

## ニューラルフィルタの簡約構造決定手法

鈴木 賢治<sup>†</sup> 堀場 勇夫<sup>†</sup> 杉江 異<sup>††</sup>

本論文では、階層型ニューラルネット（NN）で構成される信号処理フィルタであるニューラルフィルタ（NF）の入力層ユニットの構成（フィルタ窓の範囲や形状）、および、中間層ユニット数を自動的に決定する手法を提案する。本手法では、試験的にユニットを削除したときの誤差への影響に基づきユニットを削減し、この削減により増加した誤差を再学習により回復する。これらユニット削減と再学習を交互に行うことにより、目標誤差を達成する最小規模の構造のNFを得る手法である。まず、2次元自然画像の画質改善問題を学習させたNFに本手法を適用し、手法の実行時間、ユニットの削減性能、ユニット削減後のNFのフィルタ性能の観点から従来手法と定量的に比較評価する。さらに、演算量が大きな課題となっている医用X線動画像の画質改善を学習させたNFにおいても比較評価を行う。これらの比較評価実験により、本手法は、ユニットの削減性能に優れ、ユニット削減後のNFはフィルタ性能が高いことを示す。

### A Method for Determining Reduced Structure of a Neural Filter

KENJI SUZUKI,<sup>†</sup> ISAO HORIBA<sup>†</sup> and NOBORU SUGIE<sup>††</sup>

In this paper, we propose a new method for determining the reduced structure of neural filters (NF), and evaluate its performance. Experimental results demonstrate that the proposed method removes redundant units from the NF effectively, and that the performance of the NF obtained by the proposed method is superior to that of the original NF. By the comparative evaluation, we show that the proposed method is superior to the ability of the conventional methods quantitatively in terms of the ability of removal of the units, the filter performance of the NF and the generalization ability of the NF.

#### 1. はじめに

近年、学習機能を持つ非線形情報処理システムである階層型ニューラルネット（NN）をコンボリューション型フィルタとして利用したニューラルフィルタ（NF）が、その優れた非線形処理能力から研究されている<sup>1)~9)</sup>。それらは、(1) しきい値分解の原理に基づくスタッツフィルタとして実現したもの<sup>1)~4)</sup>、(2) 階層型NNに直接信号を入力するもの<sup>5)~9)</sup>に大別できる。文献1)~4)では、NFがランクオーダーフィルタ、離散時間形態素フィルタ、一般化荷重順序統計フィルタ、メディアンフィルタなどのフィルタを表現可能なモデルであることが示されており、文献5)、6)では、 $\epsilon$  フィルタがNFの特別な場合に相当することが示されている。また、階層型NNは任意の連続写像を任

意の精度で近似できるモデルであることが証明されているため<sup>10),11)</sup>、筆者らは、これをモデルとしたフィルタも高い性能を持つと期待して、分類(2)に属するNFを用いて医用X線動画像の画質改善技術の実用化を目指して研究を行っている<sup>9)</sup>。NFは入力信号とそれに対応する理想的な教師信号を与え、学習によりフィルタパラメータを適切に設計することにより、従来の非線形フィルタより高い性能を持つことが可能である<sup>1)~9)</sup>。しかし、フィルタ窓の範囲や形状、および中間層ユニット数などの構造は、この学習により決定できるものではなく、開発者の経験などに基づいて決定されている。このため、NFは学習対象に対して必ずしも最適な構造となっておらず、通常冗長な演算ユニットが多く存在する。そのため、演算やハードウェア実現のコストが増大し、汎化能力（未学習画像に対する能力）が低下しているだけでなく、ネットワークの解析を困難にしている。特にNFを動画像処理に応用する場合には、その演算量が深刻な問題となるため、NFの構造の合理的かつ自動的な決定が実用化のための重要な課題である。

<sup>†</sup> 愛知県立大学情報科学部

Faculty of Information Science and Technology, Aichi Prefectural University

<sup>††</sup> 名城大学理工学部

Faculty of Science and Technology, Meijo University

NFが利用しているモデルであるNNの構造決定に関する研究では、特に中間層ユニット数の決定に関して様々な手法が提案されている<sup>12)~23)</sup>。パターン認識などのNNの中心的な応用問題では、入力層ユニットおよび出力層ユニットの構成が、対象とする問題により自ずと決定されるため、これらの手法は最適な中間層ユニット数を求めるよう開発されている。それらを大別すると以下のようになる。

- (1) 学習-収束を繰り返しながら、定義された評価基準により不要と判定された中間層ユニットを次第に削減していく方法<sup>12)~16)</sup>。
- (2) 中間層ユニット数を変えて学習したときのネットワークの良さを評価する方法<sup>17)~19)</sup>。
- (3) 学習中に不要な重みを縮退させる、または、定義された評価基準により不要と判定された重みを次第に削減していく方法<sup>20)~25)</sup>。

これらの手法をNFの構造決定、すなわち、入力層ユニットの構成(フィルタ窓の範囲や形状)、および中間層ユニット数の決定へ適用することを考えた場合、分類(1)の文献12)~15)の手法では、定義された評価基準が、入力層の構造決定を考慮したものとなっていないため、NFの構造決定に向くものではないと考えられる。文献16)の手法では、ユニットへの伝播誤差が大きいほど悪いユニットとする評価基準により削減を行うが、誤差とのかかわりが大きい入力層の重要なユニットも伝播誤差は大きくなるため、必ずしも入力層の構造決定に向くものではない。分類(2)の手法では、中間層ユニット数の決定の場合には、中間層ユニット数分のNNを学習させればよいが、ここで検討しようとしている入力層をも含めた構造決定に対しては、入力層ユニットはその配置に意味を持つため、組合せは膨大であり実用的でない。分類(3)の手法は、基本的には重みを削減する手法である。信号処理ハードウェアの実装の観点から、NFは同一構造の処理ユニットの組合せで実現した方が都合がよいため、分類(3)の手法よりユニットごとに削減する手法の方が適していると考えられる。さらに、これらの手法を組み合わせることも考えられるが、各手法では構造決定のための方針が異なるため、お互いの評価が干渉する可能性があり、性能が向上することは限らない。このような理由から、これらを組み合わせた手法は提案されていない。このように、従来手法はNNの中間層ユニット数の決定では効果があるものの、必ずしも入力層を含めたNFの構造決定に適合するものではないと考えられる。

そこで、本論文ではNFの入力層ユニットの構成、

すなわち、フィルタ窓の範囲や形状、および、中間層ユニット数を自動的に決定する手法を提案する。NFは、教師信号と出力との誤差を最小化するよう重みを最適化する学習型のフィルタであることから、本手法では、誤差がある大きさ以下で、ユニット数を最小にすることを評価基準としてNFの構造を決定する。すなわち、試験的にユニットを削除したときの誤差への影響に基づきユニットを削減し、この削減により増加した誤差を再学習により回復する。これらユニット削減と再学習を交互に行うことにより、目標誤差を達成する最小規模の構造のNFを得る手法である。以下ではまず、2次元自然画像の画質改善問題を学習させたNFに本手法を適用し、手法の実行時間、ユニットの削減性能、ユニット削減後のNFのフィルタ性能の観点から、従来手法と定量的に比較評価する。さらに、演算量削減が実用化の大きな課題となっている医用X線動画像の画質改善を学習させたNFにおいても比較評価を行う。これらの比較評価実験により、本手法の有効性を示す。

