

ディープフィードバック型 GMDH-type ニューラルネットワークと CNN を用いた X 線 CT 画像の医用画像解析

Medical image analysis of X-ray CT images using deep feedback GMDH-type neural network and convolutional neural network

近藤 正^{1*}
Tadashi Kondo

高尾 正一郎¹
Shoichiro Takao

近藤 明佳²
Sayaka Kondo

上野 淳二¹
Junji Ueno

¹ 徳島大学

¹ Tokushima University

² 徳島医用情報科学研究会

² Tokushima medical informatics laboratory

In this study, the hybrid deep neural network which is constructed with the deep feedback Group Method of Data Handling (GMDH)-type neural network and the Convolutional Neural Network (CNN), is proposed and this hybrid neural network is applied to the medical image analysis of X-ray CT images. The feedback GMDH-type neural network can organize the deep neural network architectures so as to minimize prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS) by using the revised heuristic self-organization method. In the convolutional neural network, many image features are automatically generated using the convolutional calculations and the pooling calculations, and these generated image features are used as the input variables of the deep feedback GMDH-type neural network. The deep feedback GMDH-type neural network algorithms can automatically select the structural parameters such as the number of hidden layers, the optimum neuron architectures and useful input variables. This hybrid neural network algorithm is applied to medical image analysis of abdominal X-ray CT images, and the organs such as liver, spleen, stomach and bone, are recognized and these image regions are extracted using the deep feedback GMDH-type neural networks.

1. はじめに

ディープ GMDH-type ニューラルネットワークのアルゴリズムは、著者らのグループにより、多層構造型アルゴリズム、フィードバック型アルゴリズム、ロジスティック型アルゴリズムなどの各種のアルゴリズムが提案されており[1-6]、これらのアルゴリズムは、いろいろな臓器の医用画像認識問題や、肝臓がんや肺がんの医用画像診断に応用されている[4,5]。ディープ GMDH-type ニューラルネットワークは、多層構造をしたディープニューラルネットワークを自動的に構成することができる。そして、進化論的計算法の一種である改良形発見的自己組織化法[3-8]を用いて、入力変数のすべての組み合わせを発生させて、各々の組み合わせが出力変数の予測に有効かどうかを統計的に解析し、有力な変数の組み合わせのみを用いて複雑な構造をしたディープニューラルネットワーク構造を自動的に構成する。予測誤差の評価には、情報量基準 AIC[9]や予測誤差平方和(PSS)[10]などの予測誤差評価基準を用いている。このため、従来のニューラルネットワークのように人間が手動で、ネットワーク構造のパラメータ(中間層の層数、各層のニューロン数、有力な入力変数の選択、BP 法などの結合加重値の初期値、学習係数など)を変化させて、最適なディープニューラルネットワーク構造を見つけ出す場合と比較して、非常に多くのディープニューラルネットワーク構造の中から、効率よく予測精度が良いディープニューラルネットワーク構造を見つけ出すことができる。さらに、最適なニューロンの構造は、シグモイド関数、放射基底関数(Radial Basis Function (RBF)、線形多項式、非線形多項式などのニューロンの活性化関数の中から、予測誤差を最小にする活性化関数を自己選択できる。

本研究では、ディープフィードバック型 GMDH-type ニューラルネットワークとコンボリュショナルニューラルネットワーク(CNN)を用いたハイブリッド型ニューラルネットワークを用いて、X 線 CT 画像の医用画像解析を行う。医用画像からコンボリュショナルニューラルネットワークを用いて画像特徴量を発生させ、これらの画像特徴量に、従来から用いられている画像特徴量や位置情報などを加えて、ディープフィードバック型 GMDH-type ニューラルネットワークの入力変数とする。ディープフィードバック型 GMDH-type ニューラルネットワークでは、すべての入力変数に対して、これらの入力変数の高次の項を含めた非線形な組み合わせを発生させて統計解析することにより、有力な変数の組み合わせのみを自己選択し、複雑な構造をした非線形システムの特徴に最も適するようにディープニューラルネットワーク構造を自動的に自己組織化する。本研究では、ハイブリッド型ディープニューラルネットワークを X 線 CT 画像の医用画像解析に応用する。医用画像としては腹部 CT 画像を用いて、肝臓、胃、脾臓、骨などの領域を画像認識させて領域抽出する。そして、各臓器ごとに自己組織化されたディープフィードバック型 GMDH-type ニューラルネットワークについて比較検討する。

2. 改良形発見的自己組織化法[3-5]

改良形発見的自己組織化法[3-5]について述べる。改良形発見的自己組織化の原理では、次に示す 7 つのステップにより多層構造をしたディープニューラルネットワーク構造を構成する。

