

令和 3 年 6 月 14 日現在

機関番号：16101

研究種目：基盤研究(C)（一般）

研究期間：2018～2020

課題番号：18K04206

研究課題名（和文）深層学習とディープGMDH型人工知能技術による医用画像診断と感性工学への応用

研究課題名（英文）Application of deep learning and GMFH-type neural network for medical image diagnosis and affective engineering

研究代表者

高尾 正一郎（TAKAO, Shoichiro）

徳島大学・大学院医歯薬学研究部（医学域）・准教授

研究者番号：30363146

交付決定額（研究期間全体）：（直接経費） 3,200,000円

研究成果の概要（和文）：本研究では、多数の中間層を持つディープニューラルネットワーク構造を自己組織できるディープ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)を組み合わせたハイブリッド型ディープニューラルネットワークを開発して、頭部MRI画像解析、胸部X線CT画像解析、腹部X線CT画像解析に応用した。そして、いろいろな臓器の画像認識を行なうディープニューラルネットワークを自己組織して、得られた画像認識結果を、従来から用いられている3層構造のニューラルネットワークと比較しその有効性を確認した。

研究成果の学術的意義や社会的意義

本研究では、ディープGMDH-typeニューラルネットワークとCNNを組み合わせたハイブリッド型ニューラルネットワークを開発した。ディープGMDH-typeニューラルネットワークは、多くの中間層を持つニューラルネットワーク構造を自動的に自己組織でき、いろいろな臓器の医用画像認識問題に対して、最適な複雑さをしたネットワーク構造を自動的に自己組織できる。このような機能を備えた機械学習の数学アルゴリズムは他にない。本研究では、頭部、胸部、腹部のいろいろな臓器に対してハイブリッド型アルゴリズムを適用してその有効性を確認した。本アルゴリズムは汎用性が高く、他の分野にも簡単に応用が可能である。

研究成果の概要（英文）：In this study, the deep hybrid neural networks which are constructed with the deep Group Method of Data Handling (GMDH)-type neural network and the convolutional neural network (CNN), is developed and these hybrid algorithms are applied to the medical image analysis of MRI images of the brain regions, the medical image analysis of X-ray CT images of the chest and the abdominal regions. The deep GMDH-type neural network can automatically organize the optimal deep neural network architectures. In this study, the deep neural networks which are used to recognize many organs, are automatically organized using the deep hybrid neural networks, and the recognition results are compared with the results of the conventional three-layered neural networks and it is shown that the hybrid neural networks are useful for the medical image recognitions of many organs.

研究分野：放射線医学

キーワード：深層学習 医用画像認識 GMDH型人工知能技術

1. 研究開始当初の背景

近年、第 3 次人工知能ブームが起こり、人工知能技術（深層学習などの機械学習技術）が注目されている。医療分野への人工知能技術の応用も進んでいる。医療分野では、医療情報のデジタル化が進んでおり各種の医療画像がデジタル化されている。特に、X 線 CT 断層装置の高性能化が目覚ましく、撮影の高速化と断層画像の高精細化が進んでいる。1 回の検査で数百枚から千枚以上のデジタル断層画像が撮影されており、読影する医師にとっては負担が増加している。このため、人工知能技術（深層学習など）を応用したコンピュータ支援診断システム（CAD システム）への期待が高まっている。

2. 研究の目的

本研究では、深層学習の代表的な手法である畳み込みニューラルネットワーク（CNN）と、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機能を備えたディープ GMDH(Group Method of Data Handling)-type ニューラルネットワークを組み合わせた 3 種類の Hybrid 型ニューラルネットワークアルゴリズムを開発した。そして、この Hybrid 型ディープニューラルネットワークを組み込んだ CAD システムを開発して、頭部、胸部、腹部などの領域のいろいろな臓器をコンピュータが高精度に画像認識できるようにした。この AI システムは汎用性が高いため、学習用医用画像データを入れ替えることにより、がんなどの病変の画像認識とその領域抽出にも応用できる。

3. 研究の方法

本研究では、多層構造型、フィードバック型、ロジスティック型の 3 種類のディープ GMDH-type ニューラルネットワークを開発して CNN と組み合わせた。そして、開発した 3 種類の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 画像解析、胸部 X 線 CT 画像解析、腹部 X 線 CT 画像解析を行なった。本報告書では、紙面の都合により、ディープロジスティック GMDH-type ニューラルネットワークのアルゴリズムを組み込んだ Hybrid 型ディープニューラルネットワークとその研究成果について具体的に述べる。このディープ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を、予測誤差評価基準（情報量基準 AIC や予測誤差平方和 (PSS)）を最小にするように、自動的に決定している。以下にこのアルゴリズムを具体的に述べる。