## 2. 簡約構造決定手法

### 2.1 ニューラルフィルタの構造

NFは階層型NNで構成される信号処理フィルタである。ここでは動画像処理用の時空間フィルタとして実現されたNF<sup>9)</sup>を例に説明する。このフィルタは図1に示すように、Q個の層で構成され、第q層のユニット数は $N^{(q)}$ である。ただし、出力層のユニット数 $N^{(Q)}$ は1である。入力層、中間層、出力層ユニットの各応答関数は、恒等関数、シグモイド関数、線形関数である。図中のx、yは座標、tは時刻、 $t_0$ は注目フレームの時刻、Tはサンプリング期間である。NFは次式に示すように、注目画素 $g(x, y, t)$ および時空間的近傍画素の時空間情報を入力し、注目画素に対応する画素の情報 $f(x, y, t)$ を出力する。

$$f(x, y, t) = NN(\mathbf{I}_{x, y, t}) \quad (1)$$

$$\mathbf{I}_{x, y, t} = \{g(x - i, y - j, t - k) | i, j, k \in R\} \quad (2)$$

ただし、 $\mathbf{I}_{x, y, t}$ は注目画素の座標を $(x, y, t)$ とする入力ベクトル、 $NN(\mathbf{I})$ は $\mathbf{I}$ を入力ベクトルとする階層型NNの出力、Rはフィルタ窓の時空間領域である。ここで、入力ベクトル $\mathbf{I}_{x, y, t}$ を、入力層のm番目のユニットへ入力される入力情報 $I_m$ を用いて、次式のように書き換える。

$$\begin{aligned} \mathbf{I}_{x, y, t} &= \{g(x - i, y - j, t - k) | i, j, k \in R\} \\ &\equiv \{I_1, I_2, \dots, I_m, \dots, I_{N^{(1)}}\} \end{aligned} \quad (3)$$

入力層ユニットの応答関数は恒等関数 $f_I$ であるので、入力層のn番目のユニットの出力は次式のように表

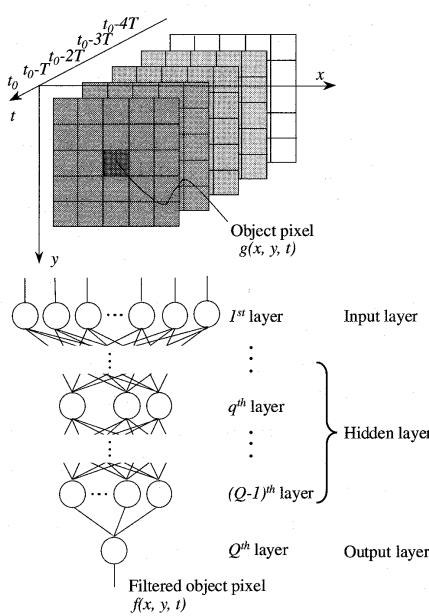


図1 ニューラルフィルタの構造  
Fig. 1 Architecture of the neural filter.

される。

$$O_n^{(1)} = f_I(I_n) = I_n \quad (4)$$

第  $q - 1$  層の各ユニットは、第  $q$  層の各ユニットと相互に接続されており、第  $q$  層の  $n$  番目のユニットの出力は次式のように表される。

$$O_n^{(q)} = f_S \left\{ \sum_{m=1}^{N^{(q-1)}} (W_{mn}^{(q)} \cdot O_m^{(q-1)}) - W_{0n}^{(q)} \right\} \quad (5)$$

ただし、 $W_{mn}^{(q)}$  は第  $q - 1$  層の  $m$  番目のユニットと第  $q$  層の  $n$  番目のユニットを結合する重み、 $W_{0n}^{(q)}$  は第  $q$  層の  $n$  番目のユニットのオフセット、 $f_S(u)$  は次式のシグモイド関数である。

$$f_S(u) = \frac{1}{1 + \exp(-u)} \quad (6)$$

出力層のユニットの出力は次式で表される。

$$\begin{aligned} NN(\mathbf{I}_{x,y,t}) \\ = f_L \left\{ \sum_{m=1}^{N^{(Q-1)}} (W_m^{(Q)} \cdot O_m^{(Q-1)}) - W_0^{(Q)} \right\} \end{aligned} \quad (7)$$

ただし、 $W_m^{(Q)}$  は第  $Q - 1$  層の  $m$  番目のユニットと出力層ユニットを結合する重み、 $W_0^{(Q)}$  は出力層ユ

ニットのオフセット、 $f_L(u)$  は次式の線形関数である。

$$f_L(u) = u + \frac{1}{2} \quad (8)$$

NF は複数枚の入力画像とその注目画像に対する理想的な教師画像を与えて、最適な重みを獲得するよう学習させる。重みを学習するための評価関数である誤差関数は、次式で定義される。

$$E = \sum_p \{T_C^p - f^p\}^2 \quad (9)$$

ただし、 $T_C^p$  は教師画像の学習領域の  $p$  番目の画素、 $f^p$  は出力画像の学習領域の  $p$  番目の画素である。学習は、バックプロパゲーション<sup>26)</sup>により誤差  $E$  が目標誤差  $E_P$  より小さくなるか、または、学習回数が設定学習回数  $T_P$  を超えるまで行う。

## 2.2 提案手法

提案する構造決定手法は、十分な入力層ユニットと中間層ユニットで  $E \leq E_P$  となるまで学習させた NF に対して適用し、目標誤差  $E_P$  を達成する最小規模の NF の構造を得ようとするものである。ユニットを削除した場合の誤差  $E$  への影響が最も小さいユニットから削除し、ユニット削除により増加した誤差を再学習により回復する。これらユニット削減と再学習を同じ評価基準の基に交互に行うことにより、ネットワークの持つ自由度を、獲得すべき問題の自由度に徐々に一致させる手法である。NF の出力層は通常 1 ユニットであるため、ユニットの削減対象は入力層と中間層となる。ここで、 $E^{(n,q)}$  を第  $q$  層の  $n$  番目のユニットを削除した場合の誤差と定義する。提案手法のフローチャートを図2に示す。なお、図中の  $F^{(q)}$  は削減対象の層を示すフラグであり、 $MAX$  は誤差  $E$  に対して十分大きな値である。提案手法は次のステップにより実行される。

[Step 1] 第  $q$  層の  $n$  番目のユニットを仮想的に削除した場合の誤差  $E^{(n,q)}$  を計算する。

[Step 2] もし、削減対象の層のすべてのユニットに対し Step 1 の削除と  $E^{(n,q)}$  の計算が終了したら Step 3 へ、それ以外は Step 1 へ戻る。

[Step 3] 削減対象の層のすべてのユニットの中で、 $E^{(n,q)}$  が最小である第  $b$  層の  $a$  番目のユニットを削除する。

[Step 4] ユニットを削除した NF の再学習を行う。

[Step 5] もし、 $E \leq E_P$  なら Step 1 へ戻り、それ以外、すなわち再学習の際に学習回数が  $T_P$  を超えてでも  $E \leq E_P$  とならない場合は Step 6 へ。

