ディープ GMDH-type ニューラルネットワークを用いた 臓器の医用画像認識

Medical Image Recognition of Organs Using Deep GMDH-type Neural Network

近藤 正(京都情報大学院大学)

Tadashi Kondo (The Kyoto College of Graduate Studies for Informatics)

Abstract

本研究では、多層構造型 GMDH (Group Method of Data Handling) -type ニューラルネットワーク とコンボリューショナルニューラルネットワーク (CNN) を組み合わせて構成したハイブリッド型ディー プニューラルネットワークを、AIC (赤池の情報量規準) や PSS (予測誤差平方和) などの予測誤差評 価基準を最小にするように構成する。CNN の内部では多くの画像特徴量を畳み込み積分やプーリング処 理によって自動的に発生させ、これらの発生した画像特徴量を、従来の画像認識で用いられていた画像 特徴量と合わせてディープ GMDH-type ニューラルネットワークの入力変数として用いる。ディープ GMDH-type ニューラルネットワークのアルゴリズムでは、中間層の層数、最適なニューロンの構造、 有益な入力変数などが自己選択され、これらの自己選択されたハイパーパラメータを用いて、多くの中 間層を備え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。このディープニューラルネッ トワークのアルゴリズムを頭部の医用画像認識に応用し、脳の実質、白質、脳室などの臓器をディープ 多層構造型 GMDH-type ニューラルネットワークを用いて画像認識してこれらの領域を抽出する。

In this study, the deep multi-layered Group Method of Data Handling (GMDH)-type neural network is combined to the Convolutional Neural Network (CNN), and the hybrid deep neural network is organized so as to minimize prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS). 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 GMDH-type neural network appending the conventional image features which were used in the conventional image recognitions. The deep GMDH-type neural network algorithms have abilities of self-selecting the number of hidden layers, the optimum neuron architectures and useful input variables, and they can automatically organize the deep neural network architectures which have many hidden layers. This deep neural network algorithm is applied to medical image recognized and these regions are extracted using the deep multi-layered GMDH-type neural networks.

1. はじめに

本研究では、ディープ多層構造型 GMDH-type ニューラルネットワークとコンボリューショナル 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 [1] を用いて、頭 部臓器の医用画像認識を行う。ディープ GMDHtype 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、各種のアルゴリズムが提 案されている [1]-[5]。 これらのディープ GMDH- type ニューラルネットワークスは、脳、肝臓、骨、 血管、脾臓などのいろいろな臓器の医用画像認識問 題に応用されている [1]-[3]。また、肺がんの医用画 像診断にも応用されている [4]。ディープ多層構造 型 GMDH-type ニューラルネットワークは、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 を用いて、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。中間層 の個数、最適なニューロン構造、有益な入力変数の 選択などのネットワークの構造パラメータ(ハイ パーパラメータ)を、予測誤差評価基準(情報量規 準 AIC [8] や予測誤差平方和(PSS)[9])を最小に するように、自動的に決定している。さらに、ニュー ロンの活性化関数として、シグモイド関数型活性化 関数、放射基底関数(Radial Basis Function(RBF)) 型活性化関数、多項式型活性化関数などの中から、 対象となる非線形システムの特徴に最も適した活性 化関数を予測誤差評価基準(PSS またはAIC)を 最小にするように自己選択する機能を備えている。

本研究では、医用画像からコンボリューショナル 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 多層構造型 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 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、有益 な変数の組み合わせのみを自己選択して、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頭部臓器の医用画像認 識に応用する。医用画像としては頭部 MRI 画像を 用いて、脳の実質、白質、脳室などの領域を画像認 識させて領域抽出する。そして、自己組織化された ディープニューラルネットワークの構造を比較検討 する。

2. 改良形発見的自己組織化法 [1, 4]

