

玉石混交の情報源から本質的な情報を取り出すニューラルネットワーク — 人の話し声を使って —

菅田一博, 吉村宏紀, 清水忠昭, 井須尚紀

鳥取大学工学部 知能情報工学科

〒680-0945 鳥取県鳥取市湖山町南4-101

あらまし: 砂時計型ニューラルネットワーク(SNN)を用いて、観測された時系列信号から雑音成分を適応的に除去する雑音除去フィルタを提案した。SNNは、階層型ニューラルネットワークにおいて、入力層および出力層のユニット数を同数とし、中間層のユニット数を入出力層のユニット数よりも少なくしたネットワーク構造を持つ。本研究では、SNN雑音除去フィルタの雑音除去能力を理論的に明らかにするとともに、計算機実験により理論の実証を行った。実験結果より低SN比の信号に対しても、SNN雑音除去フィルタは大幅な雑音除去特性を示し有効な雑音除去フィルタとして働くことを示した。

Sandglass Type Neural Network to Pick Up Substantial Information Contaminated by Noise

Kazuhiro Sugata, Hiroki Yoshimura, Tadaaki Shimizu, Naoki Isu

Tottori University, Faculty of engineering,

Department of information and knowledge engineering

4-101 Koyama-minami, Tottori, 680 Japan

Abstract: The multilayer perceptron called Sandglass type Neural Network (SNN) has the same number of units in input layer and output layer and has less units in hidden layer than units both in input layer and output layer. In this paper we clarified the properties of a noise reduction filter using the SNN. The properties were derived basically by use of the result that the output signal of the SNN could be given by Karhunen-Loeve expansion of an input data matrix. Here, we evaluated the improvement value of signal to noise ratio for the optimum number of hidden units. The noise reduction filter was assured to be effective and stable by the computer experiments using sinusoidal signal corrupted by white noise.

1. はじめに

観測された信号から有用な情報を取り出すことは、情報処理において基本的かつ重要な問題である。音声、画像、脳波、地震波などが観測されたとき、それらから有用な情報を取り出すときに、まず雑音成分を低減することが考えられる。個体を特徴つける観測信号の個数が多いときには、それらの信号の情報をできるだけ保存した少数個の信号を新たに作ることが有効で

ある場合が多い。信号が独立でなく、互いに関連しているときに、関連性を上手に利用し、出来るだけ少ない情報の損失で、少数個の無相関な合成信号に情報を縮約して分析を行う方法が考えられてきた。

ところで、ニューラルネットワークは音声認識、画像認識などのパターンマッチング以外にも、適応ディジタルフィルタの観点から近年注目を集めており、雑音除去フィルタとしても

様々な応用がなされている⁽³⁾。ニューラルネットワークの1つに、Cottrellらによって提案された砂時計型ニューラルネットワーク(以下、SNNと呼ぶ。)がある⁽⁴⁾。SNNとは、画像圧縮を行うために提案されたニューラルネットワークで、入力層および出力層のユニット数を同数とし、中間層のユニット数を入力層および出力層のユニット数よりも少なくしたネットワーク構造を持つ。SNNは教師信号を入力信号と等しくして学習を行い、入力層および出力層のユニット数よりも少ない中間層ユニットの出力信号を利用することにより、画像信号、脳波などの情報圧縮に用いられている⁽⁵⁾⁽⁶⁾⁽⁷⁾。また、3層SNNに関して理論的な解析も行われており、Bourlandらは、出力信号と教師信号の2乗誤差を評価関数とするSNNの最適な結合加重が、学習に用いる入力信号のKL変換によって与えられることを理論的に証明した⁽⁸⁾。渡辺らは、中間層のユニット数が1個のSNNが、入力信号の偏りの有無や、共分散行列が正則、非正則にかかわらず、KL変換の第1主成分(第1次KL変換成分)を出力することを数学的に証明した⁽⁹⁾⁽¹⁰⁾。舟橋は、P個の中間層ユニットを持つSNNの能力が、KL変換の第P主成分までによる近似能力以下であることを数学的に証明した⁽¹¹⁾⁽¹²⁾。