[Step 6] ネットワークを 1 つ前の構造に戻す。すなわち、第  $b$  層の  $a$  番目のユニットを削除する前

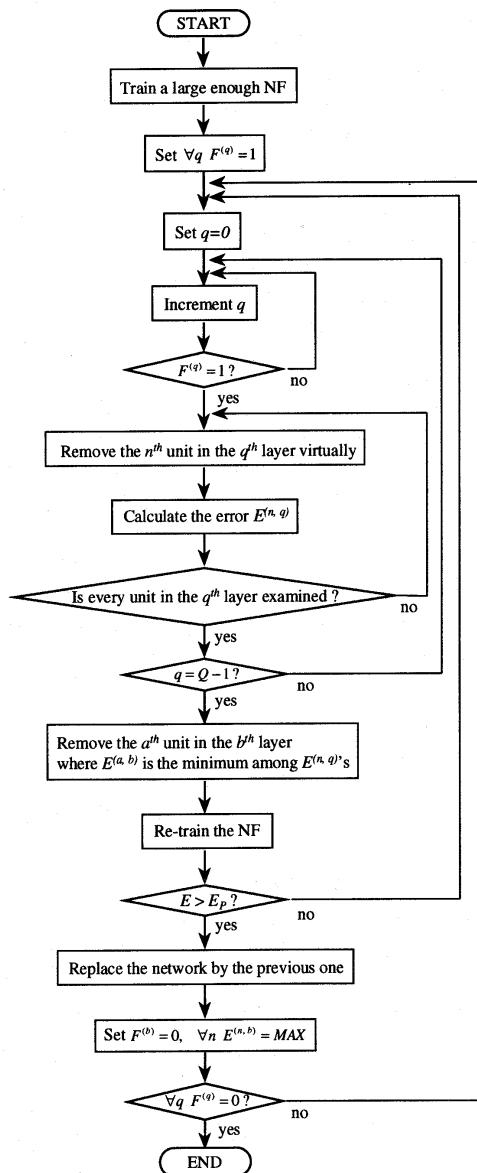


図2 提案手法のフローチャート  
Fig. 2 Flow chart of the proposed method.

のネットワークに戻す。

**[Step 7]** 第b層をユニット削減対象から除外し、このとき、すべての層が削減対象から除外されたら処理を終了し、それ以外はStep 1へ戻る。

なお、仮想的なユニットの削除は、当該ユニットの出力をゼロとするなどして行う。このようにして、階層型NNに直接信号を入力する分類(2)のNFの構造

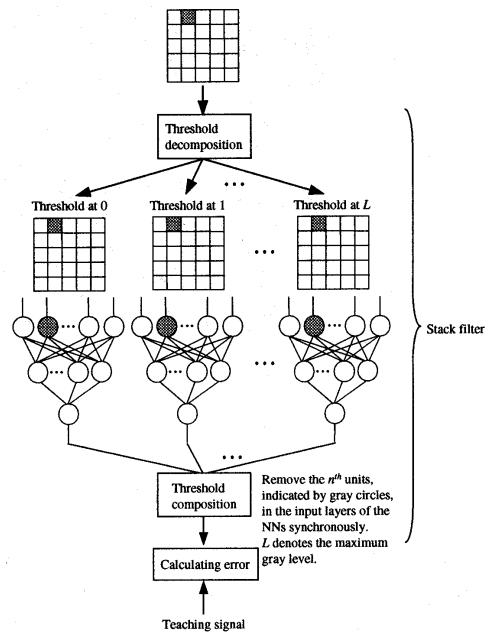


図3 スタックフィルタとして実現されたNFへの適用方法  
Fig. 3 Explanatory figure for a way to apply the proposed method to the NFs realized as the stack filters.

を自動的に決定できる。ここで、しきい値分解の原理に基づくスタックフィルタとして実現された分類(1)のNFへ適用する場合は、入力層ユニットの仮想的削除に次のような変更を加える。図3に示すように、スタックフィルタとして実現され、並列に存在する複数のNNの入力層ユニットについて、ユニットの仮想的削除を同期をとって行う。すなわち、しきい値分解の原理により分解された各画素に対応する、複数の入力層ユニット（各NNの入力層のうちで、ユニット番号が同じユニット）を同時に仮想的に削除し、その際の誤差を計算する。このような変更により、分類(1)のNFへの適用が可能となる。

本手法は、通常のNNの処理である順方向伝播および誤差の計算を利用しているため、本質的に高速性を維持しており、並列性を損なわない。さらに、通常のNNのアーキテクチャに若干の変更を加えるだけで実現でき、容易に既存のハードウェアやソフトウェアに実装可能であるという特徴を持つ。

### 3. 比較評価実験 1

#### 3.1 2次元自然画像の画質改善の学習

2次元自然画像の画質改善問題を学習させたNFを用いて、本手法を評価する。暗視カメラによる画像な

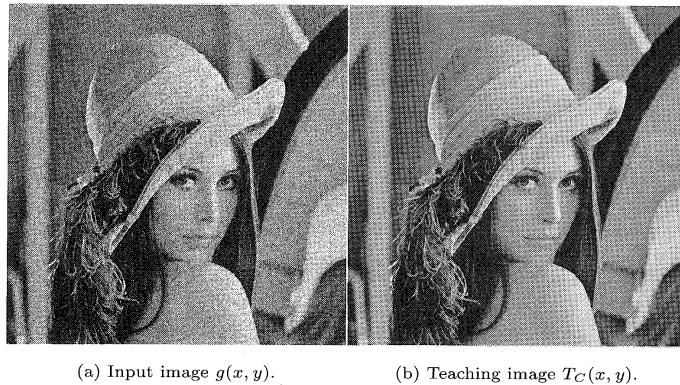


図 4 学習に用いた画像 (Lena)  
Fig. 4 Images for training the NF (Lena).

どの光量の少ない条件で撮像された画像では、量子ノイズが重畠した画像として観測される。画像からの量子ノイズの除去は、画質改善の基本的な課題の1つである。まず、量子ノイズが重畠した画像モデルを説明する。量子ノイズ  $g_N(\sigma)$  は、画像信号成分  $g_S(x, y)$  の大きさにより量の異なる信号依存性ガウスノイズであるため、観測画像  $g(x, y)$  は次式のように表すことができる。

$$g(x, y) = g_S(x, y) + g_N(\sigma) \quad (10)$$

$$\sigma = k_N \sqrt{g_S(x, y)} \quad (11)$$

ただし、 $g_N(\sigma)$  は標準偏差  $\sigma$  の白色ガウスノイズ、 $k_N$  はノイズ混入量に関するパラメータである。このモデルに基づき、対象画像にノイズを加えた画像を、NFへの入力画像として用い、教師画像には対象画像をそのまま用いる。NFは入力画像を教師画像へ近づけるように学習する非線形フィルタであるため、一般的にその空間周波数特性は学習対象に適応した非線形性を有する。この学習では、画像信号が大きいほどノイズの量が多く重畠した画像を入力画像とし、そのノイズがない画像を教師画像として用いるため、画像信号が大きいほどノイズの低減率が高く、しかも画像信号を保存するような特性となる。すなわち、NFはエッジを保存したまま、画像信号の大きさに対し依存性を持つ量子ノイズを除去する機能を獲得する。