1) 原データのトレーニングデータとテストデータへの分割

トレーニングデータはニューロンの活性化関数のパラメータの推定に用い、テストデータはディープニューラルネットワークの構造選択に用いる。

2) 入力変数の組み合わせの発生

すべての入力変数の組み合わせを発生させる。

*連絡先: 徳島大学医学部保健学科
Email: kondomedsci@gmail.com

3)最適なニューロン構造の発生

各々の組み合わせに対して、トレーニングデータを用いて回帰分析を行い、最適なニューロン構造を発生させる。発生したニューロンの出力を中間変数と呼ぶ。

4)中間変数の自己選択

テストデータに対する誤差(テストエラー)を小さくする L 個の中間変数を自己選択する。

5)総合特性変数の発生

自己選択した L 個の中間変数を用いて、トレーニングデータにより回帰分析を行うことにより、総合特性変数を発生させる。

6)多層構造の構成。

自己選択した L 個の中間変数と総合特性変数を次層の入力変数にセットして、入力変数のすべての組み合わせを発生させて繰り返し計算を行い、多層構造を構成していく。

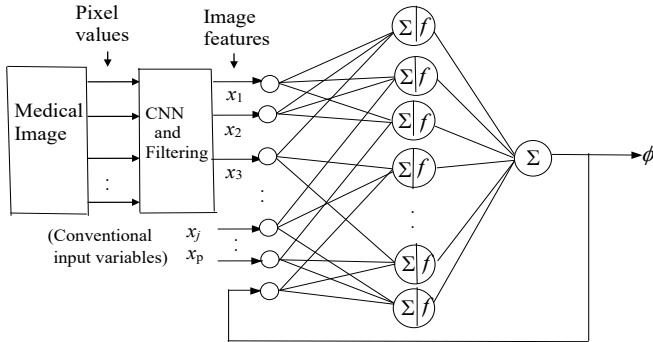
7)多層構造の繰り返し計算の停止

この繰り返し計算は、テストエラーが減少しなくなった層で停止する。そして、ディープニューラルネットワーク構造は、各層で自己選択したニューロンを用いて構成する。

以上の手続きにより構成される発見的自己組織化法は基本的な概念が進化論的計算法と同じである。

3. ディープフィードバック型 GMDH-type ニューラルネットワークスと CNN を用いたハイブリッド型ディープニューラルネットワーク

ディープフィードバック型 GMDH-type ニューラルネットワークとコンボリュショナルニューラルネットワークを用いたハイブリッド型ディープニューラルネットワークの構造を、Fig.1 に示す。



Optimum activation function is automatically selected from Sigmoid function, Radial basis function and Polynomial

Fig.1 Hybrid deep neural network architecture of deep feedback GMDH-type neural network and convolutional neural network (CNN)

このニューラルネットワークでは、CNN とフィルターリングによって画像特徴量を発生させる。さらに、従来から医用画像に用いられている画像特徴量や位置情報などと合わせてディープフィードバック型 GMDH-type ニューラルネットワークの入力変数にする。ディープフィードバック型 GMDH-type ニューラルネットワークでは、これらの入力変数のすべての組み合わせを発生させて、有益な変数の組み合わせのみを自己選択する。自己選択した変数の組み合わせを用いてディープニューラルネットワーク構造を自己組織化する。

3.1 CNN とフィルターリング

本研究では、学習に用いる大量の画像データをまだ準備できないために、CNN での学習は行わずに、CNN のフィルターの値としてはあらかじめ既存のものを準備する。そして、フィルターとしてはガウシアンフィルターとラプラシアンフィルタを用いてコンボリューション層で計算を行い画像特徴量を発生させる。次

に、プーリング層では、最大値、最小値、範囲などのフィルターリングを行い、画像特徴量の抽出を行う。

3.2 ディープフィードバック型 GMDH-type ニューラルネットワーク

このニューラルネットワークスはフィードバックループを備えており、このフィードバックループを用いた計算により、徐々にネットワークの複雑さを増加させる。フィードバックループの計算回数、中間層におけるニューロンの個数、有力な入力変数、最適なニューロンの構造は、予測誤差評価基準(AIC または PSS)を最小にするように決定する。

本アルゴリズムの概要を以下に示す。本研究では、原データを全てトレーニングデータとして用いる。そして、予測誤差評価基準(AIC または PSS)をテストデータの代わりに用いる。

[1] 最初のフィードバックループ計算

(1) 入力層

$$u_j = x_j \quad (j=1,2,\dots,p) \quad (1)$$

ここで、 x_j はシステムの入力変数を示す。

(2) 中間層

入力変数どうしを組み合わせ、すべての組み合わせを発生させる。各々の変数の組み合わせでは、シグモイド関数型、放射基底関数型、多項式型の3種類のニューロン構造を発生させる。さらに、各々のニューロン構造では、非線形結合の1型と線形結合の2型の2種類のニューロンを用いる。これら、6種類のニューロン構造から、対象となる非線形システムの特徴に最も適したニューロン構造を、予測誤差が最小になるように自己選択する。

