

科学研究費助成事業 研究成果報告書

平成 27 年 6 月 3 日現在

機関番号：16101

研究種目：基盤研究(C)

研究期間：2012～2014

課題番号：24560497

研究課題名(和文)新しい人工知能技術を用いた腹部X線CT画像解析と診断支援

研究課題名(英文)Abdominal CT image analysis and computa assisted diagnonsis with new artificial intelligence

研究代表者

上野 淳二(UENO, Junji)

徳島大学・ヘルスバイオサイエンス研究部・教授

研究者番号：60116788

交付決定額(研究期間全体)：(直接経費) 2,400,000円

研究成果の概要(和文)：本研究では、腹部の多列検出器型CT(MDCT)画像を対象にして新しい人工ニューラルネットワークの理論(Revised GMDH-type Neural Network)を開発し、腹部の臓器の高精度な画像領域抽出と肝臓癌を対象にしたコンピュータ支援画像診断(CAD)システムの開発を行った。本研究で開発したニューラルネットワークでは、医用画像の複雑さに適するように情報量基準(AIC)または予測誤差平方和(PSS)を用いてネットワーク構造を自動的に自己組織化できる。また、学習理論に主成分回帰分析法を用いることにより高精度なパラメータ推定を行った。そして、肝臓癌の画像診断へ応用しその有効性を確認した。

研究成果の概要(英文)：In this study, new artificial neural network algorithms which are called as revised Group Method of Data Handling (GMDH)-type neural network algorithms, were proposed and we applied these algorithms to the medical image diagnosis of the liver cancer and the medical image recognition of abdominal multi-organs, and we developed the computer aided diagnosis (CAD) system using abdominal multi-detector row CT images. In this neural network algorithms, the principal component-regression analysis method is used to learn the weights of the neural networks and the neural network architectures are automatically organized using the prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS) so as to fit the complexity of the medical images. In this study, we applied new neural network algorithms to the medical image diagnosis of liver cancer and it was shown that new neural networks were useful to the medical image diagnosis of liver cancer.

研究分野：放射線診断学

キーワード：人工ニューラルネットワーク GMDH マルチスライスCT コンピュータ支援診断

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 (2 次元画像) 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。このような状況を解決するために、コンピュータを用いて大量に発生する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ていた。

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、データ解析手法である多変量解析を学習理論に用いた新しい人工ニューラルネットワークの理論 Group Method of Data Handling-type neural network algorithm (以下 GMDH-type neural network algorithm) を開発し、腹部の臓器の高精度な画像領域抽出と肝臓癌を対象にしたコンピュータ支援画像診断 (CAD) システムの開発を行った。

3. 研究の方法

本研究では、医用画像診断用に開発された新しいタイプの GMDH-type neural network algorithm を用いて、複雑な特性を示す腹部の MDCT 画像を対象にして画像診断を行う人工ニューラルネットワークをコンピュータ内部に自己組織化させて、腹部の多臓器の高精度な領域抽出と、肝臓癌などを対象にした画像診断支援システムを開発した。本研究で開発した改良形 GMDH-type ニューラルネットワークスのアルゴリズムの 1 例を以下に示す。

改良形 GMDH-type ニューラルネットワークスの構造を Fig.1 に示す。フィードバックループの計算回数、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)または予測誤差平方和(PSS)を最小にするように決定される。このニューラルネットワークスはフィードバックループを備えており、このフィードバックループを用いた計算により、徐々にネットワークの複雑さを増加させる。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、情報量基準(AIC)または予測誤差評価基準(PSS)を用いているので

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。




Fig.1 Architecture of the revised GMDH-type neural network

(1) 最初のフィードバックループ計算
入力層

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

ここで、 x_j はシステムの入力変数を示す。

中間層

入力変数どうしを組み合わせ、多くの組み合わせを発生させる。ニューロンはタイプ 1 とタイプ 2 の 2 種類を用い、ニューラルネットワークス構造の種類によってニューロンの構造が異なる。