NFのフィルタ窓は、ノイズ除去に十分な大きさとして  $11 \times 11$  画素の正方形窓とし、構造は入力層、中間層、出力層の各ユニット数を 121, 50, 1 とする 3 層のものを用いた。対象の自然画像には、標準画像 (Lena,  $512 \times 512$  画素, 256 階調) を用いた。図 4(a) は、標準画像にノイズを加えた入力画像である。なお、 $k_N$  は濃度階調最大値の 5%とした。(b) は、教師画像とし

た標準画像である。画像全体の特徴を効率良く学習するため、学習セットは、画像中の 5,000 点をランダムにサンプリングして作成した。重みおよびオフセットは、小さな範囲の一様乱数により初期化し、学習効率  $\eta$  は 0.00005 として 100,000 回の学習を行ったところ、誤差  $E$  は 1.76% に収束した。なお、学習時間はワークステーション (SUN 製 UltraSPARC-II, 250 MHz) で 60.0 時間を要した。

### 3.2 提案手法の性能の比較評価

NF の構造決定手法の性能は、手法の実行時間、ユニットの削減性能、ユニット削減後の NF のフィルタ性能により評価することができる。これらの観点から、本手法を従来の構造決定手法と比較する。

#### 3.2.1 ユニット削減性能の比較

##### (a) 従来の構造決定手法

1 章で 3 種類に大別した従来手法と本手法を比較するため、各分類から比較対象とする手法を選出する。まず、分類 (1) において、文献 16) 以外の手法では、ユニットの出力値に基づいて評価基準が定義されている。入力層ユニットの出力は、NF へ入力される画像情報そのものであるため、これらの手法では、入力層の構造を正しく決定できないと考えられる。このため、分類 (1) からは、文献 16) の手法を比較対象として選択した。この手法は、ユニットへの伝播誤差が大きいほど収束状態から遠い、悪いユニットとする評価基準により削減を行う手法である。次に、分類 (2) の文献 17)~19) の手法は、ユニット数を変えて学習したときのネットワークの良さを評価する手法であるため、様々なユニットの構成で NF を学習させる必要がある。入力層ユニットはその配置に意味を持つため、ユニットの構成に関する組合せ数は、3 層の NF の場合にお

表1 構造決定手法の性能の比較評価（自然画像の画質改善の学習）  
Table 1 Comparative evaluation of the performance among the proposed method and the conventional methods.

| Group number | Neural filter                          | Execution time [hours] ([%]*) | Structure (Number of units [%]*) | Number of connections $N_C$ ([%]*) | ISNR [dB] |
|--------------|--|-------------------------------|----------------------------------|------------------------------------|-----------|
| —            | Original NF                            | 60.0 (100)                    | 121–50–1 (100)                   | 6100 (100)                         | 7.6       |
| (1)          | NF obtained by the method in 16)       | 202.0 (337)                   | 121–27–1 (87)                    | 3294 (54)                          | 7.5       |
| (2)          | NFs obtained by the methods in 17)~19) | Tremendous                    | —                                | —                                  | —         |
| (3)          | NF obtained by the OBD <sup>20)</sup>  | 59.5 (99)                     | 61–8–1 (41)                      | 496 (8)                            | 7.5       |
| —            | NF obtained by the proposed method     | 50.5 (84)                     | 22–8–1 (18)                      | 184 (3)                            | 7.6       |

\*Numerical value relative to the original NF.

いて次式のオーダーとなる。

$$N_{CON} = O(2^{N^{(1)} \cdot N^{(2)}}) \quad (12)$$

したがって、この手法では、実行時間が問題となると考えられる。最後に、分類(3)からは、性能の良い構造決定手法の1つとしてよく知られているOBD(Optimal Brain Damage)<sup>20)</sup>を代表として選択した。OBDは、各重みが取り除かれたときのネットワークの損傷を、重みに対する誤差関数の2次微分を利用して推定し、損傷の少ない重みから削除することにより構造を決定する手法であり、同じ分類の文献22)においても比較対象として用いられている。以上から、分類(1)からは文献16)、分類(2)の文献17)~19)、分類(3)からは文献20)を代表として選出し、比較評価を行った。

#### (b) 実行時間

本手法および従来手法を学習後のNF(以下、元のNFと記す)に適用した。結果を表1に示す。ここで実行時間とは、ユニット削減および再学習を含む構造決定手法全体に要する時間のことである。比較の基準として、元のNFの学習時間をあわせて示してある。分類(1)の手法では、元のNFの学習時間の3倍以上の実行時間を要するのに対し、OBDおよび本手法では、同程度の実行時間で終了している。分類(2)の手法では、今回のNFの場合、 $O(1.33 \times 10^{38})$ の組合せのNFを学習させる必要があるため、実用的な時間で解を得ることが困難である。したがって、この手法は入力層を含むNFの構造決定には向きであると考えられる。

#### (c) ユニット削減性能

表1に示すように、分類(1)の手法では、中間層ユ

ニットのみしか削減できなかった。この手法では、ユニットへの伝播誤差が大きいユニットから削減を行うが、誤差との関わりが大きい入力層の重要なユニットも伝播誤差が大きくなるため、入力層ユニットを適切に削減できなかったものと思われる。OBDと本手法では、中間層ユニットからともに42ユニットを削減できた。しかし、入力層ユニットでは、本手法の方が多くのユニットを削減できている。OBDでは、誤差関数の2次微分による損傷の推定<sup>20)</sup>により構造を決定しているが、この評価基準はすべてのユニットについて最良の推定となるとは限らないため、本手法よりも入力層ユニットの削減性能が低かったと思われる。ここで、NFの主な演算は、重み結合に関わる積和演算であるため、NFの演算量は次式の重み結合数に比例する。

$$N_C = N^{(2)}(N^{(1)} + 1) \quad (13)$$

各手法により得られたNFの重み結合数を表1に示す。得られたNFの演算量は、分類(1)の手法では、元のNFの54%への削減にとどまっているのに対し、OBDでは8%，本手法にいたっては3%と、演算コストをきわめて小さくできている。

#### (d) 入力層の構造に関する考察

入力層の構造決定結果を図5に示す。小さな正方形はNFの入力層の各ユニットを表している。11×11の小さな正方形が集まつた大きな正方形は、元のNFのフィルタ窓を表している。濃淡はユニットの削減順序を表し、黒から白に向かって削減が行われ、最も白い正方形は削減後に残ったユニットを表している。これは視覚系でいう受容野を表現しており、学習対象に適

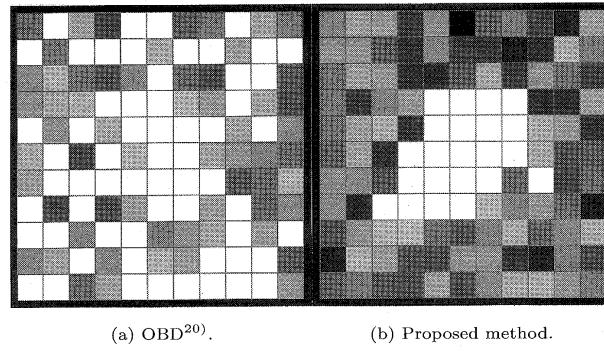


図5 NFの入力層の構造決定結果の比較  
Fig. 5 Receptive fields: the results of determining the structure of input layer of the NF using the proposed method and the conventional method.