1) シグモイド関数型ニューラルネットワークス

i) 1型ニューロン構造

Σ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_1 \quad (2)$$

or

$$z_k = w_1 u_i + w_2 u_j + w_3 u_k + w_4 u_i u_j + w_5 u_i u_k + w_6 u_j u_k + w_7 u_i^2 + w_8 u_j^2 + w_9 u_j^2 - w_0 \theta_1 \quad (3)$$

f : (Nonlinear function)

$$y_k = 1 / (1 + \exp(-z_k)) \quad (4)$$

ii) 2型ニューロン構造

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_1 \quad (r < p) \quad (5)$$

f : (Nonlinear function)

$$y_k = 1 / (1 + \exp(-z_k)) \quad (6)$$

2) 放射基底関数(RBF)型ニューラルネットワークス

i) 1型ニューロン構造

Σ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_1 \quad (7)$$

or

$$z_k = w_1 u_i + w_2 u_j + w_3 u_k + w_4 u_i u_j + w_5 u_i u_k + w_6 u_j u_k + w_7 u_i^2 + w_8 u_j^2 + w_9 u_j^2 - w_0 \theta_1 \quad (8)$$

f : (Nonlinear function)

$$y_k = \exp(-z_k^2) \quad (9)$$

ii) 2型ニューロン構造

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_1 \quad (r < p) \quad (10)$$

f : (Nonlinear function)

$$y_k = \exp(-z_k^2) \quad (11)$$

3) 多項式型ニューラルネットワークス

i) 1型ニューロン構造

Σ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_1 \quad (12)$$

or

$$z_k = w_1 u_i + w_2 u_j + w_3 u_k + w_4 u_l + w_5 u_m + w_6 u_n + w_7 u^2 + w_8 u^2 + w_9 u_j^2 - w_0 \theta_l \quad (13)$$

f : (Linear function)

$$y_k = z_k \quad (14)$$

ii) 2 型ニューロン構造

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_l \quad (r < p) \quad (15)$$

f : (Linear function)

$$y_k = z_k \quad (z_k > 0 \text{ の場合})$$

$$y_k = 0 \quad (z_k < 0 \text{ の場合}) \quad (16)$$

ここで、各々のニューロンは Σ と f の 2 個の関数から構成され、 w はニューロンの重み係数、 p は入力変数の個数を示す。

ディープフィードバック型 GMDH-type ニューラルネットワークスは、上記の 6 種類の活性化関数の中から、対象とする非線形システムの特徴に最も適した活性化関数を、AIC または PSS を用いて自己選択する能力がある。

次に、ニューロンの重み w の値は、主成分回帰分析[11]を用いて推定する。

4) 重み w の推定

まず、各々のニューロンに対して z_k^{**} の値を計算する。

i) シグモイド関数型ニューロン

$$z_k^{**} = \log_e(\phi' / (1 - \phi')) \quad (17)$$

ii) RBF 型ニューロン

$$z_k^{**} = (-\log_e \phi')^{1/2} \quad (18)$$

iii) 多項式型ニューロン

$$z_k^{**} = \phi \quad (19)$$

ここで、 ϕ はシステムの入力変数、 ϕ' は 0 から 1 の間の値に正規化された出力変数を示す。重み w は z_k^{**} を出力変数にして主成分回帰分析[11]を用いて推定する。主成分回帰分析を用いることにより、層を通過すると発生していた中間変数間の多重共線性を防止することができ、高精度な学習計算を実行することができる。

次に、各々の組み合わせに対して、シグモイド関数型ニューロン、RBF 型ニューロン、多項式型ニューロンの 3 種類のニューロンを発生して、発生した 3 種類の各々のニューロンに対して、AIC 値又は PSS 値の小さいものを L 個選択する。

(3) 出力層

出力層では、シグモイド関数型、RBF 型、多項式型ニューラルネットワークの 3 種類のニューラルネットワークに対して、つぎの線形結合式を用いて総合特性変数 (ϕ^*) を計算する。

$$\phi^* = a_0 + \sum_{k=1}^L a_k y_k \quad (20)$$

ここで、 L は中間変数の個数、 y_k は中間変数を示す。 y_k は AIC 又は PSS を用いた変数選択型重回帰分析法により、AIC 又は PSS 値の小さいものを自己選択する。次に、(20) 式の AIC 又は PSS 値が小さなニューロン構造を 3 種類の構造の中から、ディープフィードバック型 GMDH-type ニューラルネットワークの構造として自己選択する。2 番目以降のフィードバック計算では、自己選択したニューロン構造のみを用いてニューラルネットワークの計算を行う。次に、総合特性変数 (ϕ^*) を次のフィードバック計算の入力変数にセットして、次のフィードバック計算に移る。

[2] 2 番目以後のフィードバックループ計算

2 番目以後のフィードバックループ計算では、総合特性変数 (ϕ^*) をシステムの入力変数 x_j ($j=1, 2, \dots, p$) と組み合

せる。そして、全ての組み合わせを発生させて、第 1 番目のフィードバックループ計算と同じ手続きを繰り返す。

(20) 式の AIC 又は PSS 値が減少しなくなった層で、フィードバックループ計算を停止し、全体のニューラルネットワークスを構成する。

以上の手続きによりフィードバックループを持つディープフィードバック型 GMDH-type ニューラルネットワークスを構成できる。

4. X 線 CT 画像の医用画像解析への応用

本研究では、ディープフィードバック型 GMDH-type ニューラルネットワークスを用いて、腹部臓器の医用画像認識とその領域抽出を行った。本研究では、医用画像として腹部 X 線 CT 画像を用いた。対象とする臓器は、肝臓、脾臓、胃、骨などである。なお、本研究では予測誤差の評価基準として PSS を用いた。