ディープ GMDH-type ニューラルネットワーク スのアルゴリズムは, GMDH 法で用いられている 発見的自己組織化法 [6, 7] に基づいて, ニューラル ネットワークスの構造を自己組織化している。以下 に改良形発見的自己組織化法 [1, 4] 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。
- 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. ディープ多層構造型 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 [1]

ディープ多層構造型 GMDH-type ニューラルネッ トワークとコンボリュー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



Optimum activation function is automatically selected from Sigmoid function, Radial basis function and Polynomial Fig.1 Hybrid deep neural network architecture of deep multi-layered GMDH-type neural network and convolutional neural network (CNN)

ネットワークの構造を, Fig.1 に示す。

このニューラルネットワークでは、CNN とフイ 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多層構造型 GMDH-type ニューラルネットワークの入力変数に する。ディープ多層構造型 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 非線形な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 とフイルターリング

本研究では、学習に用いる大量の画像データを準 備できなかったために、CNN での学習は行わずに、 CNN のフイ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、フイルターとしてはガウ シアンフイルターとラプラシアンフイルターを用い 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、範囲などのフイルターリングを行い、画像特 徴量の抽出を行う。

3.2 ディープ多層構造型 GMDH-type ニューラル ネットワーク

本アルゴリズムの概要を以下に示す。本研究では, 原データをすべ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] 第1層
u_j=x_j (*j*=1,2,...,*p*)
ここで, *x_i*はシステムの入力変数を示す。

(1)

[2] 第2層

入力変数どうしを組み合わせて, すべての組み合 わせを発生させる。ニューロンは1型と2型の2 種類を用い, さらに1型と2型に3種類のニュー ロン構造を発生させて, 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。

シグモイド関数型ニューラルネットワークス
1型ニューロン構造

 Σ : (Nonlinear function) $z_k = w_1 u_i + w_2 u_i + w_3 u_i u_i + w_4 u_i^2 + w_5 u_i^2 - w_0 \theta_1$ (2)or $z_k = w_1 u_i + w_2 u_j + w_3 u_k + w_4 u_i u_j + w_5 u_i u_k + w_6 u_j u_k + w_7 u_i^2 + w_8 u_j^2$ $+w_9u_i^2-w_0\theta_1$ (3)*f*: (Nonlinear function) $y_k = 1 / (1 + exp(-z_k))$ (4)ii) 2型ニューロン構造 Σ : (Linear function) $z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_1 \quad (r < p)$ $(\mathbf{5})$ *f*: (Nonlinear function) $y_k = 1 / (1 + exp(-z_k))$ $(\mathbf{6})$ 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) $z_k = w_1 u_i + w_2 u_i + w_3 u_i u_i + w_4 u_i^2 + w_5 u_i^2 - w_0 \theta_1$ (7)or $z_k = w_1 u_i + w_2 u_i + w_3 u_k + w_4 u_i u_i + w_5 u_i u_k + w_6 u_i u_k + w_7 u_i^2 + w_8 u_i^2$ $+w_9u_i^2-w_0\theta_1$ (8)*f*: (Nonlinear function) $y_k = exp(-z_k^2)$ (9) ii) 2型ニューロン構造 Σ : (Linear function) $z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_1$ (r<p) (10)*f*: (Nonlinear function) $y_k = exp(-z_k^2)$ (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) $z_k = w_1 u_i + w_2 u_i + w_3 u_i u_i + w_4 u_i^2 + w_5 u_i^2 - w_0 \theta_1$ (12)or $z_k = w_1 u_i + w_2 u_i + w_3 u_k + w_4 u_i u_i + w_5 u_i u_k + w_6 u_i u_k + w_7 u_i^2 + w_8 u_i^2$ $+w_9u_i^2-w_0\theta_1$ (13)*f*: (Linear function) (14) $y_k = z_k$ ii) 2型ニューロン構造 Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_1 (r < p)$$
(15)
 $f:$ (Linear function)