応した処理を行うセンサ入力の受容特性ととらえることができる。画像は一般的に注目画素から離れるに従い、注目画素との相関が低くなるため、ノイズ除去などの画像処理を学習した場合、注目画素を中心に受容野が形成されるものと思われる。OBDによる結果では、その傾向が見られないが、本手法では、注目画素を中心に受容野が形成されている。このことから、本手法では、重要な情報が合理的に選択されていることが分かる。本手法による受容野の特性に方向依存性が見られるのは、図4の学習画像が右上がり方向の構造物を主に含む画像であるため、これを反映したものである。様々な種類の画像を学習させれば、それに応じて対称性が高くなると思われる。

### 3.2.2 NFのフィルタ性能の比較評価

#### (a) 学習画像における評価

元のNFを基準に、得られたNFのフィルタ性能を比較評価する。各NFの出力画像を図6に示す。エッジをある程度保存したまま入力画像の量子ノイズが効果的に低減され、教師画像に近づいていることが分かる。いずれの画像も視覚的な違いはほとんど認められない。各画像の画質を定量的に比較評価する。定量評価の指標として、ノイズと空間ぼけによる劣化画像の各種回復処理や各種動画像処理フィルタの性能の比較評価に用いられているISNR (Improvement in Signal-to-Noise Ratio)<sup>27),28)</sup>を採用した。ISNRは入力画像からのSN比の改善度を表す評価指標である。ISNRの定義を次式に示す。

$$\text{ISNR} = 10 \log_{10} \frac{\sum_{x,y \in R_E} \{I_D(x,y) - g(x,y)\}^2}{\sum_{x,y \in R_E} \{I_D(x,y) - f(x,y)\}^2} \quad (14)$$

ただし、 $R_E$ は評価領域であり、 $I_D(x,y)$ は理想画像

である。結果を表1に示す。なお、評価領域  $R_E$  は画像全体とし、入力画像のSN比は 8.9 dB であった。分類(1)の手法およびOBDでは、ユニット削減により、元のNFよりもフィルタ性能がやや落ちているのに対し、本手法では、元のNFと同等の性能を維持していることが分かる。

#### (b) 汎化能力の評価

NFは学習型のフィルタであるため、未学習画像においてフィルタ性能を評価することが重要である。各NFを未学習の標準画像 (512×512画素、256階調) に適用し、汎化能力を評価した。入力画像は、学習に用いた画像と同様に、標準画像にノイズを加えて作成した。入力画像、および元のNFと本手法によるNFの出力画像を図7に示す。なお、各画像は比較を容易にするため、中心付近を切り出して表示してある。本手法によるNFでは、元のNFと同程度のノイズ除去を達成しているのが分かる。ISNRの算出結果を表2に示す。従来手法<sup>16),20)</sup>によるNFを標準画像 Airplane へ適用した場合にのみ、元のNFに比べて ISNR が低下している。これは、従来手法では適切なユニット削減が行われていないため、他の未学習画像と異なる濃度ヒストグラムを持つ Airplane への適用の際に、ISNR が低下したものと考えられる。Airplane では高濃度値(白)の領域が多いのに対し、学習画像 Lena や他の未学習画像では少ない。学習画像において頻度の低い高濃度領域では、重みや構造を決定するためのデータが少ないので、適切な削減が行われない場合、この濃度領域で所望の特性とは異なる特性となりやすい。このようなことから、従来手法では、高濃度領域が多い Airplane での評価が低くなったと考えられる。しかし、提案手法によりユニット削減を行った NF では、Airplane への適用を含め、元の NF に比べて ISNR が

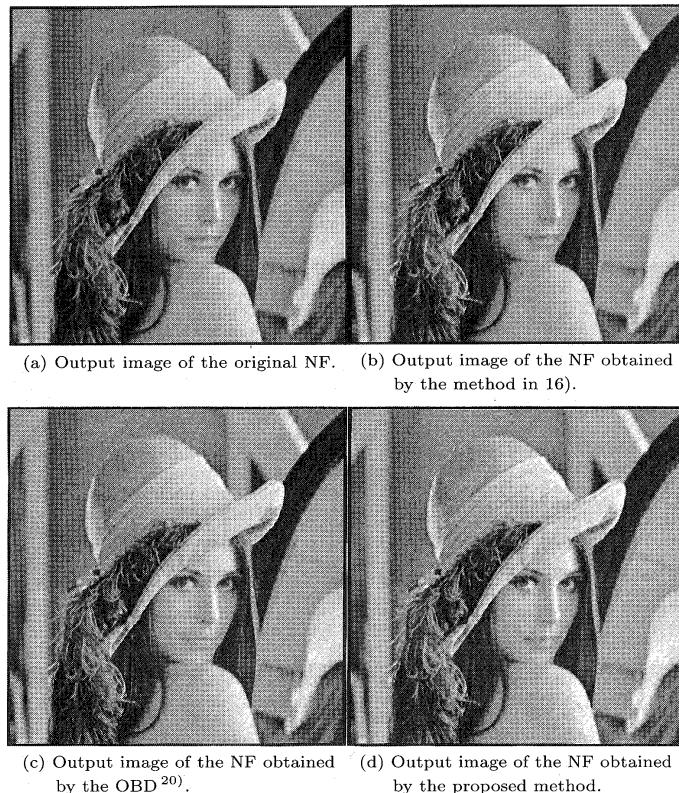


図 6 出力画像の比較

Fig. 6 Comparison among the output images of the NFs obtained by the proposed method and the conventional methods, and the output image of the original NF.

表 2 汎化能力の比較評価

Table 2 Comparative evaluation of the generalization ability among the NFs obtained by the proposed method and the conventional methods.