一方、ニューラルネットワークの学習アルゴリズムとして、誤差逆伝播学習法(BP)が一般に用いられているが、学習の収束速度の向上を計るために、Scaleroらは高速学習法を提案している⁽¹³⁾。BP法が勾配型アルゴリズムであるのに対して、Scaleroらの提案した方法は逐次最小2乗法(RLS)を応用したアルゴリズム(以下、RLS学習法と呼ぶ。)であるため、学習回数を飛躍的に少なくすることが可能である。

そこで本研究では、SNNにRLS学習法を適用することにより、観測された時系列信号(観測信号)から雑音成分をオンラインで除去する砂時計型ニューラルネットワーク雑音除去フィルタ(Sandglass type Neural network Noise Reduction Filter: 以下、SNNRFと呼ぶ)を提案する。提案するSNNRFの雑音除去の能力は、KL展開によ

るフィルタリングと同じであるが、KL展開を直接用いた場合オフライン処理となる⁽¹⁾⁽²⁾。これに対し、本手法は学習アルゴリズムとしてRLS学習法を用い、さらにSNNに観測信号が入力される毎に学習を行い、逐次出力信号を出力することによりオンライン処理を可能とした。提案するSNNRFは、中間層のユニット数を観測信号に含まれている信号成分の共分散行列のランクと同じ数にすることにより、最適な雑音除去フィルタが構成されることを明らかにした。これを確かめるために、正弦波信号にガウス性白色雑音を付加した信号を雑音除去の対象に用いて計算機実験を行った。

2. 砂時計型ニューラルネットワークを用いた雑音除去フィルタ

2・1 砂時計型ニューラルネットワーク雑音除去フィルタ(SNNRF)の構造

SNNRFの模式図を図1に示す。SNNの構造は、3層階層型ニューラルネットワークとし、入力層のユニット数をN個、中間層のユニット数をP個($P < N$)、出力層のユニット数をN個とする。しきい値ユニットは設けない。ユニットの応答関数は線形関数とする。これは、学習過程においてlocal minimumに陥ることを回避するためである⁽¹²⁾。図1に示すように、観測信号 $x(k)$ は入力層の最も下のユニットに順次入力

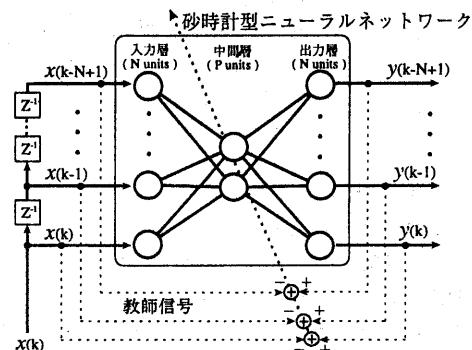


図1 砂時計型ニューラルネットワーク雑音除去フィルタの学習モデル

され、1時刻過ぎる毎に遅れ要素を通って1つ上のユニットへと入力される。学習は観測信号 $x(k)$ が入力される毎に行い、結合加重が修正される。以後、観測信号が入力されたときの、SNN の入力層の全ユニットに入力されている信号を入力信号と呼び、入力信号と教師信号の組を学習信号とよぶ。但し、入力信号と教師信号は同じ信号である。

2・2 SNNRFによる雑音成分の除去

SNN の学習誤差(1出力ユニットあたりの平均誤差2乗和)を以下のように定義する。

$$E = \frac{1}{NT} \sum_{t=1}^T |\mathbf{Y}^{(t)} - \mathbf{X}^{(t)}|^2$$

$\mathbf{X}^{(t)}$: $t(t=1, \dots, T)$ 番目の入力信号

$\mathbf{Y}^{(t)}$: $t(t=1, \dots, T)$ 番目の出力信号

ここで、 $\mathbf{X}^{(t)}, \mathbf{Y}^{(t)}$ はともに N 次元ベクトルである。

このとき、中間層のユニット数が P 個での誤差最小時の学習誤差は式(1)で与えられる⁽¹²⁾。

〔性質1〕

$$E(P) = \frac{1}{N} \left(\text{tr} \mathbf{R}_x - \sum_{i=1}^P \lambda_i \right) \quad (1)$$