$$y_k = z_k$$
 ($z_k > 0$ の場合)
 $y_k = 0$ ($z_k < 0$ の場合) (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 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。ここで、もしニューロンの活性化関数とし て、(5) 式と(6) 式のみを用いた場合、従来から よく用いられている多層構造をしたシグモイド関数 型ニューラルネットワークを, ディープ GMDHtype ニューラルネットワークアルゴリズムを用い て構成でき、学習アルゴリズムとして誤差逆伝播法 (BP法)を適用できる。次に、ニューロンの活性 化関数として、(10) 式と(11) 式のみを用いた場 合、多層構造をした放射基底関数(RBF)型ネット ワークをディープ GMDH-type ニューラルネット ワークアルゴリズムを用いて構成できる。次に, (15) 式と(16) 式のみを用いた場合, ディープラー ニングで用いられているディープニューラルネット ワークと同様なネットワーク構造を、ディープ GMDH-type ニューラルネットワークアルゴリズム を用いて構成できる。さらに、ニューロンの活性化 関数として、(12)式、(13)式と(14)式のみを 用いた場合、非線形システム同定手法である GMDH 法と同じ高次非線形多項式ネットワークを 構成できる。

次に,ニューロンの重みwの値は,主成分回帰 分析[10]を用いて次のように推定する。

4) 重み wの推定

まず,各々のニューロンに対して_{*Zk*}**の値を計算 する。

i)シグモイド関数型ニューロン	
$z_k^{**} = log_e(\phi'/(1-\phi'))$	(17)
ii) RBF 型ニューロン	

- z_k**=(-log_e ¢')^{1/2} (18) iii) 多項式型ニューロン
- 111) 多項八至ニュニロン
- $z_k^{**} = \phi \tag{19}$

ここで、 ¢ はシステムの出力変数、 ¢' は 0 から 1 の間の値に規準化された出力変数を示す。重みwは、 次に示す主成分回帰分析 [10] を用いて推定する。

各々のニューロンに対して、トレーニングデータ を用いて、主成分回帰分析により重みwを推定する。 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。そして3種類のニューロンを各々の入力変数の組み合わせに対して構成する。

主成分回帰分析を用いたニューロンの学習計算で は、入力変数の組み合わせに対して主成分の抽出を 行う。(2)式のニューロンの場合を例にとる。

まず、固有ベクトルを計算する。

$$\underline{\boldsymbol{\nu}} = \boldsymbol{H} \cdot \underline{\boldsymbol{u}} \tag{20}$$

$$\underline{\mathbf{v}} = (v_1, v_2, \dots, v_5)$$

 $\mathbf{u} = (u_i \, u_i, \, u_i u_i, \, u_i^2, \, u_i^2)$

<u>v</u>は固有ベクトル, *H*は固有行列で次式により固 有値問題を解くことによって計算する。

$$R \cdot H = H \cdot \Lambda \tag{21}$$

ここで, *R* は相関行列を表す。次に, 変数 *z* を 直交回帰分析により計算する。

 $z_k = \underline{w}^T \cdot \underline{v}$

 $= w_1 v_1 + w_2 v_2 + \dots + w_5 v_5 \tag{22}$

この場合,出力変数として *z_k*^{**} を用いる。そして, AIC または PSS を変数選択の評価基準として変数 選択型重回帰分析法 [10] を用いて有益な主成分の みを選択する。

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 値または PSS 値の小さいものをL個選択する。

5)総合特性変数 (*ϕ**) の発生

総合特性変数(ϕ^*)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、次の線形結 合式を用いて計算する。

$$\phi^* = a_0 + \sum_{k=1}^{L} a_k y_k \tag{23}$$

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またはPSSを用いた変数選択型重回 帰分析法により、AICまたはPSS値の小さいもの を自己選択する。次に、(23)式のAICまたは 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。次層の計算では、 自己選択したニューロン構造のみを用いてニューラ ルネットワークスの計算を行う。具体的には、総合 特性変数(ϕ^*)と自己選択したL個のニューロン の出力値を次層の入力変数にセットして,次層の計 算に移る。