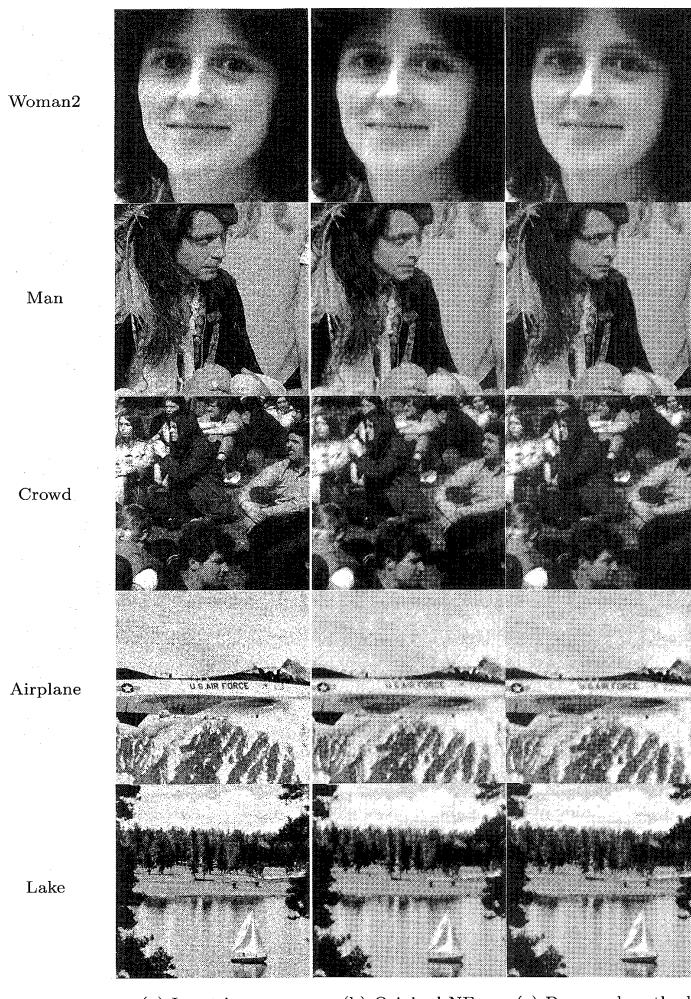
| Object image | ISNR [dB] (SISNR* [dB]) |                                  |                                       |                                    |
|--------------|-------------------------|----------------------------------|---------------------------------------|------------------------------------|
|              | Original NF             | NF obtained by the method in 16) | NF obtained by the OBD <sup>20)</sup> | NF obtained by the proposed method |
| Woman2       | 5.1                     | 6.7 (1.6)                        | 7.6 (2.5)                             | 8.3 (3.2)                          |
| Man          | 3.1                     | 3.7 (0.6)                        | 4.1 (1.0)                             | 4.1 (1.0)                          |
| Crowd        | 1.4                     | 2.2 (0.8)                        | 2.7 (1.3)                             | 3.2 (1.8)                          |
| Airplane     | 6.1                     | 5.8 (-0.3)                       | 5.8 (-0.3)                            | 6.3 (0.2)                          |
| Lake         | 2.3                     | 3.0 (0.7)                        | 3.7 (1.4)                             | 3.9 (1.6)                          |

\*Subtraction of the ISNR for the original NF from that for the NF obtained by each method.

向上している。

また、表 1 に示すように本手法と OBD では、残った中間層ユニットの数は同じであるが、入力層ユニットの削減数は本手法の方が大きい。それにもかかわら

ず、本手法による NF の ISNR は表 2 のいずれの画像においても OBD に劣ることがない。これは、中間層ユニットの削減のみならず、入力層ユニットの適切な削減により汎化能力が向上することを示している。入



(a) Input image. (b) Original NF. (c) Proposed method.

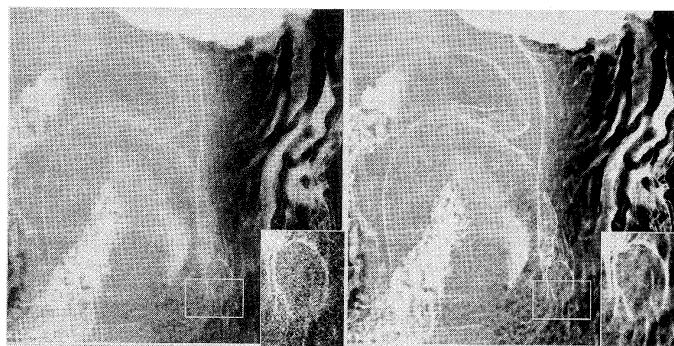
Fig. 7 Comparison of the output image of the NF obtained by the proposed method with that of the original NF (Non-trained images).

力層に冗長なユニットが多く含まれる場合には、中間層の場合と同様に、NFのフィルタ特性に対する自由度が過剰になり、学習用画像に過剰適合しやすくなる。このため、所望のフィルタ特性とは異なる特性となり、汎化能力の低下が起こる。本手法では、入力層ユニットと中間層ユニットが適切に削減され、元のNFおよび従来手法に比べて最も汎化能力の高いNFを構築できていることが分かる。

#### 4. 比較評価実験 2

##### 4.1 医用 X 線動画像の画質改善の学習<sup>9)</sup>

医用 X 線撮影装置では、1024 pixel×1024 pixel×10 bit の画像を 30 frames/sec. で処理する必要があるため、その処理を実現する回路の規模は膨大なものとなる。このため、NF の冗長なユニットの削除はきわめて重要な課題である。そこで、医用 X 線動画像の画質改善を学習させた NF に本手法を適用し、比較評価を行った。動画像を処理するため、NF のフィルタ窓は図 1 に示すように、空間的に 5×5 画素の 25 画素、

(a) Input image  $g(x, y, t_0)$ . (b) Teaching image  $T_C(x, y, t_0)$ .図 8 学習に用いた画像（医用 X 線動画像）  
Fig. 8 Images for training the NF.

時間的にそれを 5 フレーム連ねた 125 画素の時空間情報の立方形入力とし、構造は入力層、中間層、出力層の各ユニット数を 125, 50, 1 とする 3 層のものを用いた。

医用 X 線像の画質改善では、画像信号に重畠しているノイズの除去と、対象物のエッジの鮮鋭度向上により、より対象が見やすく診断しやすい画像を提供することが目標である。X 線像は X 線光子の発生消滅に基づく量子ノイズが支配的であるため、線量を多くして撮影した場合には、ノイズが非常に少ない画像が得られる。このことをを利用して学習用画像を作成する。すなわち、線量を多くして撮影した高線量画像に、式(10)に基づく量子ノイズを加えたものを入力画像とし、この高線量画像にハイパスフィルタを施し、対象物のエッジの鮮鋭度を向上したもの教師画像として用いる。

図 8 は動画像中の、学習に用いた注目フレームである。これらは、日立メディコ社製デジタル X 線撮影装置 DR-2000H により撮影された、蠕動運動とともに胃の二重造影像 ( $1024 \times 1024$  画素、1024 階調) である。ここで、 $k_N$  は実際に撮影した低線量画像のノイズ量と同じ濃度階調最大値の 0.24% とし、ハイパスフィルタは  $1/8$  ナイキスト周波数以上を  $3\text{dB}$  強調するフィルタを用いた。なお、図は原画像の中央部を  $512 \times 512$  サイズに切り出し表示したもので、関心領域である胃壁の細かなひだの部分を約 2 倍に拡大した画像を右下にあわせて表示してある。(a) は高線量画像にノイズを加えた入力画像である。(b) は高線量画像にハイパスフィルタを施し、エッジを強調した教師画像である。処理対象の画像の診断関心領域は胃壁のひだであるため、図中に白枠で示した矩形領域を

学習領域 ( $90 \times 50$  画素) として設定し、80,000 回の学習を行ったところ、誤差  $E$  は 2.37% に収束した。なお、学習時間は 48.8 時間を要した。

