

# 琉球大学学術リポジトリ

## 進化的ニューラルネットワークを用いたモートセンシング画像の分類

メタデータ	言語: 出版者: 琉球大学工学部 公開日: 2010-02-16 キーワード (Ja): キーワード (En): Neural network, Backpropagation, Genetic algorithm, Remotely sensed image, Classification 作成者: 名嘉, 靖, 曾, 湘燕, 陳, 延偉, 仲尾, 善勝, Naka, Yasushi, Zeng, Yanien, Chen, Yen-Wei, Nakao, Zensho メールアドレス: 所属:
URL	<a href="http://hdl.handle.net/20.500.12000/15647">http://hdl.handle.net/20.500.12000/15647</a>

# 進化的ニューラルネットワークを用いたリモートセンシング画像の分類†

名嘉 靖\* 曾 湘燕\* 陳 延偉\* 仲尾 善勝\*

## Classification of Remotely Sensed Images Based on an Evolutionary Neural Network†

Yasushi NAKA, Yanien ZENG, Yen-Wei CHEN, and Zensho NAKAO

### Abstract

An evolutionary neural network is proposed for classification of remotely sensed images. In the proposed neural network, the neuron number of the hidden layer is optimized by use of the genetic algorithm. The simulation results show that the proposed neural network is efficient for classification of remotely sensed images.

**Keywords:** Neural network, Backpropagation, Genetic algorithm, Remotely sensed image, Classification

### 1. はじめに

今日、地球環境問題は世界的に大きな関心を呼んでいる。酸性雨、森林の破壊、砂漠化の進行、地球の温暖化、オゾン層の破壊、海洋汚染などによってもたらされる地球全体の環境汚染の状況や気象状態、地球表面上の土地の利用区分などの環境監視の有力な手段は人工衛星から観測され地球へ送られてくる画像である。このような遠隔地の情報を探ることをリモートセンシング（遠隔計測）といい、地球表面上の状況を的確にとらえる為には、リモートセンシング技術の利用が不可欠である。リモートセンシングで得られる多量分光データから土地利用、環境調査、資源探索、災害調査などの各種情報を抽出する手段として分類処理は広く利用されている[1]。リモートセンシング画像の分類とは画像中の各画素がどのクラス(森林、海域、市街地など)に属するか識別し、分類することである。画像が与えられ、その中の対象物を分類するための情報としては、スペクトル、形状、テクスチャ（きめ）などがある。リモートセンシングにおいて、森林、海域、市街地などの各クラスへの分類は、主として各画素におけるスペクトル、すなわち各バンドの分光輝度値を用いて行う。各クラスのスペクトルが異なるので、複数のバンドの分光輝度値を調べれば、その画素がどのクラスに属しているかを判別できる。

これまで、リモートセンシング画像の分類には、最尤法や最短距離法などが用いられてきた[2]。これらの方法は、複数のバンドでできている特徴空間を分割して各クラスに対応させて判別を行う。

しかし、これらは各クラスが正規分布に従うとして分類を行っているため誤判別が度々生じる。

この誤判別を減少させるために、ニューラルネットワークによる分類法が提案され、その有効性が示されてきた[3]。また、ニューラルネットワークの学習には、BP(Back Propagation)法[4]や遺伝的アルゴリズム(GA:Genetic Algorithm)[5]等が用いられてきた。しかし、ニューラルネットワークは、内部構造を形成する中間層ニューロン数によって学習時間や制度などに差があるためニューラルネットワークの中間層ニューロン数の最適化が重要になってくる。

そこで、今回我々は、進化的ニューラルネットワークというものを提案し、リモートセンシング画像の分類を行う。これは、ニューラルネットワークの中間層ニューロン数を遺伝的アルゴリズム(GA)を用いて最適化を行う手法である。

### 2. リモートセンシング画像の分類

まず、進化的ニューラルネットワークを構築し、分類に用いるリモートセンシング画像の各画素を赤・青・緑のバンド別に分けたそれぞれの画像を学習されたニューラルネットワークの入力層から入力し、出力層で各クラスに分類する。その例を図1に示す。




図1 画像分類の例

受理日：1999年6月7日

†本論文は第2回ファジ学会九州支部研究会にて発表済

\*工学部電気電子工学科

(Dept. of Electrical and Electronics Engineering, Fac. of Eng.)