4.1 肝臓領域の医用画像認識と領域抽出

Fig.2 に、ニューラルネットワークスの学習に用いた原画像を示す。ニューラルネットワークスの入力変数としては $N \times N$ 近傍領域の画像特徴量を用いた。学習に用いた近傍領域の個数は 280 点である。ニューラルネットワークスの出力変数は、0 か 1 の値をとり、肝臓の領域内部では 1 の値を出力するように学習させた。近傍領域の大きさ N は、2 から 10 の値に対してニューラルネットワークスを自己組織化した。その結果、 N が 5 の場合に、最も良い画像認識精度を得た。Fig.3 に、最初のフィードバックループ計算で計算された 3 種類のニューラルネットワークの予測誤差 (PSS 値) を示す。ディープ GMDH-type ニューラルネットワークスは、ニューラルネットワーク構造としてシグモイド関数型ネットワーク構造を選択した。Fig.4 に、各層における PSS 値の変化を示す。ディープ GMDH-type ニューラルネットワークスの計算は 9 回目のフィードバック計算で終了した。フィードバック計算を行うことにより PSS 値は徐々に減少して最終のフィードバック計算では予測誤差が小さな値に収束した。そして、各々の中間層では 5 個のニューロンが自己選択された。次に、有力な入力変数の自己選択については以下のような結果になった。まず、CNN において、ガウシアンフィルタ、ラプラシアンフィルタ、最大値フィルタ、最小値フィルタ、レンジフィルタにより 5 個の画像特徴量を発生し、これらの画像特徴量と、従来から用いられている統計学的特徴量 (平均値、分散、標準偏差)、及び位置情報 (x と y 座標) の合計 10 個の変数をディープ GMDH-type ニューラルネットワークスの入力変数として用いた。これらの入力変数の中から、最初のフィードバック計算及び 2 回目のフィードバック計算で選択された有力な入力変数として、平均値、標準偏差、分散、 x 座標、 y 座標、範囲 (レンジ)、最大値フィルタの出力値の 7 個の入力変数がニューラルネットワークスにより有力な入力変数として自己選択された。

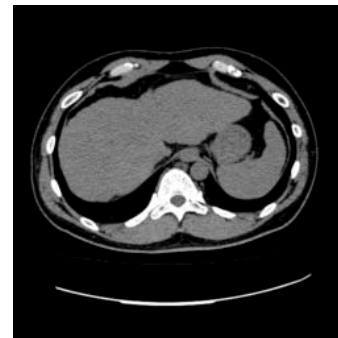


Fig.2 Original image

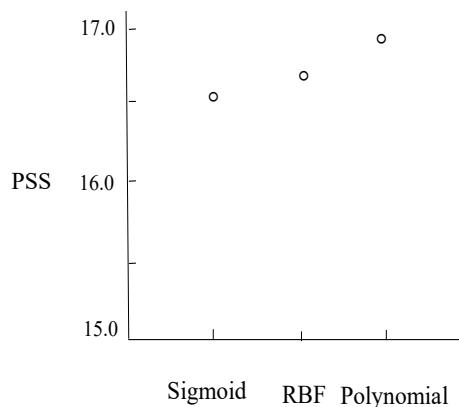


Fig.3 PSS values of three types of neuron (1)

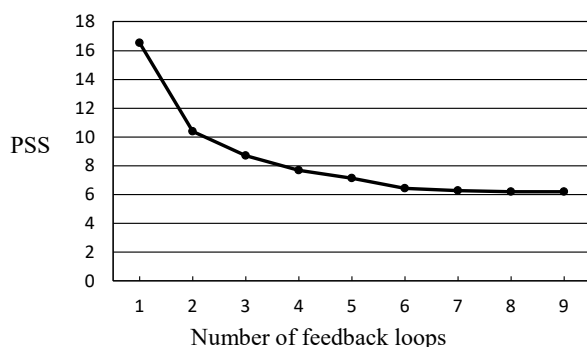


Fig.4 Variation of PSS in the deep GMDH-type of NN(1)

自己組織化されたディープフィードバック型 GMDH-type ニューラルネットワークによって肝臓領域を出力する。Fig.5 に、ニューラルネットワークの出力画像を示す。肝臓の外部の領域(孤立点)が少ないことがわかる。次に、出力画像に対して画像の後処理が行われた。ニューラルネットワークの出力画像に対する後処理では、まず、肝臓領域の輪郭を $N/2$ 画素分だけ外側に拡張した。次に、画像の膨張処理と収縮処理を行い、肝臓領域の内部に孤立した部分がある場合や、肝臓領域の外部にある孤立点が除去された。Fig.6 に、ニューラルネットワークの出力画像に後処理を行った画像を示す。原画像との一致性を確認するために、原画像との重ね合わせを行った。Fig.7 に原画像と後処理後の出力画像を重ね合わせ画像を示す。この画像から、ニューラルネットワークによって画像認識された肝臓領域は、原画像の肝臓領域によく一致していることがわかる。そして、肝臓領域を、原画像(Fig.2)から後処理後の画像(Fig.6)を差分することにより抽出した。Fig.8 に差分画像(グレイ画像)を示す。