#### 4.2 提案手法の性能の比較評価

##### 4.2.1 ユニット削減性能の比較

###### (a) 実行時間

本手法および従来手法を学習後の NF に適用した結果を表 3 に示す。分類(2)の手法を除いて、いずれの手法も元の NF の学習時間の 2 倍程度の実行時間で終了している。

###### (b) ユニット削減性能

表 3 に示すように、本手法が最も多くのユニットを削減できている。得られた NF の演算量は、元の NF の 6% と、演算コストをきわめて小さくできている。

##### 4.2.2 NF のフィルタ性能の比較評価

元の NF と本手法による NF の出力画像を図 9 に示す。いずれも入力画像のノイズが効果的に低減されており、視覚的な違いはほとんど認められない。汎化能力を評価するため、未学習フレームを含む 15 フレームの動画像において、ISNR を算出した結果を図 10 に示す。なお、入力画像の SN 比は  $11.6\text{ dB}$  であった。フレーム番号 15 が学習に用いたフレームである。従来手法による NF では、元の NF より ISNR がやや低下しており、ユニット削減によりフィルタ性能が低下したことを示している。それに比べて本手法による NF では、学習フレーム、未学習フレームとともに元の NF とほぼ同等の ISNR を達成している。ISNR の平均値を表 3 に示す。本手法による NF は、ユニット数を 3 割以下に削減したにもかかわらず、フィルタ性能が低下していないことが分かる。以上より、本手法が NF の構造決定に有効であり、演算量が少なく、性能

表3 構造決定手法の性能の比較評価（医用X線動画像の画質改善の学習）  
Table 3 Comparative evaluation of the performance among the proposed method and the conventional methods.

| Group number | Neural filter                          | Execution time [hours] ([%]*) | Structure (Number of units [%]*) | Number of connections $N_C$ ([%]*) | ISNR [dB] |
|--------------|--|-------------------------------|----------------------------------|------------------------------------|-----------|
| —            | Original NF                            | 48.8 (100)                    | 125-50-1 (100)                   | 6300 (100)                         | 1.6       |
| (1)          | NF obtained by the method in 16)       | 114.5 (235)                   | 124-50-1 (99)                    | 6250 (99)                          | 1.4       |
| (2)          | NFs obtained by the methods in 17)~19) | Tremendous                    | —                                | —                                  | —         |
| (3)          | NF obtained by the OBD <sup>20)</sup>  | 112.5 (231)                   | 58-16-1 (43)                     | 944 (15)                           | 1.5       |
| —            | NF obtained by the proposed method     | 91.5 (188)                    | 40-9-1 (28)                      | 369 (6)                            | 1.6       |

\*Numerical value relative to the original NF.

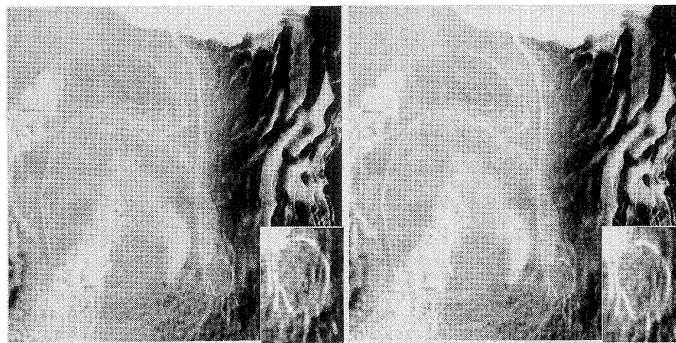


図9 出力画像の比較  
Fig. 9 Comparison of the output image of the NF obtained by the proposed method with that of the original NF.

の高いNFを設計できることが分かった。

## 5. おわりに

本論文では、教師信号と出力との誤差最小化の観点から、NFの入力層ユニットの構成（フィルタ窓の範囲や形状）、および、中間層ユニット数を自動的に決定する手法を提案し、シンプルな手法でありながら有効性が高いことを示した。まず、2次元自然画像の画質改善問題を学習させたNFに本手法を適用し、手法の実行時間、ユニットの削減性能、ユニット削減後のNFのフィルタ性能の観点から、従来手法と定量的に比較評価した。さらに、演算量削減が大きな課題となっている医用X線動画像の画質改善を学習させたNFにおいても比較評価を行った。これらの比較評価実験に

より、本手法は、実行時間が短く、ユニットの削減性能に優れ、入力情報を合理的に選択でき、フィルタ性能の高いNFが得られることを示した。本手法を用いれば、性能を維持したままNFの演算量を効果的に削減でき、演算量が問題となっている動画像処理のためのNFなどの実用化に役立つものと期待できる。

今後、様々なに提案されているNFに適用し、有効性をさらに評価していく予定である。また、本手法は、一般的なNNの入力情報の自動選択や中間層ユニットの削減に応用可能であり、それらについても有効性を評価していく予定である。

謝辞 本研究にご協力いただいた名城大学大学院生原直子さん〔現在（株）トーメー〕、ご支援くださった（株）日立メディコ小野邦男顧問、井原廣一技師長（現

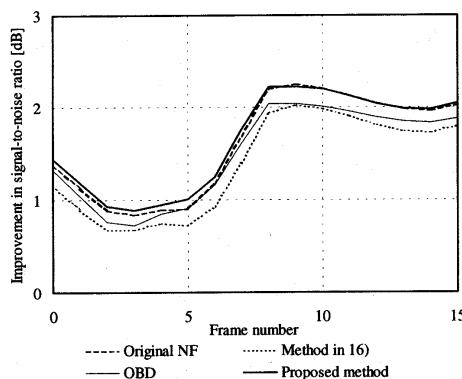


図 10 ISNR を用いた各 NF の性能の比較評価

Fig. 10 Comparative evaluation of the performance among the NFs obtained by the proposed method and the conventional methods in terms of the ISNR.

在国際医療福祉大学), 同社技術研究所矢伸重信所長, 小池功一主管技師長, 石川謙主任技師, 池田重之主任技師, 鈴木克巳技師, 菅野修二企画員, に深く感謝いたします。なお, 本研究の一部は文部省学術フロンティア「量子情報論からの生命への接近」および文部省科学研究費補助金奨励研究(A)(課題番号 10750302)の支援による。