[3] 3 層以上の層

3層以上の層では,第2層と同じ計算を繰り返す。 ただし,ニューロンの構造は自己選択した構造のみ を使用する。そして,(23)式のAICまたはPSS の値が減少しなくなる層で中間層の計算を停止す る。中間層の計算を停止した場合,最終の中間層を 出力層とする。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、多層構造をしたディープ GMDH-type ニューラルネットワークスを構成でき る。

本研究で使用したディープ多層構造型 GMDHtype ニューラルネットワークでは、入力層に近い 層で、対象となる非線形システムの部分的な特徴を 同定しており、層を積み重ねることにより、徐々に 非線形システムの全体的な特徴を同定するように なっており、層を積み重ねてネットワークが十分な 複雑性を備えて、非線形システムの全体の特徴を ネットワーク上に記憶したときに、ネットワークの 層の積み重ね計算を停止している。そして、予測誤 差評価基準の AIC 値または PSS 値が最も小さくな るディープニューラルネットワーク構造を自動的に 自己組織化している。

4. 頭部臓器の医用画像認識への応用

本研究では、ディープ多層構造型 GMDH-type ニューラルネットワークスを用いて、頭部臓器の医 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 MRI 画像を用いた。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 脳実質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を自己組織 化するため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×N近傍領域の 画像特徴量を用いた。これは、CNNにおいて、ガ ウシアンフイルター、ラプラシアンフイルター、最 大値フイルター、最小値フイルター、レンジフイル ターにより発生した5個の画像特徴量と、従来か ら用いられている統計学的特徴量である平均値、分

散,標準偏差,及び位置情報(xとy座標)の合計 10 個の入力変数を用いた。これらの特徴量の中か ら、平均値、標準偏差、分散、x座標、v座標、範 囲(レンジ)の6個の変数がニューラルネットワー クスにより有益な入力変数として自己選択された。 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3の場合に, 最も良い画像認識精度を得 た。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、対象臓器の領域内部では1の値を出 力するように学習させた。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.3に、第2層で計算された3種 類のニューロンの誤差を示す。ディープ GMDHtype ニューラルネットワークスの計算は第9層で 終了した。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。Fig.4 に、各層における PSS 値の変化を示す。層を通過することにより PSS 値は徐々に減少して予測誤差が小さな値に収 東した。



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多層構造型 GMDHtype ニューラルネットワークスによって脳実質領 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。脳実質領域が抽出されている。 脳実質の外部の領域(孤立点)はほとんど含まれて いないことがわかる。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、画像の膨張処理と収縮 処理を行い、脳実質領域の内部に孤立した部分があ る場合や、脳実質領域の外部にある孤立点が除去さ れた。そして、脳実質領域の輪郭を N/2 画素分だ け外側に拡張した。Fig.6 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.7に原画像と後処理後の出力画 像を重ね合わせた画像を示す。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脳実質 領域は、原画像の脳実質領域によく一致しているこ とがわかる。そして、脳実質領域を、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(グレー画像)を示す。 誤差逆伝播法(BP 法)を用いて学習する従来型 ニューラルネットワークを用いて脳実質領域の画像 認識を行い、画像認識結果の比較を行った。ニュー ラルネットワークは、入力層、中間層、出力層の3 層構造とした。学習データは、ディープ GMDHtype ニューラルネットワークと同じものを用いた。 学習では、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。本 研究では、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。出力画像は Fig.5 に対応 している。これらのニューラルネットワークの出力 画像には、孤立点や脳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。従来型のニューラル ネットワークスでは、ネットワーク構造の自己選択 機能を持たないため、中間層のニューロンの個数や 中間層の個数などの構造パラメータを変化させて, より望ましいネットワーク構造を見つけ出す必要が ある。このため、構造パラメータを変化させて、非 常に多くの繰り返し計算を行う必要がある。さらに、 解が局所解に収束した場合には、良い精度が得られ ないために結合加重の初期値を変化させてさらに多 くの繰り返し計算を行う必要がある。これに対して, ディープ多層構造型 GMDH-type ニューラルネッ トワークでは、このような構造パラメータを変化さ せた繰り返し計算を必要としないため、1回の計算 で複雑な構造をしたニューラルネットワークを自己 組織化できる。



