

ディープ RBF 型 GMDH-type ニューラルネットワーク

を用いた肝臓がんの医用画像診断

Medical image diagnosis of liver cancer using deep RBF GMDH-type neural network

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

In this study, a deep Radial Basis Function (RBF) Group Method of Data Handling (GMDH)-type neural network which has the deep neural network architecture, is applied to the medical image diagnosis of liver cancer. Deep RBF GMDH-type neural network has abilities of self-selecting the number of hidden layers, the number of neurons in hidden layers and useful input variables. This algorithm is applied to medical image recognition of liver cancer and it is shown that this algorithm is useful for medical image diagnosis of liver cancer and is very easy to apply practical complex problem because deep neural network architecture with many hidden layers, is automatically organized so as to minimize the prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS).

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数種類のアルゴリズムが提案され [Kondo 98, 12, 15, 15]、すでに、肝臓、肺、脳、心臓、腎臓、脾臓、血管、骨などのいろいろな臓器の画像認識や領域抽出問題に応用されており、各種臓器の高精度な領域抽出結果が得られている。さらに、学習用の入力画像を変えることにより、肺がんや肝臓がんなどのがん領域の画像認識や領域抽出への応用が可能である。ディープ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発見的自己組織化法を用いて、多くの中間層を持つ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する。ニューラルネットワーク構造は、予測誤差評価基準(情報量基準 AIC[Akaike 74]や予測誤差平方和(PSS)[Tamura 80])を最小にするように、中間層の数、各層のニューロン数、有益な入力変数などを自己選択して最適化しており、対象の非線形システムの複雑さに適したディープニューラルネットワーク構造を自己組織化している。

本研究では、ディープGMDH-type ニューラルネットワークの一種である、ディープ RBF 型GMDH-type ニューラルネットワークを用いて、肝臓がんの画像認識とその領域抽出を行う。本研究で使用するディープ RBF 型GMDH-type ニューラルネットワークの特徴は、多項式型ニューロンと RBF 型ニューロンを組み合わせ、データ数が少ない場合でも、非線形性の強い複雑な構造をした対象システムの特徴を、高次非線形多項式(g_i)を用いて高精度に同定できることに特徴がある。ディープ RBF 型GMDH-type ニューラルネットワークを肝臓がんの医用画像診断に応用して、その有効性を確認する。

2. 発見的自己組織化の原理

ディープ GMDH-type ニューラルネットワークのアルゴリズム [Kondo 98, 12, 15, 15]は、GMDH 法で用いられている発見的自己組織化の原理 [Farlow 84], [Ivakhnenko 70]に基づいて、ニューラルネットワークの構造を自己組織化している。以下に発見的自己組織化の原理の概略を示す。

発見的自己組織化の原理では、次に示す5つのステップにより非線形システムの入出力関係式(これをシステムの完全記述式という)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システムの部分記述式(部分的なシステムの特徴を表す式)のパラメータの推定に用い、テストデータはシステムの完全記述式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) 最適な部分記述式の発生

各々の組み合わせに対して、システムの部分記述式を発生させる。発生したシステムの部分記述式の出力を中間変数(y)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) 多層構造の繰り返し計算の停止

自己選択した L 個の中間変数を、次層の入力変数にセットして繰り返し計算を行い、多層構造を構成していく。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、システム全体の完全記述式は、各層で自己選択した部分記述式を用いて構成する。

以上の手続きにより構成される発見的自己組織化の原理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 RBF 型 GMDH-type ニューラルネットワーク

最適なネットワーク構造を自己選択するディープ RBF 型 GMDH-type ニューラルネットワークの構造を、Fig.1 に示す。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、情報量基準 AIC[Akaike 74]や予測誤差平方和(PSS)[Tamura 80]を最小にするように自動的に決定する。

非線形関数 g_i は、次に示す Kolmogorov-Gabor polynomial

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

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ことができる。本研究では、多層構造の層の数、

*連絡先：近藤 正、徳島大学医学部保健学科

*⁴ Email: kondomedsci@gmail.com

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、予測誤差平方和 (PSS) を最小にするように決定する。




Fig.1 Architecture of deep RBF GMDH-type neural network

本アルゴリズムの概要を以下に示す。

本アルゴリズムでは、予測誤差評価基準(PSS)を用いるので原データを 2 組に分割する必要がなく、すべてのデータをトレーニングデータとして用いる。

3.1 第 1 層

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

ここで、 x_j はシステムの入力変数を示す。

3.2 第 2 層

入力変数(u)どうしを組み合わせ、2変数のすべての組み合わせ(u_i, u_j)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。