P : 中間層のユニット数

$\text{tr} \mathbf{R}_x$: \mathbf{R}_x のトレース ($\text{tr} \mathbf{R}_x = \sum_{i=1}^N \lambda_i$)

但し、 \mathbf{R}_x は入力信号 $\mathbf{X}^{(t)}$ ($t=1, \dots, T$) の共分散行列、 λ_i は \mathbf{R}_x の固有値 ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N \geq 0$) である。

いま、SNN の学習の対象として以下のようない信号を考える。

$$x(k) = s(k) + e(k) \quad k=1, 2, \dots \quad (2)$$

ここで、 $x(k)$ は観測信号、 $s(k)$ は信号成分(原信号)、 $e(k)$ は雑音成分である。雑音成分 $e(k)$ は信号成分 $s(k)$ と独立な平均値 0、分散 σ_e^2 のガウス性白色雑音とする。

まず観測信号の共分散行列の固有値を求め る。信号成分の共分散行列を \mathbf{R}_s 、雑音成分の共

分散行列を \mathbf{R}_e で表す。信号成分と雑音成分は独立であると仮定しているので、信号成分と雑音成分は互いに無相関である。そのため観測信号の共分散行列 \mathbf{R}_x は、

$$\mathbf{R}_x = \mathbf{R}_s + \mathbf{R}_e \quad (3)$$

となる。但し $\mathbf{R}_x, \mathbf{R}_s, \mathbf{R}_e$ はともに $N \times N$ の行列である。 \mathbf{R}_x は対称行列であるので、 \mathbf{R}_x の固有値は適当な直交行列を用いて対角化することによって求まる。 \mathbf{R}_x を対角化するための直交行列を \mathbf{U} とおくと、

$$\mathbf{U}^{-1} \mathbf{R}_x \mathbf{U} = \begin{bmatrix} \lambda_1 & & & 0 \\ & \lambda_2 & & \\ & & \ddots & \\ 0 & & & \lambda_N \end{bmatrix} \quad (4)$$

となる。式(4)において、右辺の対角要素が固有値である。このとき、 \mathbf{U} における第 i 列は λ_i に対する固有ベクトルとなる。KL 変換における第 i 主成分の変換係数は、 \mathbf{R}_x の固有値 λ_i ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N \geq 0$) に対する固有ベクトルである。

〔定理1〕 信号成分の共分散行列 \mathbf{R}_s のランクを P としたとき、信号成分を学習の対象とする SNN で学習誤差をゼロとするために必要十分な中間層のユニットの個数は P である。

(証明) 信号成分の共分散行列 \mathbf{R}_s のランクは P であるので、 \mathbf{R}_s の固有値 λ_i ($i=1, \dots, N$) は、

$$\begin{cases} \lambda_i > 0 & i=1, \dots, P \\ \lambda_i = 0 & i=P+1, \dots, N \end{cases} \quad (5)$$

となる。性質1より学習誤差をゼロとするためには、中間層のユニット数は P 個以上必要となり、逆に P 個あれば学習誤差をゼロとするのに十分である。□

[補題2] 観測信号の共分散行列 R_x は式(6)の形に書き換えられる。

$$U^{-1}R_xU = \begin{bmatrix} \lambda_1 + \sigma_e^2 & & & \\ & \ddots & & 0 \\ & & \lambda_p + \sigma_e^2 & \\ & & & \sigma_e^2 \\ 0 & & & \\ & & & \ddots & \\ & & & & \sigma_e^2 \end{bmatrix} \quad \dots \quad (6)$$

