリッド距離を用いたパターン分類 (Euclid)

テンプレートとパターンは N 次元ベクトルであり、それらのユークリッド距離の計算は内積計算とほぼ同じであるとすると、 $NCC = PN_T$ である。 N_T はテンプレートの数であり、同時にパラメータである。

(6) マハラノビスの一般化距離を用いたパターン分類法 (MDG)

階層形 NN における学習データに対応するパターンの共分散行列を求めるには、パターン数を M とすると、 M 回の内積計算が必要である。しかし、共分散行列の計算はあらかじめ行っておけば、距離計算のときには必要ないため、NCC の計算から除く。したがって、式(9)における計算は、パターンが N 次元であるとすると、 $NCC = (N^2 + N)P/N \approx NP$ である。この場合、計算量を決める可変なパラメータはない。

(7) 最大エントロピー法を用いたスペクトル解析法 (MEM)

MEM におけるフィルタの係数を求める過程は、フィルタの設計や、MLNN における学習と同様のため、

表 8 Normalized computation complexity とパラメータ数
(計算量が制限された場合)

Table 8 Normalized computational complexities and the number of parameters (computation is limited).

Methods	$N = 10$		$N = 20$	
	NCC	NP	NCC	NP
MLNN	3.6	3	3.3	3
FIR1	4.0	2	4.0	2
FIR2	2.0	—	2.0	—
Fourier	4.0	1	4.0	1
Euclid	4.0	2	4.0	2
MDG	—	—	—	—
MEM	2.8	1	4.0	2

N: Number of samples

NP: Number of parameter

表 9 Normalized computation complexity とパラメータ数
(計算量が制限されない場合)

Table 9 Normalized computational complexities and the number of parameters (computation is not limited).

Methods	$N = 10$		$N = 20$	
	NCC	NP	NCC	NP
MLNN	48	40	44	40
FIR1	20	10	20	10
FIR2	—	—	—	—
Fourier	12	3	12	3
Euclid	400	200	400	200
MDG	20	—	40	—
MEM	84	3	120	3

N: Number of samples

NP: Number of parameter

NCC の計算には算入しない。式(16)より $NCC = 2PN_F M/N$ である。 N_F は観測周波数の数、 M はフィルタの次数である。観測周波数の数 N_F がパラメータである。

NCC と各手法の計算量を決めるパラメータの数を表 8、表 9 に示す。表 8 は計算量が制限された場合である。これは、階層形 NN の NCC を基準として、他の手法の NCC がこれと同程度になるようにパラメータ数が決められている。パラメータ数は整数なので、各手法の NCC は完全には一致しない。表 9 は計算量が制限されない場合である。これは、各手法において高い分類率を得るに十分なパラメータ数となっている。

A.3 フィルタ係数の連続する部分波形の相関性

FIR フィルタの入力を $x(n)$ 、係数を $h(n)$ とすると、出力 $y(n)$ は次式で与えられる。

$$y(n) = \sum_{k=0}^{N-1} x(k)h(n-k) \quad (18)$$

ここで、 $x(n)$ は $n = 0 \sim N - 1$ の N サンプルのみから成る信号であるとする。 $y(n_0)$ を求めるために

は $h(n_0) \sim h(n_0 - N + 1)$, $y(n_0 + m)$ に対しては $h(n_0 + m) \sim h(n_0 + m - N + 1)$ が用いられる。これらを簡単に $h_0(n)$, $h_m(n)$ と表し、時間窓関数 $w(n)$ を用いて表すと次のようになる。

$$h_0(n) = h(n)w(n_0 - n), \\ n = 0 \sim N - 1 \quad (19)$$

$$h_m(n) = h(n)w(n_0 + m - n), \\ n = 0 \sim N - 1 \quad (20)$$

$$w(n) = \begin{cases} 1, & 0 \leq n \leq N - 1 \\ 0, & n < 0, N \leq n \end{cases} \quad (21)$$

まず、狭帯域低域通過フィルタ (LPF) について考える。通過帯域を f_c , サンプリング周波数を f_s , 振幅特性を通過域で 1, 阻止域で 0 とすると, LPF のインパルス応答 $h(n)$ は次式で与えられる。

$$h(n) = \frac{1}{2\pi} \int_{-\omega_c T}^{\omega_c T} e^{j\omega_n T} dw T, \omega_c = 2\pi f_c \\ = \frac{2f_c}{f_s} \frac{\sin \omega_c n T}{\omega_c n T}, \omega_c n T = 2\pi \left(\frac{f_c}{f_s} \right) n \quad (22)$$