<多項式型ニューロン>

$\Sigma: (\text{Nonlinear function})$

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

$f: (\text{Linear function})$

$$y_k = z_k \quad (4)$$

ここで、 $\theta_1 = 1$ 、 w_i ($i=0, 1, 2, \dots, 9$)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[Draper 81]を用いて次のように推定する。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。

$$z^{**} = (-\log_e \phi^*)^{1/2} \quad (5)$$

ここで、 ϕ はシステムの入力変数、 ϕ^* は 0 から 1 の間の値に規準化された出力変数を示す。

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。

主成分回帰分析を用いたニューロンの学習計算では、初めに入力変数の組み合わせに対して主成分の抽出を行う。

(3)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。

$$\underline{v} = H \cdot \underline{u} \quad (6)$$

ここで、

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

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

$\underline{v}$ 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。

$$R \cdot H = H \cdot \Lambda \quad (7)$$

ここで、 R は相関行列を表す。次に、変数 z_k を直交回帰分析により計算する。

$$z_k = \underline{w}^T \cdot \underline{v} = w_1 v_1 + w_2 v_2 + \dots + w_5 v_5 \quad (8)$$

この場合、出力変数として z_k^{**} を用いる。そして、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[Draper 81]を用いて有益な主成分のみを選択する。そして、 z_k からニューロンの出力(y_k)を計算する。

次に、発生した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 個のニューロンの出力値(y_k)を次層の入力変数にセットして、次層の計算に移る。

$$u_k = y_k \quad (k=1, 2, \dots, L) \quad (9)$$

3.3 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(ϕ^*)を z_k から次のように計算する。

$$\phi^* = \exp(-z_k^2) \quad (10)$$

このため出力層では、ニューロン構造は以下になる。

<RBF ニューロン>

$\Sigma: (\text{Linear function})$

$$z_k = \sum w_i g_i(x_1, x_2, \dots, x_p) \quad (11)$$

$f: (\text{Nonlinear function})$

$$\phi^* = \exp(-z_k^2) \quad (12)$$

以上の手続きによりディープ RBF 型 GMDH-type ニューラルネットワークを構成できる。

4. 肝臓がんの医用画像診断への応用

本研究では、ディープ RBF 型 GMDH-type ニューラルネットワークを用いて、肝臓がんの画像認識とその領域抽出を行った。本研究では、医用画像としてマルチスライスCT画像を用いた。まず最初の手続きとして、肝臓の正常な領域をディープ RBF 型 GMDH-type ニューラルネットワークを用いて画像認識させ、これらの領域を抽出した。次に、画像の後処理を行うことにより肝臓がんを含んだ肝臓の全体の領域を抽出した。次に、抽出した肝臓の画像を用いて、新しいディープ RBF 型 GMDH-type ニューラルネットワークを自己組織化することにより肝臓がんの候補領域を抽出した。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 ディープ RBF 型 GMDH-type ニューラルネットワークによる肝臓領域の画像認識と領域抽出

Fig.2 に、ニューラルネットワーク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。これは、平均値、分散、標準偏差、中央値、範囲、最大値、最小値などの基本統計量と位置情報(x と y 座標)である。これらの特徴量の中から、平均値、標準偏差、分散、 x 座標、 y 座標の 5 変数がニューラルネットワーク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、3 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 7 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の出力変数は、0 か 1 の値を取り、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 RBF 型 GMDH-type ニューラルネットワークスの計算は第 10 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非常に小さな値に収束した。

自己組織化されたディープ RBF 型 GMDH-type ニューラルネットワークスによって肝臓領域が出力された。Fig.4 に、ニューラルネットワークの出力画像を示す。肝臓の正常な領域が抽出されている。肝臓の内部の正常でない領域と肝臓の外部の領域(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、画像の膨張処理や収縮処理、周囲長処理などを行い、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。そして、肝臓がんを含んだ肝臓の全体の領域を抽出した。Fig.5 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.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.5)を差分することにより抽出した。Fig.7 に差分画像(グレー画像)を示す。



Fig.2 Original image (1)




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



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



Fig.5 Output image after the first post-processing



Fig.6 Overlapped image(1)




Fig.7 Extracted gray scale image

4.2 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る肝臓領域の画像認識と領域抽出

バックプロパゲーション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を用いて肝臓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。入力変数や学習データは、ディープ RBF 型 GMDH-type 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 10,000 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.8 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.4 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。こ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、よ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 RBF 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ディープニューラルネットワークを自己組織化できる。