(証明) 式(3)より,

$$U^{-1}R_xU = U^{-1}R_sU + U^{-1}R_eU \quad \dots \quad (7)$$

が成り立つ。雑音成分の共分散行列 R_e は、 $R_e = \sigma_e^2 I$ であるから、 R_e は U で対角化される。よって、 R_x を対角化する U を用いることにより R_s も対角化され、

$$U^{-1}R_sU = \begin{bmatrix} \lambda_1 & & & \\ & \ddots & & 0 \\ & & \lambda_p & \\ & & & 0 \\ 0 & & & \\ & & & \ddots & \\ & & & & 0 \end{bmatrix} \quad \dots \quad (8)$$

で表される。これより、式(6)が導かれる。
□

[定理3] 信号成分の共分散行列 R_s のランクが P であれば、中間層のユニット数が P 個のSNN を用いることにより、学習後の出力信号は信号成分の情報を欠如することなく、最も雑音成分を除去することが可能である。

(証明) 性質1および補題2より、中間層のユニット数を P 個とすることにより、SNN によって信号成分は全て変換される。一方、雑音成分は SNN によって第 P 主成分までの成分が変換され、第 $P+1$ 主成分から第 N 主成分までの成分は変換されない。よって、SNN の出力信号は信号成分を欠如することなく、雑音成分を低減することが可能である。□

[定理4] 信号成分の共分散行列 R_s のランクが P であれば、SNN を用いて学習後には出力信号の SN 比を最大 $10\log_{10}(N/P)$ [dB] 改善することが可能である。

(証明) 性質1より、中間層のユニット数が P 個のときの学習誤差は、

$$E(P) = \frac{1}{N} \sum_{i=P+1}^N \sigma_i^2 = \frac{N-P}{N} \sigma_e^2 \quad \dots \quad (9)$$

となる。定理3より式(9)の学習誤差は、信号成分を欠如することなく、除去された雑音成分の分散に等しい。ここで、入力信号のSN比を以下のように定義する。

$$SN = 10\log_{10} \frac{\sigma_s^2}{\sigma_e^2} \quad \dots \quad (10)$$

但し、 σ_s^2 は信号成分の分散、 σ_e^2 は雑音成分の分散を表す。

このとき、出力信号に含まれる雑音成分の分散は、 $(P/N)\sigma_e^2$ に低減される。よって、観測信号の SN 比は $10\log_{10}(\sigma_s^2 / (P/N)\sigma_e^2)$ [dB] であるのに對し、出力信号の SN 比は、 $10\log_{10}(N\sigma_s^2 / P\sigma_e^2)$ [dB] となり、 $10\log_{10}(N/P)$ [dB] 改善することができる。□

2・3 高速学習アルゴリズムによるオンライン処理

2.2節の定理4に示したSNNRFの雑音除去の能力は、直接KL展開によりフィルタリングを行った場合と同じ能力を持つが、KL展開を行うためには得られたすべての観測信号から共分散行列を求め、固有ベクトルを求めなければならず、オフライン処理となってしまう。

それに対して本手法では、観測信号 $x(k)$ が順次入力される毎にそのときの入力信号に対して学習を行い、結合加重の更新の後に逐次出力信号を出力することができる。そのため、オンラインでの処理が可能である。

また学習アルゴリズムとして、一般に用いられている誤差逆伝播学習法(BP法)の適用は、勾配型の学習法の1つであるため学習の収束に時間がかかり、多くの観測信号データが必要と

なる。本手法では、高速な収束特性を有する逐次最小2乗法を応用したRLS学習法⁽¹³⁾を用いることにより、収束速度の向上を計った。さらに、観測信号 $x(k)$ が順次入力された時の入力信号に対して、1回のRLS学習だけでは十分な結合加重の更新が行えないと考え、観測信号 $x(k)$ が入力される毎に、そのときのSNNの入力信号に対して $I_r \geq 2$ 回繰り返して学習を行う。

3. 白色雑音を含む正弦波からの雑音の除去

3・1 問題の設定

SNNRFの有効性を示すために、以下のような雑音に埋もれた信号を対象に計算機実験を行う。

$$x(k) = s(k) + e(k) \quad k = 1, 2, \dots, L \quad (11)$$

$$s(k) = \sum_{i=1}^M A_i \cos(\omega_i t_k + \theta_i) \quad t_k = k\Delta t \quad (12)$$