次に、誤差逆伝播法(BP 法)を用いて学習する、従来からよく用いられている 3 層構造のシグモイド関数型ニューラルネットワークを用いて肝臓領域の画像認識と領域抽出を行った。学習データは、ディープ GMDH-type ニューラルネットワークと同じものを用い、各々の学習データを 100,000 回学習させた。結合加重の初期値は乱数により設定した。そして、中間層のニューロン数(m)を変化させて画像認識を行った。Fig.9 に、 $m=5$ 、 $m=7$ と $m=9$ の場合の出力画像を示す。これらのニューラルネットワークの出力画像には、孤立点や肝臓領域でない領域を多く含んでおり、画像認識精度が十分でないことがわかる。また、中間層のニューロン数(m)を変化させた場合に、異なった出力画像が得られた。



Fig.5 Output image of the neural network(1)



Fig.6 Output image after the post-processing(1)

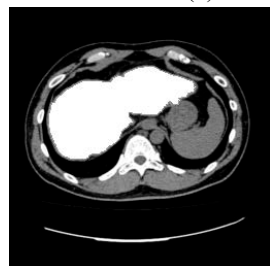


Fig.7 Overlapped image(1)

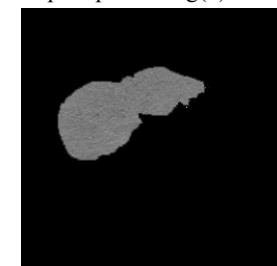
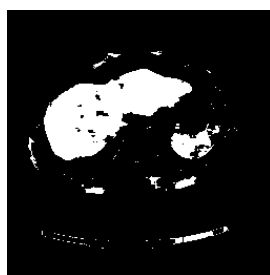
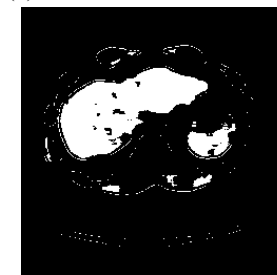


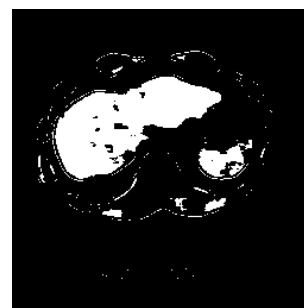
Fig.8 Extracted gray scale image (1)



(a) $m=5$



(b) $m=7$



(c) $m=9$

Fig.9 Output images of the conventional sigmoid function neural network (1)

4.2. 脾臓領域の医用画像認識と領域抽出

脾臓領域の抽出を目的にした新しいニューラルネットワークを自己組織化した。ニューラルネットワークの入力変数としては 4.1 のニューラルネットワークと同じ 10 個の入力変数を用いた。ニューラルネットワークの出力変数は、0 か 1 の値を取り、脾臓の内部では 1 の値を出力するように学習させた。近傍領域の大きさ N は、2 から 10 の値に対してニューラルネットワークを自己組織化した。その結果、 N が 5 の場合に、最も良い画像認識精度を得た。Fig.10 に、最初のフィードバックループ計算で計算された 3 種類のニューロンの予測誤差(PSS 値)を示す。ディープ GMDH-type ニューラルネットワークは、ニューラルネットワーク構造としてシグモイド関数型ネットワーク構造を選択した。Fig.11 に、各フィードバック計算における PSS 値の変化を

Fig.12 にニューラルネットワークの出力画像を示す。次に、この出力画像に対して画像の後処理を行った。ニューラルネットの出力画像に対する後処理では、まず脾臓領域の輪郭を $N/2$ 画素分だけ外側に拡張した。次に、画像の膨張処理と収縮処理を行い、脾臓領域の内部に孤立した部分がある場合や、脾臓領域の外部にある孤立点が除去された。Fig.13 に、ニューラルネットワークスの出力画像に後処理を行った画像を示す。原画像との一致性を確認するために、原画像との重ね合わせを行った。Fig. 14 に原画像と後処理後の出力画像を重ね合わせ画像を示す。この画像から、ニューラルネットワークスによって画像認識された脾臓領域は、原画像の脾臓領域によく一致していることがわかる。そして、原画像から差分を行うことにより脾臓領域のグレイ画像が抽出された。Fig.15 に、脾臓領域のグレイ画像を示す。Fig.16 に BP 法を用いて学習する 3 層構造のシグモイド関数型ニューラルネットワークによって得られた画像認識結果を示す。学習方法は 4.1 の肝臓領域の場合と同じである。

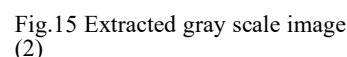
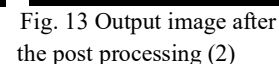
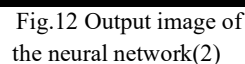
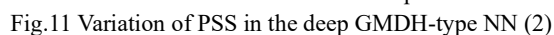
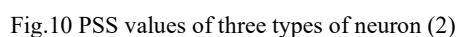


Fig.16 Output images of the conventional sigmoid function neural network (2)

4.3. 胃領域の医用画像認識と領域抽出

09-05

Fig.18 に、PSS 値の変化を示す。ディープ GMDH-type ニューラルネットワークの計算は 9 回目のフィードバック計算で終了した。フィードバック計算により PSS 値は徐々に減少して予測誤差が非常に小さな値に収束した。そして、各々の中間層では 5 個のニューロンが自己選択された。次に、有力な入力変数の自己選択についてであるが、平均値、X 座標、Y 座標、分散、標準偏差の 5 個の入力変数が自己選択された。