<シグモイド関数型ニューラルネットワークス>

i) The first type neuron

Σ : (Nonlinear function)

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

f : (Nonlinear function)

$$y_k = 1 / (1 + \exp(-z_k)) \quad (3)$$

ii) The second type neuron

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_1 \quad (r < p) \quad (4)$$

f : (Nonlinear function)

$$y_k = 1 / (1 + \exp(-z_k)) \quad (5)$$

<Radial Basis Function(RBF)型ニューラルネットワークス>

i) The first type neuron

Σ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_1 \quad (6)$$

f : (Nonlinear function)

$$y_k = \exp(-z_k^2) \quad (7)$$

ii) The second type neuron

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_l \quad (r < p) \quad (8)$$

f : (Nonlinear function)

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

<多項式型ニューラルネットワークス>

i) The first type neuron

Σ : (Nonlinear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + w_4 u_4 + w_5 u_5 - w_0 \theta_l \quad (10)$$

f : (Linear function)

$$y_k = z_k \quad (11)$$

ii) The second type neuron

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_l \quad (r < p) \quad (12)$$

f : (Linear function)

$$y_k = z_k \quad (13)$$

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。ニューロンの重み w の値は、主成分回帰分析を用いて次のように推定する。

<AIC または PSS を用いた主成分回帰分析による重み 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

$$z_k^{**} = \log_e(\phi' / (1 - \phi')) \quad (14)$$

ii) RBF 型ニューロン

$$z_k^{**} = (-\log_e \phi')^{1/2} \quad (15)$$

iii) 多項式型ニューロン

$$z_k^{**} = \phi \quad (16)$$

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。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。

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。

$$\underline{v} = C \cdot \underline{u} \quad (17)$$

ここで、

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

$$\underline{u} = (u_1, u_2, u_3, u_4, u_5)$$

\underline{v} は固有ベクトル、 C 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。

$$R \cdot C = C \cdot A \quad (18)$$

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。

$$z_k = \underline{W}^T \cdot \underline{V} = W_1 V_1 + W_2 V_2 + \dots + W_5 V_5 \quad (19)$$

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を用いて有益な主成分のみを選択する。

次に、構成した 3 種類の各々のニューロンに対して、AIC または 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を次層の入力変数にセットして、出力層の計算に移る。

出力層

出力層では、中間層の出力値 y_k を線形結合する。

$$\phi^* = a_0 + \sum_{k=1}^L a_k y_k \quad (20)$$

ここで、 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、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自己選択する。2 番目以後のフィードバックループ計算では、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。

(2) 2 番目以後のフィードバックループ計算

2 番目以後のフィードバックループ計算では、出力値 ϕ^* をシステムの入力変数 x_j ($j=1, 2, \dots, p$) と組み合わせる。そして、多くの組み合わせを発生させて、第 1 番目のフィードバックループ計算と同じ手続きを繰り返す。(20)式の AIC または PSS 値が減少しなくなった層で、フィードバックループ計算を停止し、全体のニューラルネットワークスを構成する。

以上の手続きによりフィードバックループを持つ改良形 GMDH-type ニューラルネットワークスを構成できる。

4. 研究成果

本研究では、開発した改良形 GMDH-type ニューラルネットワークスを組み込んだ CAD システムを用いて、肝臓癌の画像診断や腹部のいろいろな臓器のコンピュータによる画像認識とその領域抽出などを行った。ここでは、肝臓癌の医用画像診断への応用について示す。

肝臓癌の医用画像診断への応用

本研究では、開発した改良形 GMDH-type ニューラルネットワークスを用いて、肝臓癌の画像診断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改良形 GMDH-type ニューラルネットワークス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癌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

後処理することにより、肝臓癌の候補領域を抽出した。予測誤差評価基準としてはAICを用いた。

肝臓領域の抽出と肝臓癌の候補領域の抽出

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 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。