$e(k)$: 平均値0, 分散 σ_e^2 のガウス性白色雑音。ここで、 Δt はサンプリング間隔(周期), ω_i ($\omega_i = 2\pi f_i$)は角周波数である。 A_i は振幅, θ_i は初期位相を表す。

式(11), (12)に示す信号は、周波数推定問題などの対象としてよく用いられている信号である。また、音声信号などの調和信号は近似的に正弦波の和として表すことができる。故に、SNNRFを信号処理の前段階におけるプレフィルタとして用いることを考えれば、式(11), (12)の信号を雑音除去の対象とすることは有用である。

3・2 最適な中間層のユニット数

[定理5] 白色雑音下の単一正弦波の雑音除去に最適な中間層のユニット数は2個となる。

(証略)

[定理6] 正弦波がM個含まれておれば、中間層のユニット数を2M個とすれば最適である。

(証略)

4. 実験による検証

これまで、SNNRFの雑音除去能力に関して、理論的に議論を展開してきた。理論と実際の整合性を検証するために、以下に示す信号を対象に計算機実験を行い SNNRFの雑音除去能力を評価した。

$$x(k) = A_1 \cos(\omega_1 t_k + \theta_1) + e(k) \quad k = 1, \dots, 65 \quad (13)$$

ここで、 $A_1 = 1$, $\omega_1 = 2\pi f_1$ [rad/s], $f_1 = 3/(16\Delta t)$ [Hz], $\Delta t = 1$ [s], $\theta_1 = -\pi/2$ とし、 $e(k)$ は平均値0, 分散 σ_e^2 のガウス性白色雑音とした。

実験に用いたSNNの入力層および出力層のユニット数は16個とした。

4・1 SNNRFの雑音除去能力

図2に中間層のユニット数が2個のときの、学習後の出力信号の1例を示す。図2(a)はSN比5 [dB]の学習信号(入力信号), 図2(b)は学習後の出力信号である。図2(c)は入力信号に含まれる信号成分を表わしている。1パターン毎の学習回数 $I_r = 3$, 忘却係数 $\eta = 1.0$ として学習を行った。さらに図3(a)および図3(b)に入力信号(学習信号)および学習後の出力信号の平均振幅スペクトルを示す。信号成分の周波数はグラフ上の離散周波数 $3/16$ [Hz] ($\omega = 3/8\pi$)である。図3(a), (b)より出力信号は雑音成分が低減されていることが分かる。

4・2 中間層のユニット数と雑音除去能力の関係

図4に、SNNの中間層のユニット数を1個から4個に可変にした場合の、学習後の出力信号のSN比について示す。ここでは、出力信号のSN比を以下のように定めた。

$$SN_{out} = 10 \log_{10} \left(\frac{1}{T - \tau + 1} \sum_{t=\tau}^T \frac{\|\mathbf{S}^{(t)}\|^2}{\|\mathbf{Y}^{(t)} - \mathbf{S}^{(t)}\|^2} \right) \quad (14)$$

