

平成 30 年 5 月 30 日現在

機関番号：16101

研究種目：基盤研究(C) (一般)

研究期間：2015～2017

課題番号：15K06145

研究課題名(和文) 深層学習とDeep GMDH型人工知能技術による腹部X線CT画像解析と診断支援

研究課題名(英文) Medical image analysis of abdominal X-ray CT images by hybrid deep neural network of deep logistic GMDH-type neural network and convolutional neural network

研究代表者

上野 淳二 (UENO, Junji)

徳島大学・大学院医歯薬学研究部(医学系)・教授

研究者番号：60116788

交付決定額(研究期間全体)：(直接経費) 2,300,000円

研究成果の概要(和文)：本研究では、コンボリューションニューラルネットワーク(CNN)とディープGMDH-typeニューラルネットワークを組み合わせた、Hybrid型人工知能アルゴリズムを提案した。ディープGMDH-typeニューラルネットワークは、たくさんの隠れ層を持つ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。そして、Hybrid型人工知能アルゴリズムを、腹部臓器の医用画像認識や、肝臓がんの医用画像診断などに応用した。また、得られた画像認識結果を、学習理論として誤差逆伝播法(BP法)を用いる従来からよく使われているシグモイド関数型人工ニューラルネットワークと比較して、その有効性を確認した。

研究成果の概要(英文)：We proposed the hybrid artificial neural network algorithms of the convolutional neural network (CNN) and the deep GMDH-type neural networks. The deep GMDH-type neural networks can automatically organize the deep neural network architectures which have many hidden layers. These hybrid artificial neural network algorithms were applied to the medical image diagnosis of the liver cancer and the medical image recognitions of the abdominal organs such as spleen. The recognition results were compared with those of the conventional sigmoid function type neural network using the backpropagation algorithm as the learning calculations. It was shown that these proposed algorithms were useful for the medical image recognitions and the medical image diagnosis of the abdominal organs.

研究分野：放射線診断学

キーワード：ニューラルネットワーク GMDH MDCT 医用画像診断 CAD

### 1. 研究開始当初の背景

近年、医療情報のデジタル化が進み、医用画像においてもほとんどの領域でデジタル化されている。一方、画像診断機器の進歩により医療における画像診断の役割が拡大している。なかでも X 線 CT 断層撮影装置の発達はめざましく、多列検出器型 CT 断層撮影装置の登場により撮影の高速化と体軸方向の空間分解能向上がもたらされた。撮影の高速化は広範囲の撮影を可能とし、体軸方向の空間分解能向上は等方向性 volume data の取得を可能とした。これらにより高精細な三次元画像情報が得られるようになったが、1 回の検査で撮影される断層画像の枚数は数百枚から数千枚にも達している。このような膨大なデータは診断的価値の増加をもたらしたが、それを読影する医師に対しては負荷の増大や作業効率の低下を招く可能性が出てきた。この状況を解決するために、コンピュータを用いて大量の医用画像を効率よく処理して医師の診断支援を行うためのコンピュータ支援画像診断(CAD)システムの開発に期待が集まった。

### 2. 研究の目的

本研究では、腹部の多列検出器型 CT(MDCT)画像を対象にして、人工ニューラルネットワーク理論であるコンボリユーションニューラルネットワーク(CNN)とディープ GMDH (Group Method of Data Handling)-type ニューラルネットワーク理論を組み合わせた新しい多層型 Hybrid 人工知能アルゴリズムを開発して、腹部の臓器の高精度な画像解析やコンピュータによる腹部臓器の画像認識を行い、対象となる腹部臓器の領域抽出や、肝臓腫瘍などの異常領域の抽出を行うコンピュータ支援画像診断 (CAD) システムの開発を試みた。

### 3. 研究の方法

本研究では、CNN とディープ GMDH-type ニューラルネットワーク理論を組み合わせた新しい多層型 Hybrid 人工知能アルゴリズムを開発した。このアルゴリズムでは、まず始めに医用画像からピクセル値を CNN に入力して画像特徴量を発生させる。次にこれらの画像特徴量と従来から用いられている画像特徴量を合わせて、ディープ GMDH-type ニューラルネットワークに入力し、ディープ GMDH-type ニューラルネットワークの内部で有用な入力変数のみを自己選択させた。ディープ GMDH-type ニューラルネットワークは、有用な入力変数の自己選択能力を備えており、入力された入力変数のすべての組み合わせを発生させて、有用な変数の組み合わせを自己選択できる。