Fig.2 Original image

改良形 GMDH-type ニューラルネットワークは、ニューラルネットワーク構造として RBF(Radial Basis Function)型ネットワーク構造を選択した。Fig.3 に、計算された 3 種類のニューロンの誤差を示す。改良形 GMDH-type ニューラルネットワークの計算は第 7 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 AIC 値の変化を示す。フィードバックループ計算を重ねることにより AIC 値は徐々に減少して小さな値に収束した。

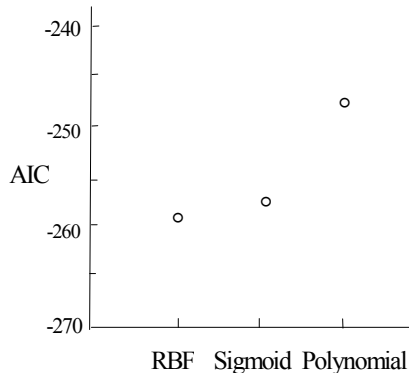


Fig.3 AIC values of three kinds of neurons (1)




Fig.4 Variation of PSS in the revised GMDH-type neural network(1)

自己組織化された改良形 GMDH-type ニューラルネットワークによって肝臓領域が出力された。フィードバックの計算を行うことによって肝臓領域が徐々に抽出される。Fig.5 に、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、画像の膨張処理と収縮処理などを行い、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、肝臓領域の輪郭を $N/2$ 画素分だけ外側に拡張して正常な肝臓領域を抽出した。Fig. 6 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.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、得られた肝臓領域を、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。次に、Fig.6 に対して 2 回目の画像の後処理を行い、正常でない領域も含めた肝臓領域を Fig.9 のように抽出した。そして、原画像 (Fig.2) から、後処理後の画像 (Fig.9) を差分することによりグレー画像を抽出した (Fig.10)。Fig.10 から Fig.8 を差分することにより、肝臓癌の候補領域を抽出した (Fig.11)。

本研究では、改良形 GMDH-type ニューラルネットワークを用いて、肝臓癌の候補領域を抽出した。これらの出力結果は、誤差逆伝播法 (BP 法) を用いて学習を行う従来形の人工ニューラルネットワーク (シグモイド関数型人工ニューラルネットワーク) の出力結果との比較を行い、改良形 GMDH-type ニューラルネットワークの出力結果が、高精度であることを確認した。また、医用画像の複雑さに適した人工ニューラルネットワークの構造が、AIC または PSS を用いて自動的に自己組織化できるので、応用が非常に容易であるという特徴がある。




Fig. 5 Output image of the revised GMDH-type NN




Fig. 6 Output image after the first post processing



Fig. 7 Overlapped image




Fig. 8 Extracted image (1)



Fig.9 Output image after the second post processing




Fig. 10 Extracted image (2)



Fig.11 Extraction of the candidate image region of liver cancer

むすび

本研究では、人工ニューラルネットワークの学習に主成分回帰分析を用いてパラメータ(シナプスウエイト)の高精度な推定を行い、人工ニューラルネットワークの構造は医用画像の複雑さに適するように情報量基準(AIC)または予測誤差平方和(PSS)を用いて自動的に自己組織化を行うことができる改良形 GMDH-type ニューラルネットワークスのアルゴリズムを提案した。この人工ニューラルネットワークは、医用画像の複雑さに適したニューラルネットワークの構造を自己組織化する能力を備えており、一般的に、医用画像に適用した場合は中間層を多数備えた複雑な構造をしたニューラルネットワーク構造を自己組織化できる。この改良形 GMDH-type ニューラルネットワークスのアルゴリズムは、シグモイド関数型ニューラルネットワーク、ラジアルベース関数型ニューラルネットワーク、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の中からニューラルネットワーク構造を自己選択し、対象となる医用画像の特徴に最も適したニューラルネットワーク構造を自己組織化している。また、発見的自己組織化の原理を用いて、フィードバック計算の回数、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 AIC または PSS 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。本研究では、肝臓癌の画像診断へ応用して従来手法(BP 法を用いて学習を行うシグモイド関数型人工ニューラルネットワーク)によって得