(a) $m=5$ (b) $m=7$ (c) $m=9$

Fig.8 Output images of the conventional sigmoid function neural network using back propagation algorithm

4.3 ディープ RBF 型 GMDH-type ニューラルネットワークスによる肝臓がん領域の画像認識と領域抽出

Fig.7 の抽出された肝臓領域のグレー画像を原画像(Fig.9)として用いて、肝臓がんの領域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ものを用いた。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 2 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、肝臓がんの内部では 1 の値を出力するように学習させた。ディープ RBF 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.10 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.11 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、膨張処理、周囲長処理などを行い、肝臓がん領域の外部にある孤立点が除去された。そして、肝臓がん領域の輪郭を $N/2$ 画素分だけ外側に拡張した。Fig.12 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.13 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がん領域は、原画像の肝臓がん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肝臓がんの候補領域が抽出された。Fig.14 に肝臓がんの候補領域を示す。



Fig.9 Original image(2)
(Fig.7)




Fig.10 Variation of PSS in the deep
RBF GMDH-type NN(2)



Fig.11 Output image of
the neural network(2)




Fig.12 Output image after
the second post processing



Fig.13 Overlapped image(2)



Fig.14 Candidate regions
of liver cancer

5. 考察

ディープ RBF 型 GMDH-type ニューラルネットワークのアルゴリズムを肝臓がんの画像認識とその領域抽出へ応用した。まず、肝臓領域の画像認識と領域抽出では、10 層のディープニューラルネットワークを自己組織化した。PSS 値は第 2 層では大きい、層を通過することにより減少して、第 10 層ではかなり小

さな値になった。有益な入力変数が自己選択された。また、領域抽出された肝臓領域は実際の肝臓領域によく一致していた。次に、肝臓がん領域の画像認識と領域抽出では、6 層のディープニューラルネットワークを自己組織化した。出力層の PSS 値は非常に小さくなった。また、抽出された肝臓がんの領域は実際の肝臓がんの領域によく一致していた。また、学習に用いたデータは、学習に用いた 1 枚のスライス画像上の、約 200 点の学習ポイントが対象臓器に含まれるかどうかを、コンピュータに教えるのみでディープニューラルネットワークを自己組織化できた。自己組織化したディープニューラルネットワークは、学習に用いなかった他のスライス画像(約 150 枚のスライス画像)に対しても精度良く適用できた。

6. むすび

ディープ RBF 型 GMDH-type ニューラルネットワークのアルゴリズムは、発見的自己組織化の原理を用いて、対象の医用画像の特徴に最も適したディープニューラルネットワーク構造を自己選択する機能を備えている。さらに、中間層の個数、中間層のニューロンの個数、有益な入力変数、最適なニューロン構造などの構造パラメータを、情報量基準(AIC)や予測誤差平方和(PSS)を最小にするように、データ数が少ない場合でも自己選択できる機能を備えている。このため実際問題への応用が非常に容易である。本研究では、肝臓がんの画像診断問題へ応用して、肝臓領域と肝臓がん領域を精度良く領域抽出してその有効性を確認した。

参考文献

- [Akaike 74] H. Akaike: A new look at the statistical model identification, IEEE Trans. Automatic Control, Vol.AC-19, No.6, pp.716-723, 1974.
- [Draper 81] N. R. Draper and H. Smith : Applied Regression Analysis, John Wiley and Sons, New York, 1981.
- [Farlow 84] S.J.Farlow ed.: Self-organizing methods in modeling, GMDH-type algorithm, Marcel Dekker, Inc., New York, 1984.
- [Ivakhnenko 70] A. G. Ivakhnenko: Heuristic self-organization in problems of engineering cybernetics, Automatica, Vo.6, No.2, pp.207-219, 1970.
- [Kondo 98] 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.
- [Kondo 12] T. Kondo, J. Ueno and S. Takao: Feedback GMDH-type neural network and its application to medical image analysis of liver cancer, *International Journal of Innovative Computing, Information and Control*, Vol.8, No.3, pp.2285-2300, 2012.
- [Kondo 15] T. Kondo, J. Ueno and S. Takao: Logistic GMDH-type neural network using principal component-regression analysis and its application to medical image diagnosis of lung cancer, *Artificial Life and Robotics*, Vol.20, No.2, pp.137-144 2015.
- [Kondo 15] T. Kondo, J. Ueno and S. Takao: Medical image diagnosis of liver cancer by hybrid feedback GMDH-type neural network using principal component-regression analysis, *Artificial Life and Robotics*, Vol.20, No.2, pp.145-151, 2015.
- [Tamura 80] H. Tamura and 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.