Fig.19 にニューラルネットワークの出力画像を示す。次に、この出力画像に対して画像の後処理を行った。ニューラルネットワークの出力画像に対する後処理では、まず胃領域の輪郭を $N/2$ 画素分だけ外側に拡張した。次に、画像の収縮処理と膨張処理を行い、胃領域の外部にある孤立点が除去された。Fig.20 に、ニューラルネットワークの出力画像に後処理を行った画像を示す。原画像との一致性を確認するために、原画像との重ね合わせを行った。Fig.21 に原画像と後処理後の出力画像を重ね合わせ画像を示す。この画像から、ニューラルネットワークによって画像認識された胃領域は、原画像の胃領域によく一致していることがわかる。そして、原画像から差分を行うことにより胃領域のグレイ画像が抽出された。Fig.22 に、胃領域のグレイ画像を示す。Fig.23 に、BP 法を用いて学習する 3 層構造のシグモイド関数型ニューラルネットワークによって得られた画像認識結果を示す。学習方法は 4.1 の肝臓領域の場合と同じである。

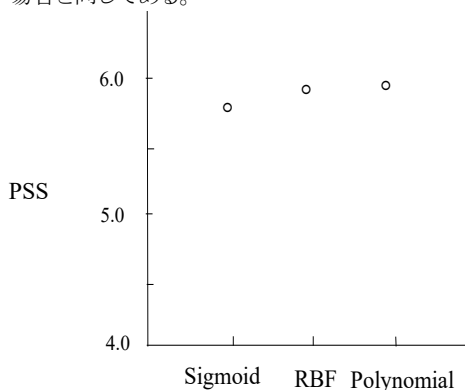


Fig.17 PSS values of three types of neuron(3)

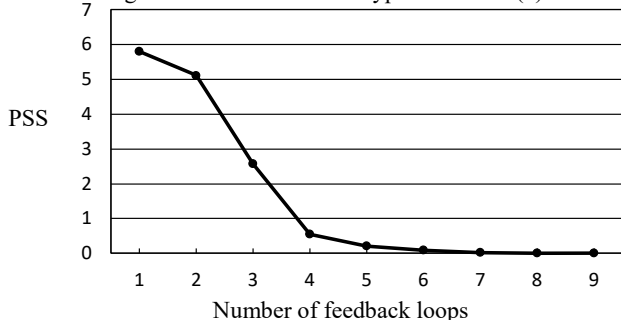


Fig.18 Variation of PSS in the deep GMDH-type NN(3)

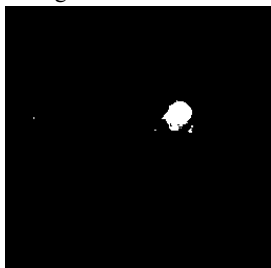


Fig.19 Output image of the neural network (3)

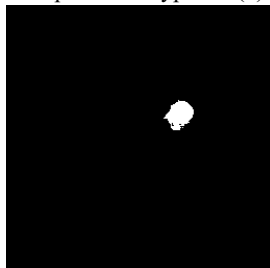


Fig.20 Output image after the post processing (3)

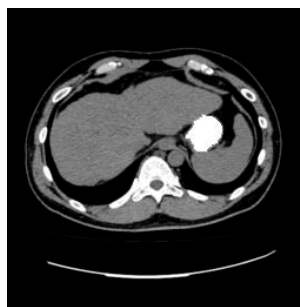


Fig.21 Overlapped image(3)

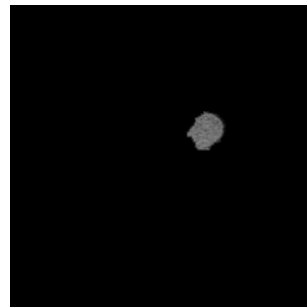
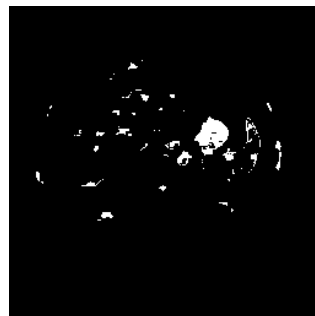
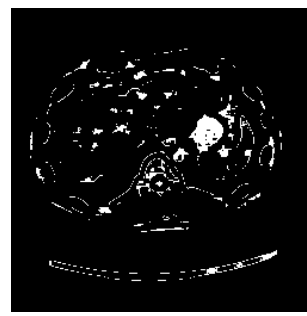


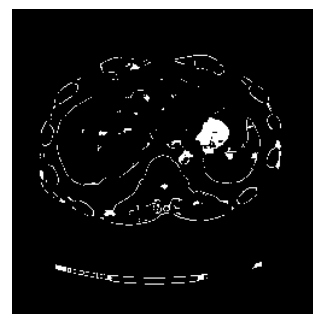
Fig.22 Extracted gray scale image (3)



(a) $m=5$



(b) $m=7$



(c) $m=9$

Fig.23 Output images of the conventional sigmoid function neural network (3)