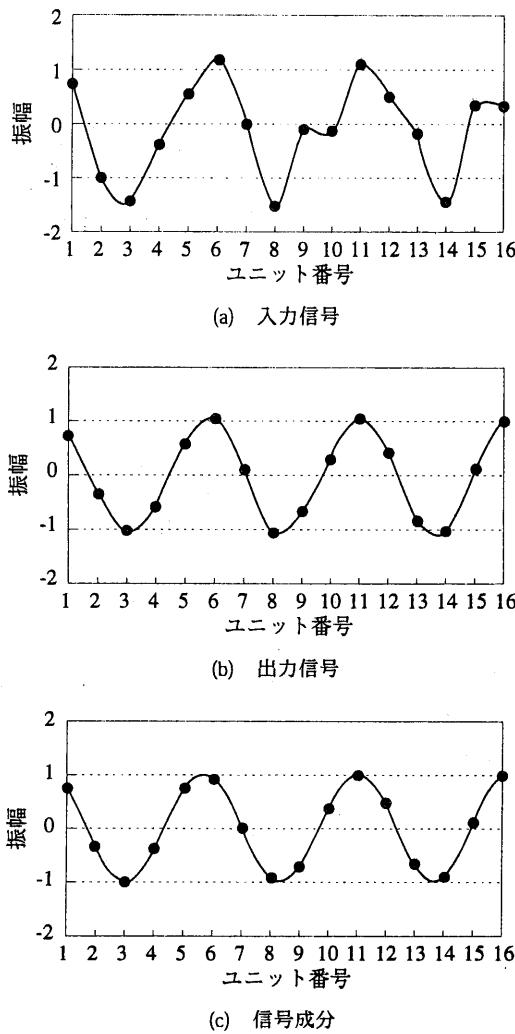


図2 SNNRFによる雑音除去の1例

$$\mathbf{Y}^{(t)} = [y(t), \dots, y(t+N-1)]$$

$$\mathbf{S}^{(t)} = [s(t), \dots, s(t+N-1)]$$

$$\tau = 11$$

ここで、 $\mathbf{Y}^{(t)}$ は t 番目の出力信号、 $\mathbf{S}^{(t)}$ は t 番目の入力信号に含まれる信号成分である。 $\mathbf{Y}^{(t)}$ 、 $\mathbf{S}^{(t)}$ はともに N 次元ベクトルである。また、式(14)より $k = 1, \Delta c, 65$ ($L=65$) としたので、全学習信号の数 $T = 50$ ($T = L - N + 1$) である。

図4に示されている各中間層のユニット数に対する出力信号の SN 比は、異なる雑音成分の学

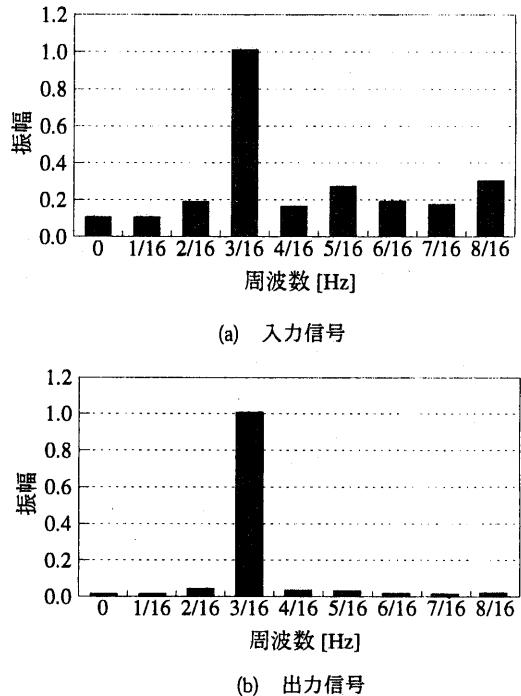


図3 入力信号および出力信号の平均振幅スペクトル

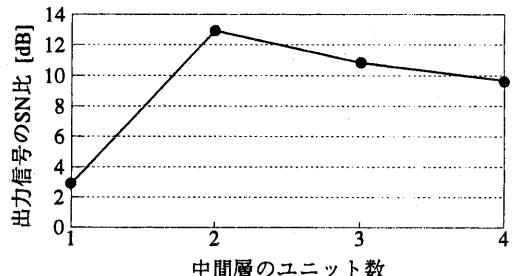


図4 中間層のユニット数に対する出力信号のSN比

習信号を 30 系列作成し、それらの出力信号の SN 比の平均値を示している。学習に用いた入力信号（学習信号）の SN 比は 5 [dB]、1 パターン毎の学習回数 $I_r = 3$ 、忘却係数 $\eta = 1.0$ とした。図4より、中間層のユニット数が 2 個の場合が最も SN 比を改善していることが分かる。中間層のユニット数が 3 個、4 個となるにつれて SN 比が低下するのは、雑音成分の情報しか持たない第3、第4主成分の情報が結合加重に