本研究では、ディープ GMDH-type ニューラルネットワークアルゴリズムとして数種類のアルゴリズムを提案した。ここでは、その中で、代表的なアルゴリズムの概要とその医用画像認識への応用を以下に示す。

本研究で提案したディープ GMDH-type ニ

ューラルネットワークアルゴリズムでは、有用な入力変数の自己選択能力のほかに、シグモイド関数型ニューロンと放射基底関数(RBF)型ニューロンと多項式型ニューロンの3種類のニューロン構造を用いて、対象の非線形システムの特徴に合ったニューロンの活性化関数を自己選択する機能を備えている。そして、進化論的計算手法の一種である改良形発見的自己組織化法を用いて、ネットワーク構造を自己組織化して対象となる医用画像の複雑さに適したニューラルネットワーク構造を自動的に構成している。多層構造の層の数、中間層のニューロンの個数、最適なニューロン構造などの構造パラメータは情報量基準(AIC)や予測誤差平方和(PSS)などで定義された予測誤差評価基準を最小にするように自己選択している。

#### (1) 改良形発見的自己組織化法

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、GMDH 法で用いられている発見的自己組織化法に基づいて、ニューラルネットワークの構造を自己組織化している。以下に改良形発見的自己組織化法について述べる。

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。

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。

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。

最適なニューロン構造の発生。各々の組合せに対して、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。

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。

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。


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、入力変数のすべての組合せを発生させ繰り返し計算し、多層構造を構成していく。

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。

#### (2) CNN とディープ GMDH-type ニューラルネットワークを組み合わせた多層構造

**型 Hybrid 人工 ニューラルネットワーク**  
 CNN とディープ GMDH-type ニューラルネットワークを組み合わせた多層構造型 Hybrid 人工ニューラルネットワークの構造を Fig.1 に示す。ディープ GMDH-type ニューラルネットワークでは、有用な入力変数、中間層の個数、各々の中間層におけるニューロンの個数、最適なニューロンの構造などのディープニューラルネットワークの構造パラメータを、情報量規準(AIC)や予測誤差平方和 (PSS) などの予測誤差評価基準を最小にするように自動的に決定する。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。このため、原データの分割は行わない。



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)

**【第1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。

**【第2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。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**

**i) 1型ニューロン**

$\Sigma$ : (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

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

$f$ : (Nonlinear function)

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

**ii) 2型ニューロン**

$\Sigma$ : (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)

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

**放射基底関数(RBF)型ニューラルネットワーク**

**i) 1型ニューロン**

$\Sigma$ : (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

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

$f$ : (Nonlinear function)

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

**ii) 2型ニューロン**

$\Sigma$ : (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)

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

**多項式型ニューラルネットワーク**

**i) 1型ニューロン**

$\Sigma$ : (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

$$z_k = w_1 u_i + w_2 u_j + w_3 u_k + w_4 u_i u_j + w_5 u_i u_k + w_6 u_j u_k + w_7 u_i^2 + w_8 u_j^2 + w_9 u_k^2 - w_0 \theta_1 \quad (13)$$

$f$ : (Linear function)

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

**ii) 2型ニューロン**

$\Sigma$ : (Linear function)

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

$f$ : (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 $\Sigma$ 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。

次に、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。

**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、 $\phi$ はシステムの出力変数、 $\phi'$ 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。

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。

**総合特性変数( $\phi^*$ )の発生**

総合特性変数( $\phi^*$ )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 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の計算を行う。総合特性変数( $\phi^*$ )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。

### [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。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、(20)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を構成できる。このようにして、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する。