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 白質領域の医用画像認識と領域抽出

白質領域の抽出を目的にした新しいニューラル ネットワークスを自己組織化した。ニューラルネッ トワークス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。そ して, 平均値, X座標, Y座標, 範囲, ガウシアン フイルターの出力値、ラプラシアンフイルターの出 力値の6個の入力変数が自己選択された。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3の場合に、最も良い画像認識精度を得た。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, 白質の内部では1の値を出力するように学習 させた。ディープ多層構造型 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.10に、第2層で計算された3種類のニュー ロンの誤差を示す。ディープ多層構造型 GMDHtype ニューラルネットワークスの計算は第15層で 終了した。Fig.11 に, 各層における PSS 値の変化 を示す。層を通過することにより 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。



Fig.10 PSS values of three types of neuron (2)



Fig.11 Variation of PSS in the deep GMDH-type NN (2)

Fig.12 に最終層で得られた出力画像を示す。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,画像の収縮処理と膨張処理を行い,白質領域 の外部にある孤立点が除去された。そして,白質領 域の輪郭を N/2 画素分だけ外側に拡張した。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た画像 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白質領域は,原画像の白質 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白質領域のグレー画 像が抽出された。Fig.15 に,白質領域のグレー画



Fig.12 Output image of the neural network (2)



Fig. 13 Output image after the post processing (2)



Fig. 14 Overlapped image (2)

像を示す。Fig.16 に BP 法を用いて学習する 3 層 構造の従来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 の脳の実 質領域の場合と同じである。



Fig.15 Extracted gray scale image (2)



(a) *m*=5



(b) *m*=7



(c) m=9 Fig.16 Output images of the conventional sigmoid function neural network (2)

4.3 脳室領域の医用画像認識と領域抽出

脳室領域の抽出を目的にした新しいニューラル ネットワークスを自己組織化した。ニューラルネッ トワークス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。そ して, 平均値, X座標, Y座標, 範囲, ガウシアン フイルターの出力値,最大値の6個の入力変数が 自己選択された。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3の場合に、最も良 い画像認識精度を得た。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、脳室領域では1 の値を出力するように学習させた。ディープ多層構 造型 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.17に、第2 層で計算された3種類のニューロンの誤差を示す。 ディープ多層構造型 GMDH-type ニューラルネッ トワークスの計算は第6層で終了した。Fig.18に、 各層における PSS 値の変化を示す。層を通過する 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。Fig.19に最終層で得ら れた出力画像を示す。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、画像の収縮処理と膨 張処理を行い、脳室領域の外部にある孤立点が除去 された。そして、脳室領域の輪郭を N/2 画素分だ け外側に拡張した。Fig.20 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.21 に原画像と後処理後の 出力画像を重ね合わせた画像を示す。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 脳室領域は、原画像の脳室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 により脳室領域のグレー画像が抽出された。Fig.22 に、脳室領域のグレー画像を示す。Fig.23 に、BP 法を用いて学習する3層構造の従来型ニューラル 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の脳の実質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 考察

本研究では、脳実質、白質、脳室の各々の領域を 画像認識して領域抽出する、3つのディープニュー ラルネットワークスを自己組織化した。まず、 Table1 に、各々のディープニューラルネットワー クの層数とニューラルネットワークの種類を示す。 層数では、脳の実質では9層、白質では15層、脳 室では6層のディープニューラルネットワークス が自己組織された。また、3つ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。 画像認識結果(Fig.4, Fig.11, Fig.18)から、予測 誤差評価基準値(PSS)は、層を積み重ねるごとに 徐々に減少していき、最終層ではPSS値が小さな 値に収束した。第1層のPSS値と比較すると、最 終層ではPSS値が大幅に減少したことがわかる。