(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

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を、Fig.1 に示す。このニューラルネットワークでは、CNN とフィ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。

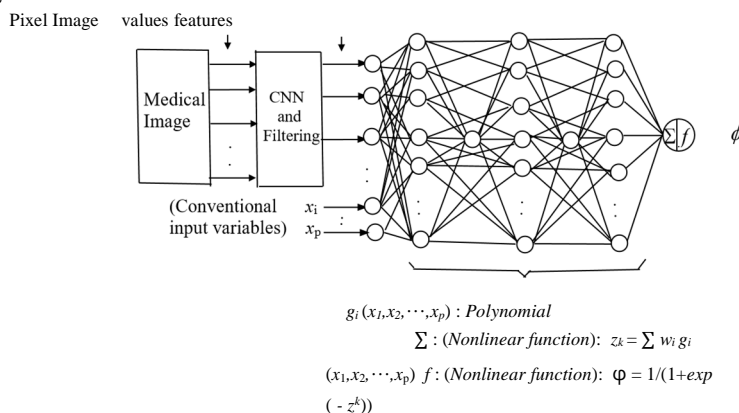


Fig.1 Hybrid deep neural network architecture of deep logistic GMDH-type neural network and convolutional neural network (CNN)

(2) CNN とフィルタリング

本研究では、学習に用いる教師ラベル付の大量の医用画像データを準備できていなかったため、CNN での学習は行わずに、CNN のフィ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、フィルタとしてはガウシアンフィ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、範囲などのフィルタリングを行い、画像特徴量の抽出を行う。

- (3) 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 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。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。

第1層

$$u_j = x_j \quad (j=1, 2, \dots, p) \quad (2) \text{ ここで, } x_j \text{ はシステムの入力変数を示す。}$$

第2層入力変数(u)を組み合わせ、2変数のすべての組み合わせ(u_i, u_j) 又は3変数すべての組み合わせ(u_i, u_j, u_k)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>

Σ : (Nonlinear function)

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

or

$$z_k = w_1 u_i + w_2 u_j + w_3 u_k + w_4 u_i u_j + w_5 u_i u_k + w_6 u_j u_k + w_7 u_i^2 + w_8 u_j^2 + w_9 u_k^2 - w_0 \theta_1 \quad (4)$$

f : (Linear function)

$$y_k = z_k \quad (5)$$

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_k^{**} の値を計算する。

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

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

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

ϕ^* と L 個のニューロンの出力値(y_k)を次層の入力変数(u_k)にセットして、次層の計算に移る。

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。

$$\phi = 1 / (1 + \exp(-z_k)) \quad (8)$$

このため出力層では、ニューロン構造は以下ようになる。 <シグモイド関数型ニューロン>

Σ : (Linear function)

$$z_k = \sum w_i g_i(x_1, x_2, \dots, x_p) \quad (9)$$

f : (Nonlinear function)

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

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を構成できる。

4. 研究成果

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研究成果について具体的に述べる。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。

(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 $N \times N$ 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。

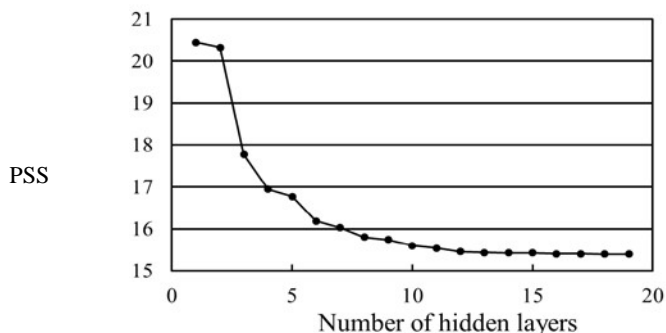



Fig.2 Original image Fig.3 Variation of PSS in the deep GMDH-type of NN

自己組織化されたディーププロジスティック GMDH-type ニューラルネットワーク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.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。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 Fig.5 Output image after the post-processing the neural








Fig.6 Overlapped image
Fig.7 Gray scale image



(a) $m=5$

(b) $m=7$

(c) $m=9$

Fig.8 Output images of the conventional three-layered sigmoid function neural network