## 4. 研究成果

本研究では、CNN とディープ GMDH-type ニューラルを組み合わせた多層構造型 Hybrid 人工知能アルゴリズムを開発し、腹部の臓器の医用画像認識や医用画像診断に応用した。ここでは、脾臓の医用画像認識やその領域抽出についてその概要を以下に述べる。マルチスライス CT 画像を用い、ディープ GMDH-type ニューラルネットワークの画像認識精度の確認を行うために、従来から用いられている誤差逆伝播法 (BP 法) を用いた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との比較を行った。

### (1) ディープニューラルネットワークの自己組織化

Fig.2 に、ディープ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 CNN で発生させた画像特徴量や従来から用いられている画像特徴量などから構成される 10 個の画像特徴量を用いた。そして、ディープ GMDH-type ニューラルネットワークによって 6 個の画像特徴量が有用な入力変数として自己選択された。ディープニューラルネットワークの構造としては、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 (Fig.3)。画像特徴量の計算に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を自己組織化した。そして  $N$  が 4 の場合に最良の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、脾臓の領域内部では 1 の値を出力するよう学習させた。ディープ GMDH-type ニューラルネットワークの計算は第 8 層で終了した。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第 8 層で非常に小さな値に収束した。




Fig.2 Original image

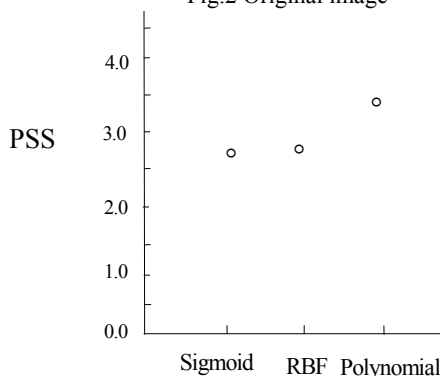


Fig.3 PSS of three types of neurons




Fig.4 Variation of PSS in the deep GMDH-type neural network

### (2) 画像認識結果

自己組織化されたディープ GMDH-type ニューラルネットワークによって脾臓領域が出力された。Fig.5 に最終層 (第 8 層) におけるディープニューラルネットワークの出力画像を示す。脾臓領域が抽出されている。次に出力画像に対して画像の後処理が行われた。ディープ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った。そして脾臓領域の輪郭を  $N/2$  画素分だけ外側に拡張した。Fig.6 に、ディープ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。この画像が

ら、ディープニューラルネットワーク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、脾臓領域を、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(グレー画像)を示す。このような画像処理をほかのスライス全体に対して実行して、レンダリングソフトウェアにより、脾臓領域を3次元表示した。Fig.9に、3次元表示した脾臓領域を示す。



Fig.5 Output image in the eighth layer      Fig.6 Output image after the first post-processing




Fig.7 Overlapped image      Fig.8 Extracted image





Fig.9 The three dimensional image of spleen


### (3)バックプロパゲーション法を用いて学習する従来形ニューラルネットワークによる脾臓領域の画像認識結果

バックプロパゲーション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脾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 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.10に、 $m=5$ 、 $m=7$ と $m=9$ の場合の出力画像を示す。出力画像はディープ GMDH-type ニューラルネットワークの出力画像 Fig.5 に対応している。これらの従来形ニューラルネットワークの出力画像には、孤立点や脾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。従来形のニューラルネットワークでは、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BP法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多くのBP法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 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。



(a)  $m=5$       (b)  $m=7$



(c)  $m=9$

Fig.10 Output images of the conventional sigmoid function neural networks

### (4)まとめ

本研究では、CNNとディープ GMDH-type ニューラルネットワークを組み合わせた多層構造型 Hybrid 人工知能アルゴリズムを提案した。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、有用な入力変数の自己選択能力を備えており、さらに、シグモイド関数型ニューロンとRBF型ニューロンと多項式型ニューロンの3種類のニューロンを用いて対象となる医用画像の特徴に最も適したネットワーク構造を自己組織化できる。また、改良形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、層の個数、中間層のニューロンの個数、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)などの予測誤差評価基準を最小にするように自己選択す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。ここでは脾臓の画像認識問題への応用例を示してその有効性を確認した。



## 5. 主な発表論文等

〔雑誌論文〕(計8件)

Shoichiro Takao, Sayaka Kondo, Junji Ueno, Tadashi Kondo, Deep multi-layered GMDH-type neural network using revised heuristic self-organization and its application to medical image diagnosis of liver cancer, *Artificial Life and Robotics*, Vol.23, No.1, pp.48-59 (2018) 査読有, DOI 10.1007/s10015-017-0392-z

Shoichiro Takao, Sayaka Kondo, Junji Ueno, Tadashi 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) 査読有, DOI 10.1007/s10015-017-0420-z

Shoichiro Takao, Sayaka Kondo, Junji Ueno, Tadashi 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 Symposium on Artificial Life and Robotics 2018 (AROB 23nd 2018)*, pp.84-88, (2018), 査読有.