反映されるためである。中間層のユニット数が1個の場合は、SN比を悪化した。これは、第1主成分までの情報のみが結合加重に反映され、第2主成分まで必要とする信号成分の情報をすべて反映することができないために、信号成分の情報を欠如したからである。以上より、図4の結果は定理3および定理5の議論と一致していることが分かる。

4・3 学習信号のSN比と雑音除去能力の関係

学習信号に用いる入力信号のSN比がSNNRFの雑音除去能力に及ぼす影響を調べるために、中間層のユニット数が2個のSNNを用いて、学習信号のSN比が-5[dB]から20[dB]の各々の場合について、異なる雑音成分の学習信号を30系列作成し学習を行い、出力信号のSN比を調べた。図5に各SN比の入力信号（学習信号）に対する学習後の出力信号のSN比の平均値を示す。1パターン毎の学習回数 $I_r = 3$ 、忘却係数 $\eta = 1.0$ とした。図5より、入力信号のSN比が5から20[dB]において、出力信号のSN比の平均値は定理2で与えられる理論的限界値 $10\log_{10}(N/P) = 10\log_{10}(16/2) \approx 9.03[\text{dB}]$ 近くまで改善がみられた。理論的限界値との差は、逐次的な学習を行っているために、学習初期に対するSN比の改善度が小さかったことに起因する。入力信号の各SN比で作成したすべての学習系列で、出力信号のSN比は入力信号のSN比を下回ることはなかった。以上の結果より、SNNRFは安定した雑音除去フィルタであると言える。

4・4 忘却係数 η と雑音能力との関係

忘却係数 η とSN比の関係について示す。本実験で用いた高速学習アルゴリズム(RLS学習)は適応フィルタリングでよく用いられている逐次最小2乗アルゴリズムを基本としており、そのため忘却係数 η というパラメータが導入されている⁽¹³⁾。高速学習アルゴリズムは、一般に η の設定が小さすぎると結合加重の更新は大きく、学習誤差の収束は速くなるが、不安定となる。逆に η の設定が大きすぎると結合加重の更新が小さく学習誤差の収束が遅くなる。ま

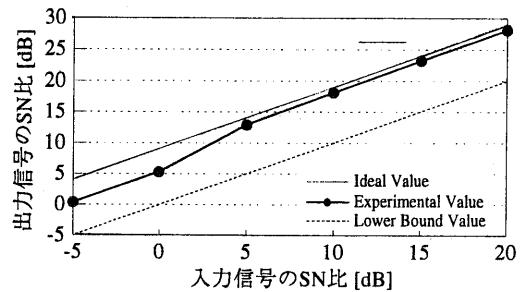


図5 入力信号（学習信号）のSN比に対する出力信号のSN比

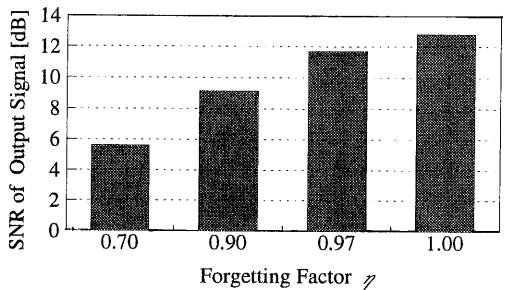


図6 忘却係数 η の変化に対する出力信号のSN比

た、そのために local minimum に陥るという問題が起きる。但し、提案する SNNRF は、線形ユニットを用いているため、local minimum を考慮する必要はない⁽¹²⁾。図6に $\eta = 0.70, 0.90, 0.97, 1.00$ について、出力信号のSN比を示す。図6に示すように、 η が小さくなるにつれて、SN比の改善は悪くなっている。これは η の値を小さく設定するにつれて、学習が不安定となり、雑音の除去に失敗したパターンが増えたためである。