られた結果と比較することによりその有効性を確認した。

5. 主な発表論文等

〔雑誌論文〕(計 11 件)

(1) Kondo T., Ueno J., Takao S., Medical image diagnosis of kidney regions by deep feedback GMDH-type neural network using principal component-regression analysis. Proceedings of the twentieth international symposium on artificial life and robotics 2015, pp.424-427 (2015) 査読有

(2) Kondo T., Ueno J., Takao S., Deep feedback GMDH-type neural network using principal component-regression analysis and its application to medical image recognition of abdominal multi-organs, Proceedings of international conference on artificial life and robotics (ICAROB 2015), pp.119-122 (2015), 査読有

(3) Kondo T., Ueno J., Takao S., Medical image recognition of abdominal multi-organs by hybrid multi-layered GMDH-type neural network using principal component-regression analysis, Proceedings of 2014 second international symposium on computing and networking, pp.157-163 (2014) 査読有, DOI 10.1109/CANDAR2014.62

(4) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by RBF GMDH-type neural network using principal component-regression analysis, ICIC Express Letters (ICIC-EL), Vol.8, pp.851-858 (2014) 査読有

(5) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by hybrid feedback GMDH-type neural network using principal component-regression analysis, Proceedings of the nineteenth international symposium on artificial life and robotics, pp.339-342 (2014) 査読有

(6) Kondo T., Ueno J., Takao S., Hybrid multi-layered GMDH-type neural network using principal component-regression analysis and its application to medical image diagnosis of liver cancer. Procedia Computer Science, Vol.22, pp.172-181 (2013) 査読有

(7) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by multi-layered GMDH-type neural network using principal component-regression analysis and PSS criterion, Proceedings of the 44th ISCIE international symposium on stochastic systems theory and its applications, pp.255-262 (2013) 査読有

(8) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by hybrid feedback GMDH-type neural network using heuristic self-organization, ASE Science Journal, Vol.1, pp.12-21 (2012) 査読有

(9) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by feedback

GMDH-type neural network using knowledge base, Artificial Life and Robotics, Vol.17, No.3-4, pp.488-494 (2012) 査読有

(10) Kondo T., Ueno J., Takao S., Hybrid multilayered GMDH-type neural network self-selecting various neurons and its application to medical image diagnosis of liver cancer, Proceedings of international conference SCIS-ISIS 2012, pp.1919-1924, (2012) 査読有

(11) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by revised GMDH-type neural network using feedback loop calculation, Proceedings of 2012 sixth international conference on genetic and evolutionary computing, pp.237-240, (2012) 査読有

〔学会発表〕(計 14 件)

(1) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by hybrid feedback GMDH-type neural network using heuristic self-organization, 2012 ASE International conference on biomedical computing, 2012 年 12 月 14 日 ~ 2012 年 12 月 16 日, Hilton Alexandria Mark Center (Washington D.C., U.S.A)

(2) Kondo T., Ueno J., Takao S., Medical image diagnosis of liver cancer by multi-layered GMDH-type neural network using principal component-regression analysis and PSS criterion, The 44th ISCIE International Symposium on Stochastic Systems Theory and Its Applications, 2012 年 11 月 1 日 ~ 2012 年 11 月 2 日, Kokushikan University (東京都 世田谷区)

6. 研究組織

(1) 研究代表者

上野 淳二 (UENO, Junji)

徳島大学・大学院ヘルスバイオサイエンス研究部・教授

研究者番号：60116788

(2) 研究分担者

近藤 正 (KONDO, Tadashi)

徳島大学・大学院ヘルスバイオサイエンス研究部・教授

研究者番号：80205559