

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

長瀬 永遠

富山県立大学 情報基盤工学講座

May 10, 2023

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

目的

ディープ GMDH-type ニューラルネットワークには以下のようないくつかのアルゴリズムが存在する.

- 多層構造型アルゴリズム
- フィードバック型アルゴリズム
- ロジスティック型アルゴリズム

本研究ではこれらを用いることでいろいろな臓器の医用画像認識問題を解決する.

改良形発見的自己組織化法の手順 1

- 1 原データをトレーニングデータとテストデータに分割
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推定, 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使用
- 2 入力変数の組合せ発生
すべての入力変数の組合せを発生
- 3 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た回帰分析を行い, 最適なニューロン構造を発生. 発生したニューロンの出力を中間変数という
- 4 中間変数の自己選択
テストデータに対する誤差を小さくする L 個の中間変数を自己選択

はじめに

改良形発見的自己組織化法

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
用いたハイブリッド型ディープ
ニューラルネットワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

改良形発見的自己組織化法の手順 2

- 5 総合特性変数の発生
 L 個の中間変数を用いて、トレーニングデータによる回帰分析を行い、総合特性変数を発生
- 6 多層構造の構成
 L 個の中間変数と総合特性変数を次層の入力にセットし、同様の手順を繰り返すことで多層構造を構成
- 7 多層構造の繰り返し計算の停止
繰り返し計算はテストエラーが減少しなくなった時点で停止

はじめに

改良形発見的自己組織化法

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
用いたハイブリッド型ディープ
ニューラルネットワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

本手法では CNN とフィルタリングによって画像特徴量を発生させることで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の入力変数とする。

CNN を用いた画像特徴量の抽出



はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

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 1

6/17

最初のフィードバックループ計算 1

[入力層]

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

x_j はシステムの入力変数

[中間層]

入力変数同士を組み合わせて、すべての組み合わせを発生させる。各変数の組み合わせでは、3種類のニューロン構造を発生させる。さらに、各ニューロン構造では、非線形結合の1型と線形結合の2型の2種類のニューロンを用いる。これら6種類のニューロン構造から対象となる非線形システムに最も適した構造を予測誤差が最小になるように自己選択する。

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

最初のフィードバックループ計算 2

- ・シグモイド関数型ニューラルネットワークス
(1 型ニューロン構造)

Σ : (Nonlinear function)

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

or

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

f : (Nonlinear function)

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

- (2 型ニューロン構造)

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_l \quad (r < p) \quad (5)$$

f : (Nonlinear function)

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

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

最初のフィードバックループ計算 3

- ・放射基底関数 (RBF) 型ニューラルネットワークス
(1 型ニューロン構造)

Σ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_l \quad (7)$$

or

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

f : (Nonlinear function)

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

- (2 型ニューロン構造)

Σ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_l \quad (r < p) \quad (10)$$

f : (Nonlinear function)

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

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

最初のフィードバックループ計算 4

・多項式型ニューラルネットワークス

(1 型ニューロン構造)

Σ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_l \quad (12)$$

or

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

f : (Linear function)

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

(2 型ニューロン構造)

Σ : (Linear function)

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

f : (Linear function)

$$\begin{aligned} y_k &= z_k & (z_k > 0 \text{ の場合}) \\ y_k &= 0 & (z_k < 0 \text{ の場合}) \end{aligned} \quad (16)$$

最初のフィードバックループ計算 5

各ニューロンは \sum と f の 2 個の関数から構成される. w はニューロンの重み係数, p は入力変数の個数を示す.

また, 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, 各ニューロンに対して z_k^{**} の値を計算する.
(シグモイド関数型ニューロン)

$$z_k^{**} = \log_e(\phi'/(1 - \phi')) \quad (17)$$

(RBF 型ニューロン)

$$z_k^{**} = (-\log_e \phi')^{1/2} \quad (18)$$

(多項式型ニューロン)

$$z_k^{**} = \phi \quad (19)$$

最初のフィードバックループ計算 6

ϕ はシステムの出力変数, ϕ' は 0 から 1 の間に基準化された出力変数を示す.

重み w は z^{**} を出力変数にして主成分回帰分析を用いてもとめる.

[出力層]

出力層では前述の 3 種類のニューラルネットワークに対して, 以下の線形結合式を用いて総合特性変数 (ϕ^*) を計算する.

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

L は中間層の個数, y_k は中間変数を示す. y_k は情報量基準 (AIC) または予測誤差平方和 (PSS) を用いた変数選択型重回帰分析により, AIC または PSS 値が小さいものを自己選択する. 次に, (20) 式の AIC または PSS 値が小さいニューロン構造を 3 種類の構造の中から自己選択する.

2 番目以降のフィードバックループ計算

総合特性変数 (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. すべての組合せを発生させ, 最初のフィードバックループと同様の処理を AIC または PSS 値が減少しなくなるまで繰り返す. この際, ニューロン構造は最初のフィードバックループ時に自己選択した構造のみを用いる.

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

本研究では図 1 のような CT 画像を用いて肝臓領域の画像認識を行った．予測誤差の評価基準は PSS を用いた．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． N の大きさは 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．出力変数は 0 か 1 の値をとり，肝臓領域内部で 1 の値を出力するように学習させた．

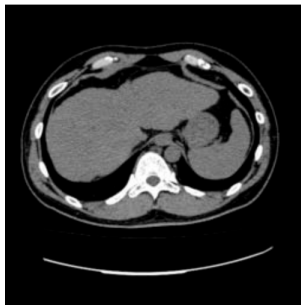


図 1: 学習に用いた原画像（腹部）

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッド
型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

入力変数の近傍領域の値は $N = 5$ のときに最も精度の高い結果が得られた。

CNN の結果からは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 5 個の画像特徴量が発生し、これらに従来使用されている統計学的特徴量（平均値、分散、標準偏差）、位置情報（ x 座標、 y 座標）を加えた 10 個の特徴量を入力変数とした。

最初のフィードバック計算で選択された有力な入力変数は平均値、標準偏差、分散、 x 座標、 y 座標、範囲（レンジ）、最大値フィルタの出力の 7 個と自己選択された。

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッド
型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに

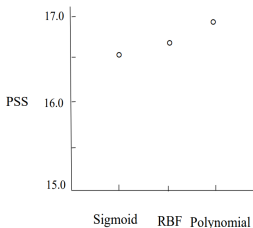


図 2: 最初のフィードバックループで計算された各構造の PSS 値

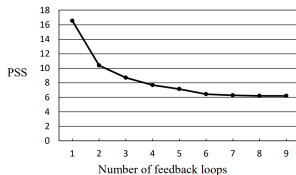


図 3: 各層における PSS 値の変化

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに



図 4: 出力結果

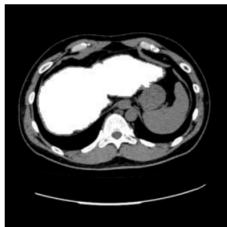


図 5: 後処理を行った出力結果と原画像の重ね合わせ

まとめ

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 を用いて、腹部の X 線 CT 画像の医用画像解析を行った。

今後の展望

CNN の学習には多くの医用画像が必要になるため、これらを準備して CNN の学習を行い CNN で発生させた画像特徴量を入力変数として加えることによりより高い精度を目指す。

はじめに

改良形発見的自己
組織化法

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
用いたハイブリッ
ド型ディープ
ニューラルネット
ワーク

X 線 CT 画像の
医用画像解析への
応用

おわりに