5. おわりに

中間層のユニット数がP個のSNNの出力信号が最適状態で、入力信号の第P主成分までのKL展開によって得られた信号と等しくなるという性質を利用することにより、SNNによる雑音除去フィルタ(SNNRF)を提案した。SNNRFの中間層のユニット数を信号成分の共分散行列のランクとすることにより、SNNRFが構成されることを理論的に示した。提案した SNNRF

はオンラインでの処理を可能としているため、実時間の雑音除去を必要とする問題への適用に有効である。

計算機実験の結果から、SNNRFは学習信号1パターン毎の学習回数Irを複数回（本実験では3回以上）に設定することにより、出力信号のSN比が入力信号のSN比を大幅に改善し、安定した雑音除去フィルタとなることが示された。

本論文では最適なSNNRFと信号成分の共分散行列のランクとの関係を示すために、ランクが既知である単一正弦波を信号成分として計算機実験によりSNNRFの評価を行った。実際に現実の信号処理にSNNRFを適用する上で、対象となる信号の共分散行列のランクを知る必要がある。しかし、信号処理（雑音除去）の対象を定めれば、対象となる信号の性質が予めわかるのでランクは推定できる。例えば、11.025 [kHz]でサンプリングされた音声信号により音声認識を行うためには、ランクは12以下で充分である。実際に白色雑音を付加した音声信号を用いた計算機実験では、中間層のユニット数を6,7個とすることにより、SNNRFはSN比を最も向上させることができた。

文献

- (1) Tufts D.W. and Kumarean R. : "Singular value decompositon and improved frequency estimation using linear prediction" , IEEE Trans. Acoust. Speech Signal Process., ASSP-30-4,pp.671 - 675 (1982).
- (2) Hamida M. and Pearl J. : "Comparison of the cosine and fourier transforms of markov-1 signals" , IEEE Trans. Acoust. Speech Signal Process., ASSP-24,pp428 - 429(1976)
- (3) 荒川 薫, 原島 博 : "バックプロパゲーションによる階層型ニューラル非線形フィルタの設計", 信学論(A), J74-A,3,pp.421 - 429 (1991).
- (4) Cottrell G. W., Munro P. and Zipser D. : "Image compression by back-propagation : An example of extensional programming" , Advances in Cognitive Science,3,pp.208 - 240,Ed.Sharkey N.E.,Norwood,NJ : Ablex (1988).
- (5) 曽根原登, 川人光男, 三宅 誠, 中根一成：“ニューラルネットによる画像データの圧縮 (Neuro-CODEC) の検討”, 信学技報, IE88 - 62 (1988)
- (6) 長坂保典, 岩田 彰, 鈴村宣夫：“ニューラルネットワークによる長時間心電図の特徴抽出と情報圧縮”, 信学技報, MBE88 - 91 (1988).
- (7) 入江文平, 川人光男：“多層パーセプトロンによる内部表現の獲得”, 信学論(D-II), J73 - D - II,8,pp.1173 - 1178 (1990)
- (8) Bourlard H. and Kamp Y.: "Auto-association by multilayer perceptrons and singular value decomposition" , Biol.Cybern.,59,pp.291 - 294 (1988).
- (9) 渡辺一央, 伊東英彦, 増田一, 大堀隆文：“KL変換用多段接続形パーセプトロン” , 信学論(D-II), J75-D-II,11,pp.1925 - 1932 (1992).
- (10) 渡辺一央, 大堀隆文, 下沢橋夫：“KL変換用単位パーセプトロンの収束特性に関する理論的考察”, 信学論(D-II), J75-D-II,11,pp.1933 - 1939 (1992).
- (11) 舟橋賢一：“3層ニューラルネットワークによる恒等写像の近似的実現についての理論的考察”, 信学論(A), J73-A,1,pp.139 - 145 (1990).
- (12) Baldi P. and Hornik K.: "Neural networks and principal component analysis : Learning from examples without local minima" , Neural Networks,2,pp.53 - 58 (1989).
- (13) Scalero R. S. and Tepedelenlioglu N. : "A fast new algorithm for training feedforward neural networks" , IEEE Trans.Signal Process., 40, 1, pp.202 - 210 (1992).