ディープロジスティック GMDH-type ニューラルネットワークと CNN を用いた 頭部 MRI 画像の医用画像認識

Medical image recognition of MRI brain images using deep logistic GMDH-type neural network and convolutional neural network

近藤 正 ^{*1}	高尾 正一郎	*2 近藤 明佳*3	上野 淳二 ^{*4}
Tadashi Kondo	Shoichiro Takao	Sayaka Kondo	Junji Ueno
^{*1} 徳島大学	^{*2} 徳島大学	*3 徳島医用情報科学研究会	^{*4} 徳島大学
Tokushima University	Tokushima University	Tokushima medical informatics laboratory	Tokushima University

In this study, hybrid deep neural network is organized using the deep logistic Group Method of Data Handling (GMDH)type neural network and the Convolutional Neural Network (CNN) and, is applied to the medical image recognition problem. 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 to minimize prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS). This deep neural network algorithm is applied to medical image recognitions of brain regions, and the organs such as brain, the white matter and the lateral ventricle, are recognized and these regions are extracted accurately using the deep logistic GMDH-type neural networks.

1. はじめに

本研究では、ディープロジスティック 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 MRI 画像の医用画像認識を行う。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、各 種のアルゴリズムが提案されている[1-4]. ディープロジスティック GMDH-type ニューラルネットワーク[1]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[5]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を、予測誤差評 価基準(情報量基準 AIC[6]や予測誤差平方和(PSS)[7])を最 小にするように、自動的に決定している。本研究では、ディープ ロジスティック GMDH-type ニューラルネットワークス[1]を、文献 [2,3]と同じ頭部 MRI 画像の医用画像認識問題に応用して、 その画像認識結果を比較検討する。

2. ディープロジスティック 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]

ディープロジスティック GMDH-type ニューラルネットワークと 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の 構造[1]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を 加えてディープロジスティック GMDH-type ニューラルネットワー クの入力変数にする。このディープニューラルネットワークでは、 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し、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。

^{*1}Email: kondomedsci@gmail.com



 $\begin{array}{l} g_i(x_1,x_2,\cdots,x_p): Polynomial\\ \sum: (Nonlinear function): \ z_k = \sum w_i g_i(x_1,x_2,\cdots,x_p)\\ f: (Nonlinear function): \ \phi = 1/(1+exp\ (-z_k))\\ \mbox{Fig.1 Hybrid deep neural network architecture of deep logistic}\\ \mbox{GMDH-type neural network and convolutional neural network (CNN)} \end{array}$

2.1 CNN とフイルタリング

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 かったので、CNN での学習は行わずに、CNN のフイルタの値と してはあらかじめ既存のものを準備する。そして、フイルタとして はガウシアンフイルタ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、範囲などのフイルタリングを行 い、画像特徴量の抽出を行う。

2.2 ディープロジスティック GMDH-type ニューラルネットワーク

中間層の個数、各々の中間層におけるニューロンの個数、有益な入力変数、最適なニューロンの構造は、情報量規準(AIC) や予測誤差平方和(PSS)を最小にするように自動的に決定する。

Fig.1 において、非線形関数 gi は、次に示す Kolmogorov-Gabor polynomial

$$g_i(x_1, x_2, \dots, x_p) = a_0 + \sum_{i} a_i x_i + \sum_{i} \sum_{j} a_{ij} x_i x_j + \sum_{j} \sum_{k} a_{ijk} x_i x_j x_k + \dots$$
(1)

を示す。この非線形関数は、多項式型ニューロンを用いて 構成する。本研究では、予測誤差評価基準として、予測誤 差平方和(PSS)を用いる。本アルゴリズムの概要を以下に 示す。

[1] 第1層

^{*}連絡先:近藤正、徳島大学医学部保健学科

入力変数(u)を組み合わせて、2変数のすべての組み合わせ (ui, ui) 又は 3 変数すべての組み合わせ(ui, ui, uk)を発生させる。 各組み合わせに対して、ニューロンの構造は次の関数を用いる。

$$z_{k} = w_{l}u_{i} + w_{2}u_{j} + w_{3}u_{i}u_{j} + w_{4}u_{i}^{2} + w_{5}u_{j}^{2} - w_{0}\theta_{l}$$
(3)
or

 $z_k = w_1 u_i + w_2 u_j + w_3 u_k + w_4 u_i u_j + w_5 u_i u_k + w_6 u_j u_k$

$$+w_7 u_1^2 + w_8 u_1^2 + w_9 u_k^2 - w_0 \theta_l \qquad (4)$$

f:(Linear function)

 $y_k = z_k$

(5)ここで、θ1 =1、wi (i=0,1,2,…,9)は入力層と中間層との間の重み を示す。このニューロンは多項式ニューロンで、Σとfの2個の 関数から構成され、ニューロンの重み wの値は、主成分回帰分 析を用いて推定する。ニューロンの出力(y)を中間変数とする。

まず、各々のニューロンに対して z** の値を計算する。

$$z_k^{**} = \log_e(\frac{\phi}{1 - \phi'}) \tag{6}$$

値に規準化された出力変数を示す。zk**を用いて、各々の ニューロンに対して、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。