フィルタ係数としては、フィルタ次数を $N_f - 1$ とすると, $h(n)$ を $(N_f - 1)/2$ だけ右側にシフトし, $0 \sim N_f - 1$ の区間を使用する。

次に, $h_0(n)$ と $h_m(n)$ との類似性について考える。式 (22) から, $\omega_c n_0 T$ と $\omega_c (n_0 + m) T$ とを比較すると、その差は $\omega_c m T = 2\pi(f_c/f_s)m$ である。一般に狭帯域 LPF では $f_s/f_c \gg 1$ であるから、 $f_s/f_c \gg m$ を満たす小さい m に対しては $2\pi(f_c/f_s)m \ll 2\pi$ が成り立ち、 $h_0(n)$ と $h_m(n)$ は類似する。

さらに、狭帯域の帯域通過フィルタ (BPF) のインパルス応答 ($h_p(n)$ とする), すなわち, FIR フィルタで構成したときのフィルタ係数について考える。 $h_p(n)$ は近似的には、狭帯域 LPF のインパルス応答に通過帯域の中心周波数を有する正弦波形を乗じることによって求められる。ここでは、複数の帯域を考え、その中心周波数を f_1 , f_2 , f_3 とする。 $h_p(n)$ は次式で表される。

$$h_p(n) = h(n)\{\cos(2\pi f_1 n T) + \cos(2\pi f_2 n T) \\ + \cos(2\pi f_3 n T)\} \quad (23)$$

前述の議論と同様に、フィルタ出力 $y(n_0)$, $y(n_0 + m)$ は次のようにフィルタ係数の一部を用いて計算される。

$$h_{p0}(n) = h_p(n)w(n_0 - n) \quad (24)$$

$$h_{pm}(n) = h_p(n)w(n_0 + m - n) \quad (25)$$

この場合は、 f_1 , f_2 , $f_3 \ll f_s$ が必ずしも成り立たないから、狭帯域 LPF のように隣接するフィルタ係

数が類似するという性質は保証されない。その結果、 $h_{p0}(n)$ と $h_{pm}(n)$ は波形そのものとして類似しなくなる。しかし、 $h_p(n)$ を生成するために乗じる正弦波形そのものはサンプル間の相関性が非常に高い波形であり、これより $h_{p0}(n)$ と $h_{pm}(n)$ の相関性も高くなる。言い換えると、 $f_s/f_c \gg m$, すなわち $h_0(n) \approx h_m(n)$ が成り立つ範囲では、 $h_{p0}(n)$ と $h_{pm}(n)$ は正弦波形のサンプル間と同様な相関性を持つことになる。

m がある程度大きくなり $h_0(n)$ と $h_m(n)$ の波形の類似性が低くなる場合でも、 $h_{p0}(n)$ と $h_{pm}(n)$ の相関性は正弦波形よりも低くなるが、ある程度の相関性を有する。

このように、狭帯域 BPF のフィルタ係数の隣接する部分波形は相関性が高く、この部分波形を係数とする超平面による N 次元空間の領域形成は自由度の低いものとなる。

(平成 8 年 5 月 16 日受付)

(平成 8 年 11 月 7 日採録)

原 一之 (正会員)



昭和 32 年生。昭和 57 年日本大学大学院生産工学研究科電気工学専攻博士前期課程修了。同年日本電気ホームエレクトロニクス(株)入社。高解像度ディスプレイ装置の設計に従事。平成元年より雇用促進事業団富山職業能力開発短期大学校講師。平成 4 年より金沢大学大学院自然科学研究科システム科学専攻在学。階層形ニューラルネットワークの汎化能力、分類能力の研究に従事。電子情報通信学会、INNS、IEEE 各会員。

中山 謙二

昭和 46 年東京工業大学工学部電子工学科卒業。昭和 46~47 年同大学研究生。昭和 58 年同大学より工学博士の学位取得。昭和 47 年日本電気(株)入社。伝送事業部および C&C システム研究所にて通信用各種フィルタ、デジタル信号処理、適応信号処理、ニューラルネットの研究に従事。昭和 63 年 8 月金沢大学工学部電気情報工学科助教授。平成 2 年 4 月同教授となり現在に至る。昭和 62 年 9 月 IEEE Circuits & Device Mag. 論文賞受賞。著書「SC 回路の設計と応用」(東海大学出版会)ほか。電子情報通信学会、INNS 各会員、IEEE シニア会員。