4.4 骨領域の医用画像認識と領域抽出

骨領域の抽出を目的とした新しいニューラルネットワークを自己組織化した。ニューラルネットワークの入力変数としては 4.1 のニューラルネットワークと同じ 10 個の入力変数を用いた。ニューラルネットワークの出力変数は、0 か 1 の値をとり、骨領域では 1 の値を出力するように学習させた。近傍領域の大きさ N は、2 から 10 の値に対してニューラルネットワークを自己組織化した。その結果、 N が 5 の場合に、最も良い画像認識精度を得た。Fig.24 に、最初のフィードバック計算で計算された 3 種類のニューラルネットワークの予測誤差 (PSS 値) を示す。ディープ GMDH-type ニューラルネットワークは、ニューラルネットワーク構造としてシグモイド関数型ネットワーク構造を選択した。Fig.25 に、PSS 値の変化を示す。ディープ GMDH-type ニューラルネットワークの計算は 5 回目のフィードバック計算で終了した。フィードバック計算を行うことにより PSS 値は徐々に減少して予測誤差が非常に小さな値に収束した。そして、各々の中間層では 5 個のニューロンが自己選択された。次に、有力な入力変数の自己選択についてであるが、平均値、分散、標準偏差、Y 座標、ガウシアンフィルタの出力値、ラプラシアンフィルタの出力値、最大値フィルタの出力値の 7 個の入力変数が自己選択

された。

Fig.26 にニューラルネットワークの出力画像を示す。骨領域の場合は、ニューラルネットワークの出力画像にノイズがほとんどなく鮮明なので、膨張処理、収縮処理などの後処理を省略した。精度は、原画像の骨領域によく一致していた。次に、Fig.27 に BP 法を用いて学習する 3 層構造のシグモイド関数型ニューラルネットワークによって得られた画像認識結果を示す。学習方法は 4.1 の肝臓領域の場合と同じである。

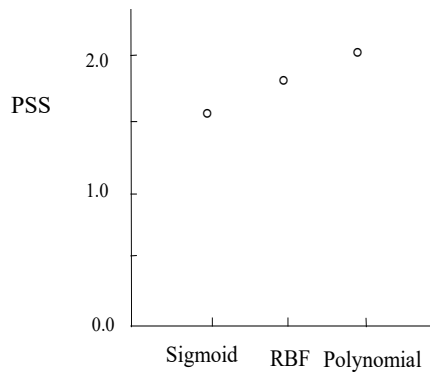


Fig.24 PSS values of three types of neuron(4)

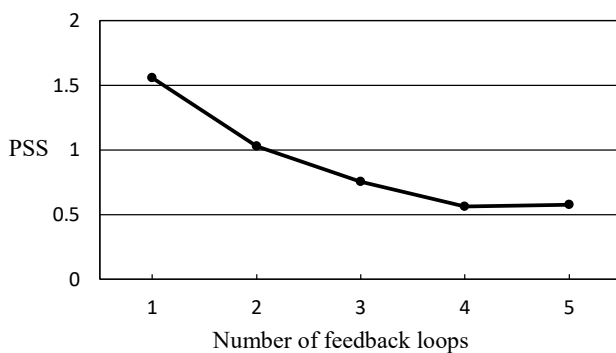
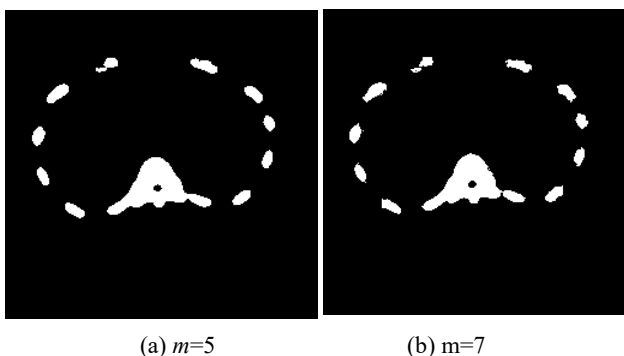


Fig.25 Variation of PSS in the deep GMDH-type NN(4)



Fig.26 Output image of the neural network (4)



(c) $m=9$

Fig.27 Output images of the conventional sigmoid function neural network (4)

4.5 考察

本研究では、肝臓、脾臓、胃、骨の各々の領域を画像認識して領域抽出する 4 個のディープニューラルネットワークを自己組織化した。まず、画像認識結果 (Fig.4, Fig.11, Fig.18, Fig.25) から、予測誤差評価基準値 (PSS) は、フィードバック計算を行うごとに徐々に減少していき、最終のフィードバック計算では PSS 値が小さな値に収束した。最初のフィードバック計算の PSS 値と比較すると、最終のフィードバック計算では PSS 値が大幅に減少した。次に、Table1 に、各々のディープニューラルネットワークの、フィードバックループ計算の計算回数とニューラルネットワークの種類を示す。肝臓領域では、9 回、脾臓領域では 7 回、胃領域では 9 回、骨領域では 5 回のフィードバック計算を行い、ディープニューラルネットワークが自己組織された。また、4 個のディープニューラルネットワークの種類としては、すべてシグモイド関数型ニューラルネットワークが自己選択された。次に、Table2 に有力な入力変数の自己選択結果を示す。本研究では、4 個のディープニューラルネットワークで共通に自己選択された入力変数は、平均値、分散、標準偏差、Y 座標の 4 変数であった。CNN やフィルタリングで発生された画像特徴量も自己選択されており、対象となる臓器の画像認識に適した画像特徴量が、各々のディープニューラルネットワークにおいて有力な入力変数として自己選択されていることが分かる。