## 参考文献

- 1) Yin, L., Astola, J. and Neuvo, Y.: A new class of nonlinear filters – neural filters, *IEEE Trans. Signal Processing*, Vol.41, No.3, pp.1201–1222 (1993).
- 2) Zhang, Z.Z. and Ansari, N.: Structure and properties of generalized adaptive neural filters for signal enhancement, *IEEE Trans. Neural Networks*, Vol.7, No.4, pp.857–868 (1996).
- 3) Yin, L., Astola, J. and Neuvo, Y.: Adaptive multistage weighted order statistic filters based on the back propagation algorithm, *IEEE Trans. Signal Processing*, Vol.42, pp.419–422 (1994).
- 4) Yin, L., Astola, J. and Neuvo, Y.: Neural filters: a class of filters unifying FIR and median filter, *Proc. ICASSP-92*, pp.53–56, IEEE (1992).
- 5) 荒川 薫, 原島 博: バックプロパゲーションによる階層形ニューラル非線形フィルタの設計, 電子情報通信学会論文誌 (A), Vol.J74-A, No.3, pp.421–429 (1991).
- 6) 荒川 薫, 山川浩二, 小山美津夫: 非線形関数の最適設計を伴なうニューラルネット型フィルタ, 電子情報通信学会論文誌 (A), Vol.J78-A, No.2, pp.151–160 (1995).
- 7) 棟安実治, 前田隆宏, 離元孝夫: 階層型メディアンフィルタと適応窓を用いた2次元ニューラルハイブリッドフィルタ, 電子情報通信学会論文誌 (A), Vol.J78-A, No.12, pp.1558–1565 (1995).
- 8) 田口 亮, 棟安実治, 離元孝夫: メディアンニューラルハイブリッド(MNNH)フィルタの提案, 電子情報通信学会論文誌 (A), Vol.J79-A, No.11, pp.1817–1825 (1996).
- 9) Suzuki, K., Horiba, I., Sugie, N. and Ikeda, S.: Improvement of image quality of X-ray fluoroscopy using spatiotemporal neural filter which learns noise reduction, edge enhancement and motion compensation, *Proc. Int. Conf. on Signal Processing Applications and Technology*, Boston, MA, Vol.2, pp.1382–1386 (1996).
- 10) Funahashi, K.: On the approximate realization of continuous mappings by neural networks, *Neural Networks*, Vol.2, pp.183–192 (1989).
- 11) Barron, A.R.: Universal approximation bounds for superpositions of a sigmoidal function, *IEEE Trans. Information Theory*, Vol.39, No.3, pp.930–945 (1993).
- 12) Sietsma, J. and Dow, R.J.F.: Creating artificial neural networks that generalize, *Neural Networks*, Vol.4, No.1, pp.67–69 (1991).
- 13) 松永 豊, 中出美彰, 山川 修, 村瀬一之: 階層型ニューラルネットワークの中間層素子を自動削減する誤差逆伝搬学習アルゴリズム, 電子情報通信学会論文誌 (D-II), Vol.J74-D-II, No.8, pp.1118–1121 (1991).
- 14) 押野隆弘, 尾島 潤, 山本真司: 誤差逆伝搬学習における中間層ユニットの逐次削減法, 電子情報通信学会論文誌 (D-II), Vol.J76-D-II, No.7, pp.1414–1424 (1993).
- 15) 松永 豊, 村瀬一之, 山川 修, 谷藤 学: 競合作用により冗長中間素子を自律淘汰する誤差逆伝搬学習アルゴリズム, 電子情報通信学会論文誌 (D-II), Vol.J79-D-II, No.3, pp.403–412 (1996).
- 16) 萩原将文: 淘汰機能を有するバックプロパゲーション(学習回数の低減と中間層ユニットの削減法), 電子情報通信学会論文誌 (D-II), Vol.J74-D-II, No.6, pp.812–818 (1991).
- 17) 栗田多喜夫: 情報量基準による3層ニューラルネットの隠れ層のユニット数の決定法, 電子情報通信学会論文誌 (D-II), Vol.J73-D-II, No.11, pp.1872–1878 (1990).
- 18) Fogel, D.B.: An information criterion for optimal neural network selection, *IEEE Trans. Neural Networks*, Vol.2, No.5, pp.490–497 (1991).
- 19) Murata, N., Yoshizawa, S. and Amari, S.: Network information criterion – Determining the

- number of hidden units for an artificial neural network model, *IEEE Trans. Neural Networks*, Vol.5, No.6, pp.865–872 (1994).
- 20) Cun, Y.L., Denker, J.S. and Solla, S.A.: Optimal brain damage, *Advances in Neural Information Processing (2)*, Touretzky, D.S. (Ed.), pp.598–605 (1990).
- 21) Weigend, A.S., Rumelhart, D.E. and Huberman, B.A.: Generalization by weight-elimination applied to currency exchange rate prediction, *Proc. Int. Joint Conf. Neural Networks*, Seattle, USA, Vol.1, pp.837–841 (1991).
- 22) Ishikawa, M.: Structural learning with forgetting, *Neural Networks*, Vol.9, No.3, pp.509–521 (1996).
- 23) 上田智之, 高橋 潔, 森 真作: ファジ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(D-II), Vol.J78-D-II, No.10, pp.1479–1490 (1995).
- 24) Ji, C., Snapp, R.R. and Psaltis, D.: Generalizing smoothness constraints from discrete samples, *Neural Computation*, Vol.2, No.2, pp.188–197 (1990).
- 25) Nowlan, S.J. and Hinton, G.E.: Simplifying neural networks by soft weight-sharing, *Neural Computation*, Vol.4, No.4, pp.473–493 (1992).
- 26) Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: *Learning internal representations by error propagation*, Parallel Distributed Processing, chapter 8, Vol.1, pp.318–362, M.I.T. Press (1986).
- 27) Banham, M.R. and Katsaggelos, A.K.: Digital image restoration, *IEEE Signal Processing Magazine*, Vol.14, No.2, pp.24–41 (1997).
- 28) Brailean, J.C., Kleihorst, R.P., Efstratiadis, S., Katsaggelos, A.K. and Lagendijk, R.L.: Noise reduction filters for dynamic image sequences: A review, *Proc. IEEE*, Vol.83, No.9, pp.1270–1291 (1995).

(平成 11 年 4 月 2 日受付)

(平成 11 年 9 月 2 日採録)



鈴木 賢治 (正会員)

昭和 43 年生。平成 3 年名城大学理工学部電気電子工学科卒業。平成 5 年同大学大学院工学研究科修士課程修了。同年(株)日立メディコ入社。平成 9 年愛知県立大学。現在、情報科学部助手。医用画像処理・認識および学習型情報処理の研究に従事。電子情報通信学会、電気学会、日本神経回路学会、日本循環器学会、IEEE 各会員。



堀場 勇夫 (正会員)

昭和 23 年生。昭和 49 年名古屋大学工学部電気工学科卒業。同年(株)日立メディコ入社。昭和 62 年名城大学理工学部電気電子工学科講師。平成 3 年同助教授。平成 10 年愛知県立大学情報科学部教授、現在に至る。生体情報の計測、医用画像処理、および交通系における画像処理応用に関する研究に従事。工学博士。電子情報通信学会、日本 ME 学会、日本放射線技術学会、日本超音波医学会、日本医用画像工学会、日本循環器学会等各会員。



杉江 翼 (正会員)

昭和 7 年生。昭和 32 年名古屋大学工学部電気工学科卒業。同年通商産業省電子技術総合研究所入所。昭和 37~39 年カナダ・マギル大学客員研究員。昭和 45 年バイオニクス研究室長。昭和 53 年視覚情報研究室長。昭和 54 年名古屋大学大学院工学研究科情報工学専攻教授。昭和 60 年同大学工学部電気工学第二学科教授。平成 2 年同大学工学部情報工学科教授。平成 6 年名城大学理工学部電気電子工学科教授。現在に至る。バイオニクス、医用工学、コンピュータビジョン、自然言語処理等の研究・教育に従事。工学博士。電子情報通信学会、計測自動制御学会、ロボット学会、エム・イー学会、映像情報メディア学会、日本神経回路学会、IEEE 各会員。