次に、発生した多項式型ニューロンに対して、PSS 値の 小さいものを L 個選択する。L 個の多項式型ニューロンを 用いて総合特性変数*ϕ**を発生させる。

$$\phi^* = a_0 + \sum_{k=1}^{L} a_k y_k \tag{7}$$

にセットして、次層の計算に移る。

[3] 第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。そして、 L 個のニューロンの PSS の値が減少しなくなる層で隠れ層 の計算を停止する。隠れ層の計算を停止した場合、最終の 隠れ層を出力層とする。出力層ではニューラルネットワー クの出力変数(Øを Zkから次のように計算する。

$\phi = 1/(1 + exp(-z_k))$	(8)
このため出力層では、ニューロン構造は以下のよ	うになる。
〈シグモイド関数型ニューロン〉	

 Σ : (Linear function)

$z_k = \sum w_i g_i(x_1, x_2, \dots, x_p)$	(9)
<i>f</i> : (Nonlinear function)	

(10) $\phi = 1/(1 + exp(-z_k))$

以上の手続きによりディープロジスティック GMDH-type ニューラルネットワーク[1]を構成できる。

3. 頭部臓器の医用画像認識への応用

本研究では、ディープロジスティック 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。 3.1 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、ラプラシアンフイルタ、最大値フイ ルタ、最小値フイルタ、レンジフイルタにより発生した 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、y座標、最大値の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 5 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 トワークスの計算は第19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.3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束した。





Fig.3 Variation of PSS in the deep GMDH-type of NN(1)

自己組織化されたディープロジスティック GMDH-type 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.4 に、ニ ューラルネットワークの出力画像を示す。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.5 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。Fig.6 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。Fig.7 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形ニューラルネ 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[2,3]との比較を行った。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 GMDH-type ニューラルネットワークと同じものを用いた。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.8 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。



Fig.4 Output image of the neural network(1)







Fig.6 Overlapped image(1)





Fig.7 Gray scale image (1)



(a) *m*=5

(c) *m*=9

Fig.8 Output images of the conventional neural network (1)[2,3] 3.2. 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。そして、平均値、x座標、y座標、範囲、ガウ シアンフイルタの出力値、ラプラシアンフィルタの出力値の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。ディ ープロジスティック GMDH-type ニューラルネットワークスの計 算は第 20 層で終了した。Fig.9 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束した。Fig.10 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。Fig.11 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。Fig. 12 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。Fig.13 に、 白質領域のグレー画像を示す。Fig.14 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[2,3]を示す。







Fig.10 Output image of the neural network(2)



Fig. 12 Overlapped image(2)



Fig. 11 Output image after the post processing (2)



Fig.13 Gray scale image (2)



(a) m=5 (b) m=7 (c) m=9 Fig.14 Output images of the conventional neural network (2)[2,3] **3.3. 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。そして、平均値、x座標、y座標、範囲、ガウ シアンフイルタの出力値、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 4 の場合 に、最も良い画像認識精度を得た。ディープロジスティック GMDH-type ニューラルネットワークスの計算は第8層で終了し た。Fig.15 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.16 に最終層で得られた出力画像を示す。 Fig.17 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。Fig. 18 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。Fig.19 に、脳室領 域のグレー画像を示す。Fig.20 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[2,3]を示す。





Fig.16 Output image of the neural network (3)







Fig. 18 Overlapped image(3)





(b) m=7



(c) m=9

(a) *m*=5 Fig.20 Output images of conventional neural network (3)[2,3]

Table 1 Number of hidden layers

Regions	Number of hidden layers				
Brain	19				
White matter	20				
Lateral ventricle	8				

3.4 考察

3.4 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。Table1に、各々のディープニュー ラルネットワークの隠れ層の層数を示す。脳の実質では19 層、白質では20層、脳室では8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。画像認識結果(Fig.3, Fig.9, Fig.15)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。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つの入力変数が良く用いられていた。 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、x座標、y座標の3変数で あった。CNNやフイ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最も 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たことが分かる。

4. むすび

本研究では、ディープロジスティック GMDH-type ニューラル ネットワークと 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 MRI 画像の医用画像認識を行った。ディー プロジスティック 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、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ー(有益な入力変数の選択、層 数の選択、各層のニューロン数の選択など)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の学習計 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 MRI 画像の医用画像認識問題へ 応用し、画像認識結果を比較してその有効性を確認した。文献 [2,3]の医用画像認識結果との比較については、発表時に示す。

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。

考文献

[1] 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)

[2]近藤正、高尾正一郎、近藤明佳、上野淳二:ディープ 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臓器の自動医用画像 認識、医療情報学会・人工知能学会 AIM 合同研究会資料 SIG-AIMED-006-05(2018)

[3] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image recognition of brain regions using deep multi-layered GMDHtype neural network and convolutional neural network, Proceedings of the Twenty-Fourth International Symposium on Artificial Life and Robotics 2019 (AROB 24th 2019), pp.115-121 (2019)

[4] 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)

[5] S. J. Farlow ed.: Self-organizing methods in modeling, GMDH-type algorithm, New York: Marcel Dekker Inc. (1984)

[6] H. Akaike: A new look at the statistical model identification, IEEE Trans. Automatic Control, vol.AC-19, no.6, pp.716-723 (1974)

[7] 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)

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