今後の研究では、CNN の学習には多くの医用画像が必要とされるため、これらの医用画像を準備して CNN において学習を行い、CNN で発生させた画像特徴量をディープ GMDH-type ニューラルネットワークの入力変数に新たに加えることにより、さらに予測精度の向上を試みる予定である。

Table 1 Number of feedback loops and type of neural networks

Regions	Number of feedback loops	Type of neural network
Liver	9	Sigmoid function NN
Spleen	7	Sigmoid function NN
Stomach	9	Sigmoid function NN
Bone	5	Sigmoid function NN

5. むすび

本研究では、ディープフィードバック型 GMDH-type ニューラルネットワークとコンボリュショナルニューラルネットワーク (CNN) を用いたハイブリッド型ニューラルネットワークを用いて、腹部の X 線 CT 画像の医用画像解析を行い、肝臓、脾臓、胃、骨などの臓器の医用画像認識を行ってそれらの領域を抽出し

た。ディープフィードバック型 GMDH-type ニューラルネットワークは、学習に必要な医用画像が少ない場合でもディープニューラルネットワーク構造を自己組織することが可能である。また、ニューロンの活性化関数として、シグモイド関数、放射基底関数、線形多項式、非線形多項式などの多くの種類の関数の中から、対象となる非線形システムの特徴に最も適した活性化関数を、AIC または PSS などの予測誤差評価関数を最小にするように自己選択している。そして、すべての入力変数の組み合わせを発生させて、最も適した変数の組み合わせを見つけ出して、ディープニューラルネットワーク構造を構成している。このため、人間が手動で、ディープニューラルネットワーク構造を見つけ出す場合と比較して、非常に多くのディープニューラルネットワークの構造の中から、効率的に予測精度が良いディープニューラルネットワーク構造を見つけ出すことができる。そして、ディープニューラルネットワーク構造を自動的に自己組織化できるため実際問題への応用が非常に容易である。本研究では、X 線 CT 画像の医用画像解析問題へ応用して、画像認識結果を比較してその有効性を確認した。

謝 辞

本研究は、科学研究費補助金 JSPS KAKENHI Grant Number JP18K0420600 により補助を受けて実施された。

参 考 文 献

- [1] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image analysis of abdominal X-ray CT images by deep multi-layered GMDH-type neural network, *Artificial Life and Robotics*, vol.23, No.2, pp.271-278 (2018)
- [2] T. Kondo, S. Kondo, J. Ueno and S. Takao: Medical image diagnosis of kidney regions by deep feedback GMDH-type neural network using principal component-regression analysis, *Artificial Life and Robotics*, vol.22, No.1, pp.1-9 (2017)

- [3] S. Takao, S. Kondo, J. Ueno and T. Kondo: Hybrid deep neural network of deep multi-layered GMDH-type neural network and convolutional neural network and its application to medical image recognition of spleen regions, *Proceedings of the Twenty-Third International Symposium on Artificial Life and Robotics 2018 (AROB 23rd 2018)*, pp.84-88 (2018)
- [4] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image diagnosis of liver cancer by hybrid deep neural network of deep logistic GMDH-type neural network and convolutional neural network, *Proceedings of the Twenty-Third International Symposium on Artificial Life and Robotics 2018 (AROB 23rd 2018)*, pp.89-93 (2018)
- [5] T. Kondo, S. Kondo, J. Ueno and S. Takao: Medical image diagnosis of lung cancer by deep logistic GMDH-type neural network using revised heuristic self-organization, *Proceedings of the Twenty-Second International Symposium on Artificial Life and Robotics 2017 (AROB 22nd 2017)*, pp.386-389 (2017)
- [6] T. Kondo: GMDH neural network algorithm using the heuristic self-organization method and its application to the pattern identification problem, *Proc. of the 37th SICE Annual Conference*, pp.1143-1148 (1998)
- [7] S. J. Farlow ed.: Self-organizing methods in modeling, GMDH-type algorithm, New York: Marcel Dekker Inc. (1984)
- [8] A. G. Ivakhnenko: Heuristic self-organization in problems of engineering cybernetics, *Automatica*, vo.6, no.2, pp.207-219 (1970)
- [9] H. Akaike: A new look at the statistical model identification, *IEEE Trans. Automatic Control*, vol.AC-19, no.6, pp.716-723 (1974)
- [10] H. Tamura, T. Kondo: Heuristics free group method of data handling algorithm of generating optimum partial polynomials with application to air pollution prediction, *Int. J. System Sci.*, vol.11, no.9, pp.1095-1111 (1980)
- [11] N. R. Draper, H. Smith: *Applied Regression Analysis*, New York: John Wiley and Sons (1981)

Table2 Selection of useful input variables in the deep feedback GMDH-type neural networks

Regions \ Input variables	Gaussian filter	Laplacian filter	Maximum filter	Minimum filter	Range filter	Mean	X	Y	Variance	Standard deviation
Liver			○		○	○	○	○	○	○
Spleen	○					○	○	○	○	○
Stomach						○	○	○	○	○
Bone	○	○	○			○		○	○	○