次に、Table2 に有益な入力変数の自己選択結果 を示す。従来のディープ GMDH-type ニューラル ネットワークの研究では、平均値、分散、標準偏差、 X 座標値、Y 座標値の5つの入力変数がよく用いら れていた。本研究では、3つの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、範 囲、X 座標、Y 座標の4変数であった。CNN やフ イルター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最も適し た画像特徴量が、各々のディープニューラルネット ワークスにおいて自己選択されていることがわか る。

今後の研究では、学習に用いる医用画像を大幅に 増やして 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加えて自己選択させ 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 layers and type of neural networks

Regions	Number of layers	Type of neural network
Brain	9	Sigmoid function NN
White matter	15	Sigmoid function NN
Lateral ventricle	6	Sigmoid function NN

5. むすび

本研究では、ディープ多層構造型 GMDH-type ニューラルネットワークとコンボリューショナル 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、頭部臓 器の医用画像認識を行った。ディープ多層構造型 GMDH-type ニューラルネットワークスは、対象と なる複雑な構造をした非線形システムの特徴によく 適合するように、ディープニューラルネットワーク スの種類の自己選択(最適なニューロンの活性化関 数の自己選択)、中間層の層数の自己選択、有益な 入力変数の自己選択などの機能を備えており、予測 誤差評価基準(AICやPSS)を最小にするように, 複雑な構造をしたディープニューラルネットワーク 構造を自動的に自己組織化している。このため, ニューラルネットワークの構造パラメータ(有益な 入力変数の選択、層数の選択、ニューロンの活性化 関数の選択、各層のニューロン数の選択、BP 法に おける乱数の初期値の選択など)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 るために学習計算を繰り返す必要がないため、実際 問題への応用が非常に容易である。本研究では、頭 部臓器の医用画像認識問題へ応用して、画像認識結 果を比較してその有効性を確認した。

参考文献

 S. Takao, S. Kondo, J. Ueno and T. Kondo: Hybrid deep neural network of deep multi-layered GMDHtype 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)

- [2] S. Takao, S. Kondo, J. Ueno and T. Kondo: Deep feedback GMDH-type neural network and its application to medical image analysis of MRI brain images, *Artificial Life and Robotics*, vol.23, No.2, pp.161-172 (2018)
- [3] 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)
- [4] 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)*, (2017)
- [5] 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)
- [6] S. J. Farlow ed.: Self-organizing methods in modeling, GMDH-type algorithm, New York: Marcel Dekker Inc. (1984)
- [7] A. G. Ivakhnenko: Heuristic self-organization in problems of engineering cybernetics, *Automatica*, vo.6, no.2, pp.207-219 (1970)
- [8] H. Akaike: A new look at the statistical model identification, *IEEE Trans. Automatic Control*, vol.AC-19, no.6, pp.716-723 (1974)
- [9] 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)
- [10] N. R. Draper, H. Smith: Applied Regression Analysis, New York: John Wiley and Sons (1981)

◆ 著者紹介

近藤 正 Tadashi Kondo

京都情報大学院大学教授

Table 2	Selection	of useful	input	variables i	in the	deep	multi-layered	GMDH-type	neural	networks
---------	-----------	-----------	-------	-------------	--------	------	---------------	-----------	--------	----------

Input variables Regions	Gaussian filter	Laplacian filter	Maximum filter	Minimum filter	Range filter	Mean	х	Y	Variance	Standard deviation
Brain					0	0	\bigcirc	0	0	0
White matter	0	0			0	0	0	0		
Lateral ventricle	0		0		0	0	0	0		