Shoichiro Takao, Sayaka Kondo, Junji Ueno, Tadashi 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 Symposium on Artificial Life and Robotics 2018 (AROB 23nd 2018)*, pp.89-93, (2018), 査読有.

Tadashi Kondo, Sayaka Kondo, Junji Ueno and Shoichiro 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, pp.1-9, (2017) 査読有, DOI 10.1007/s10015-016-0337-y

Tadashi Kondo, Junji Ueno and Shoichiro Takao, The 3-dimensional medical image recognition of right and left kidneys by deep GMDH-type neural network, *Journal of Bioinformatics and Neuroscience*, Vol.1, No.1, pp.14--23, (2015) 査読有

Tadashi Kondo, Junji Ueno and Shoichiro 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) 査読有, DOI: 10.1007/s10015-015-0213-1

Tadashi Kondo, Junji Ueno and Shoichiro Takao, Deep feedback GMDH-type neural network using principal component-regression analysis and its application to medical image recognition of abdominal multi-organs, *Journal of Robotics Networking and Artificial Life*, Vol.2, No.2, pp.94--99, (2015) 査読有, DOI: 10.2991/jrnal.2015.2.2.6

〔学会発表〕(計6件)

Shoichiro Takao, Sayaka Kondo, Junji Ueno, Tadashi 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, *The twenty-third International Symposium on Artificial Life and Robotics 2018 (AROB 23nd 2018)*, 2018年01月18日-2018年01月20日, B-con Plaza(大分県・別府市).

Shoichiro Takao, Sayaka Kondo, Junji Ueno, Tadashi Kondo, Medical image diagnosis of liver cancer by hybrid deep neural network of deep logistic GMDH-type neural network and convolutional neural network, *The twenty-third International Symposium on Artificial Life and Robotics 2018 (AROB 23nd 2018)*, 2018年01月18日-2018年01月20日, B-con Plaza(大分県・別府市).

高尾正一郎、近藤明佳、上野淳二、近藤正、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た肝臓がんの医用画像診断、医療情報学会・人工知能学会 AIM 合同研究会、2017年11月24日-2017年11月25日、慶應義塾大学(神奈川県・横浜市)

Tadashi Kondo, Sayaka Kondo, Junji Ueno and Shoichiro Takao, Deep multi-layered GMDH-type neural network using revised heuristic self-organization and its application to medical image diagnosis of liver cancer, *The twenty-second international symposium on artificial life and robotics (AROB 22nd 2017)* 2017年01月19日-2017年01月21日, B-con Plaza(大分県・別府市)

Tadashi Kondo, Junji Ueno and Shoichiro Takao, Medical image analysis of abdominal X-ray CT images by deep multi-layered GMDH-type neural network, *The Twenty-First International Symposium on Artificial Life and Robotics (AROB 21st 2016)*, 2016年01月20日-2016年01月22日, B-con Plaza(大分県・別府市)

Tadashi Kondo, Junji Ueno and Shoichiro Takao, The 3-dimensional medical image recognition of right and left kidneys by deep GMDH-type neural network, *International Conference on Intelligent Informatics and Biomedical Sciences*, 2015年11月28日-30日, 沖縄科学技術大学院大学(沖縄・国頭郡恩納村)

## 6. 研究組織

(1)研究代表者

上野 淳二(UENO, Junji)

徳島大学・大学院医歯薬学研究部・教授

研究者番号: 60116788

(2)研究分担者

近藤 正(KONDO, Tadashi)

徳島大学・大学院医歯薬学研究部・名誉教授

研究者番号: 80205559