ニューラルネットワークの学習には、トレーニングデータ（森林や市街地などの各クラスからのサンプル点の分光輝度値）と教師信号（望ましい出力値）を用いて各層間の重み係数を更新していき誤差の少ない出力値を得ることができる誤差逆伝播法(BP法:Back propagation)を用いて、画像分類に最適な構造をもったネットワークを構築する。

### 3. 進化的ニューラルネットワーク

進化的ニューラルネットワークとは、学習により入力情報を認識することができるニューラルネットワークの中間層ニューロン数を探索・最適化アルゴリズムの一つである遺伝的アルゴリズムを用いて最適な中間層ニューロンの数を探索し、決定するネットワークである。今回、リモートセンシング画像分類に最適なニューラルネットワークの構造を遺伝的アルゴリズムにより最適化してから、その構造の下で通常のニューラルネットワークの学習を行い、画像の分類を行う。

#### 3.1 ニューラルネットワーク

ニューラルネットワークとは生物の脳神経細胞の働きを数学的にモデル化したものである[4]。今回、ニューラルネットワークの学習に誤差逆伝播法(BP法)を用いて入力データに対して誤差の少ない出力を得ることができるネットワークを構築し、画像の分類を行うことを目的としている。図2にBP法の例を示す。

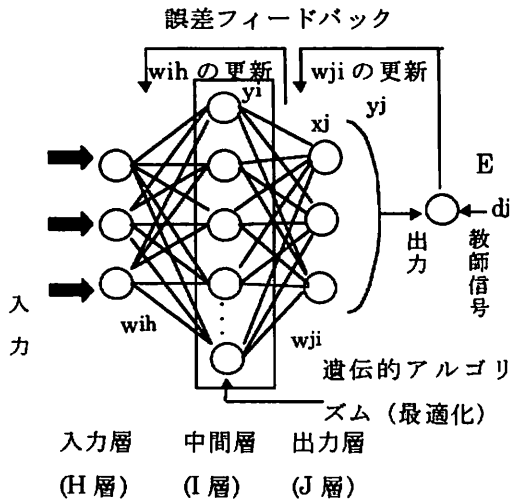


図2 誤差逆伝播法(BP法)

今回、分類に用いる画像を画像の三要素でもある赤、緑、青の三つの画像に分類し、それぞれの画像をバンド1、2、3として入力するので入力層ニューロン数を3つに設定し、分類するクラスを3つにするので出力層ニューロン数を3つに設定する。そして、中間層ニューロン数を遺伝的アルゴリズムで最適化を行い、設定する。

入力データ（画像から求められた各バンドの分光

輝度値）を与えたとき、ネットワークの入出力関係は次のような式で示される。

$$x_i(t) = \sum_h y_h(t) w_{ih}(t) \quad (1)$$

$$y_i(t) = \frac{1}{1 + \exp\{-x_i(t) + \theta_i(t)\}} \quad (2)$$

$$x_j(t) = \sum_i y_i(t) w_{ji}(t) \quad (3)$$

$$y_j(t) = \frac{1}{1 + \exp\{-x_j(t) + \theta_j(t)\}} \quad (4)$$

ここで  $X_i$  は I 層（中間層）  $i$  番目の総入力、  $y_i$  は I 層  $i$  番目の出力、  $\theta_i$  はニューロン  $i$  のしきい値、  $y_h$  はニューロン  $i$  の入力側に結合した入力層（H層）ニューロン  $h$  の出力、  $w_{ih}$  はニューロン  $i$  と  $h$  の結合の重みである。また  $X_j$  は J 層（出力層）  $j$  番目の総入力、  $y_j$  は J 層  $j$  番目の出力、  $\theta_j$  は出力層ニューロン  $j$  のしきい値、  $w_{ji}$  はニューロン  $i$  と  $j$  の結合の重み、  $t$  は学習回数である。

入力パターン(バンド1, 2, 3)を与えたとき、実際の出力値  $y_j$  と望ましい出力値を  $d_j$  (1: 属するクラス, 0: 属さないクラス)とすると、その誤差は次式で表される。

$$E(t) = \frac{1}{2} \sum_j \{y_j(t) - d_j\}^2 \quad (5)$$

式(5)に入出力関係の式(1)~(4)を代入し、ネットワークの誤差を最小化するために  $w(t)$  に対する  $E(t)$  の変化率  $(\partial E / \partial w)$  を求め、その値を用いた BP 法の重みを変換する式(6)により重み係数を更新し、誤差を漸近的にゼロに近づけることができる。

$$\Delta w(t) = -\eta \frac{\partial E(t)}{\partial w(t)} + \alpha \Delta w(t-1) \quad (6)$$

ここで、 $\eta$  は学習定数で学習速度を調整する。 $\alpha$  は 1 回前の変更量に対する正定数で、前回の重みの値を使い、収束時の振動を抑える効果がある。また、最小二乗誤差を求める式を次式で示す。

$$mse = \frac{1}{N \cdot M \cdot P} \{y_j(t) - d_j\}^2 \quad (7)$$

ここで、 $N \cdot M$  はトレーニングデータの大きさを表し、 $P$  は出力層ニューロンの数である。

そして、終了条件を満たすと学習を終了する。このようにして、目的とする構造を持ったネットワークを構築できるので入力画像に対する分類を行うことができる。

#### 3.2 GA による中間層ニューロン数の決定

前述のように、学習の精度や収束速度は中間層ニューロン数に依存しているので、中間層ニューロン数の最適化が必要である。そこで、中間層ニューロン数の最適化に遺伝的アルゴリズムを用いる。

遺伝的アルゴリズム(GA : Genetic Algorithm)とは、自然界における生物の進化とそれを構成している遺伝の仕組みを情報処理モデルとしたもので、目的とする値を高速に求める最適化、探索アルゴリズムである[6].