(2) 白質領域と脳室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を自己組織化した。また、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を自己組織化した。ニューラルネットワークの出力結果は紙面の都合で省略する。

(3) まとめ

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。次に、Table2 に有益な入力変数の自己選択結果を示す。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において自己選択されたことが分かる。

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。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。

Table 1 Number of hidden layers

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

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

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

5. 主な発表論文等

〔雑誌論文〕 計3件（うち査読付論文 3件／うち国際共著 0件／うちオープンアクセス 0件）

1. 著者名 Shoichiro Takao, Sayaka Kondo, Junji Ueno and Tadashi Kondo	4. 巻 -
2. 論文標題 Medical image analysis of X-ray CT images using hybrid deep neural network of deep feedback GMDH-type neural network and convolutional neural network	5. 発行年 2020年
3. 雑誌名 Proceedings of the twenty-fifth international symposium on artificial life and robotics 2020	6. 最初と最後の頁 435 ~ 442
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Shoichiro Takao, Sayaka Kondo, Junji Ueno and Tadashi Kondo	4. 巻 -
2. 論文標題 Medical image recognition of brain regions using deep multi-layered GMDH-type neural network and convolutional neural network	5. 発行年 2019年
3. 雑誌名 Proceedings of the twenty-fourth international symposium on artificial life and robotics 2019	6. 最初と最後の頁 115 ~ 121
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Shoichiro Takao, Sayaka Kondo, Junji Ueno and Tadashi Kondo	4. 巻 -
2. 論文標題 Hybrid deep neural network of deep multi-layered GMDH-type neural network and convolutional neural network and its application to medical image recognition of chest regions	5. 発行年 2021年
3. 雑誌名 Proceedings of the twenty-sixth international symposium on artificial life and robotics 2021(AROB 26th 2021)	6. 最初と最後の頁 353 ~ 359
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

〔学会発表〕 計7件（うち招待講演 0件／うち国際学会 3件）

1. 発表者名 Shoichiro Takao, Sayaka Kondo, Junji Ueno and Tadashi Kondo
2. 発表標題 Medical image analysis of X-ray CT images using hybrid deep neural network of deep feedback GMDH-type neural network and convolutional neural network
3. 学会等名 The twenty-fifth international symposium on artificial life and robotics 2020 (AROB 25th 2020) (国際会議) (国際学会)
4. 発表年 2020年

1. 発表者名 近藤正、高尾正一郎、近藤明佳、上野淳二
2. 発表標題 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
3. 学会等名 第33回人工知能学会全国大会
4. 発表年 2019年

1. 発表者名 近藤正、高尾正一郎、近藤明佳、上野淳二
2. 発表標題 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
3. 学会等名 医療情報学会・人工知能学会AIM合同研究会
4. 発表年 2019年

1. 発表者名 Shoichiro Takao, Sayaka Kondo, Junji Ueno and Tadashi Kondo
2. 発表標題 Medical image recognition of brain regions using deep multi-layered GMDH-type neural network and convolutional neural network
3. 学会等名 The twenty-fourth international symposium on artificial life and robotics 2019 (AROB 24th 2019) (国際学会)
4. 発表年 2019年

1. 発表者名 近藤正、高尾正一郎、近藤明佳、上野淳二
2. 発表標題 ディープGMDH-typeニューラルネットワークとコンボリユーションア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
3. 学会等名 医療情報学会・人工知能学会AIM合同研究会
4. 発表年 2018年

1. 発表者名 Shoichiro Takao, Sayaka Kondo, Junji Ueno and Tadashi Kondo
2. 発表標題 Hybrid deep neural network of deep multi-layered GMDH-type neural network and convolutional neural network and its application to medical image recognition of chest regions
3. 学会等名 The twenty-sixth international symposium on artificial life and robotics 2021(AROB 26th 2021) (国際学会)
4. 発表年 2021年

1. 発表者名 近藤正、高尾正一郎、近藤明佳、上野淳二
2. 発表標題 ディープ多層構造型GMDH-typeニューラルネットワークとCNNを用いた胸部画像の医用画像解析
3. 学会等名 第34回人工知能学会全国大会
4. 発表年 2021年

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-

6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
研究分担者	上野 淳二 (UENO Junji) (60116788)	徳島大学・大学院医歯薬学研究部(医学域)・非常勤講師 (16101)	
研究分担者	近藤 正 (KONDO Tadashi) (80205559)	徳島大学・大学院医歯薬学研究部(医学域)・名誉教授 (16101)	

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8 . 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------