今回、この GA をニューラルネットワークの中間層を決定するのに用いた。遺伝的アルゴリズムによる中間層ニューロン数の決定手順を以下に示す。

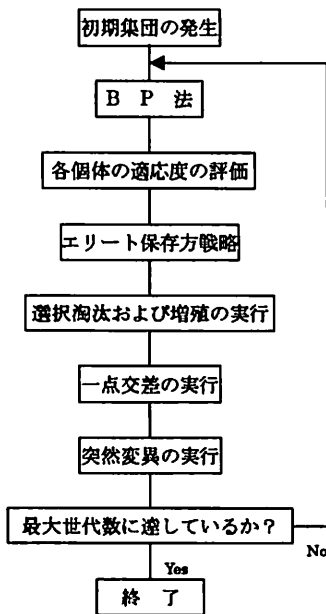


図3 GA の処理手順

### 3.3 初期集団の発生

遺伝的アルゴリズムを用いてニューラルネットワークの中間層ニューロン数の最適化を行うので、中間層ニューロン数を 6 ビットの 2 進数表現で表わし、各ビットに対して 0 か 1 をランダムに発生させて一つの個体として生成する。これをいくつか形成して初期集団として発生させる。その例を図 4 に示す。そして、その個体の値を BP 法に定義して誤差の値を調べる。




図4 初期集団の発生

### 3.4 適応度の評価

BP 法に初期集団の値を中間層ニューロン数として、それぞれ定義し、その値が良いのかどうか評価する必要があります。そこで各個体を評価する関数を以下に示す。

$$fitness = \frac{1}{1 + \alpha \times mse} + \beta \times \exp\left\{\frac{H^2}{A}\right\} \quad (8)$$

ここで  $\alpha$ ,  $\beta$ ,  $A$  は定数である。そして  $mse$  は BP 法で求められた最小二乗誤差値、 $H$  はその時の中間層ニューロン数を示している。この評価関数は最小二乗誤差値と中間層ニューロン数が小さいほど適応度の値が高くなるように設定できるので、目的とする処理を行うのに最適な値、または最適なものに十分近い値に対して適応度を高くすることができる。この関数により各個体を評価していく。

### 3.5 エリート保存型戦略

各個体を評価し、淘汰および増殖を行い適応度の低い個体を適応度の高い個体に置き換える処理をする場合、低い確率ではあるが適応度の一番高い個体が消滅する可能性がある。そこでエリート保存型戦略というものをを用いる。これは、適応度の一番高い個体を次世代の  $N+1$  番目の個体として保存し、加えるというものである。その例を図 5 に示す。これにより適応度の一番高い個体が残るので有効な手法である。

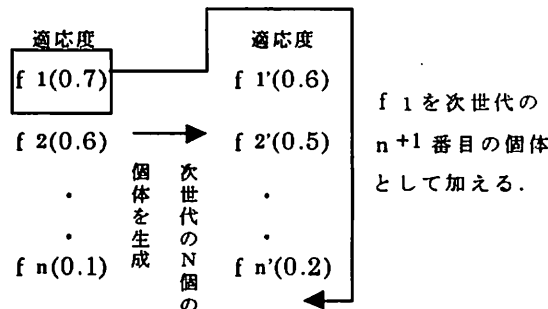


図5 エリート保存型戦略

### 3.6 一点交差の実行

一点交差とは、生成された  $N$  個の個体の中からランダムに 2 つの個体ペアを  $M$  組みだけ選択し、個体の情報を変化させるものである。その例を図 6 に示す。




図6 一点交差

一点交差は、二つの個体の遺伝子型をランダムな位置で部分的に入れ替えを行う操作であり、個体の情報を変化させることができる。

### 3.7 突然変異の実行

突然変異とは、各個体の遺伝子型である各ビットを突然変異の生起確率に従い、0 を 1、1 を 0 に変換する操作である。その例を図 7 に示す。




図7 突然変異

以上の操作を行うことで、広域的な探索が可能になる。

4 シミュレーション結果とトレーニング結果

今回、ニューラルネットワークの中間層ニューロン数を最適化するために用いた GA の処理設定を表1に示す。

遺伝子型	2進数表現
遺伝子長	6ビット
最大世代数	30
淘汰・増殖	ルーレット選択方式
一点交差率	0.7
突然変異率	0.1

表1：GA の処理設定

この処理設定に従い、最適な中間層ニューロン数を探索した結果、H=9 の値が最適な値であるという結果が出た。実際に H=9 が最適な値かどうか他の中間層ニューロン数の場合と比べてときの BP 法の学習に対する誤差の収束を示したシミュレーション結果を図8に示す。




図8 シミュレーション結果

H=15 と H=9 は、ほぼ同じだがこの場合、ニューロン数が少ないほうがいいので H=9 が選択されている。また、H=7 と比べると学習回数が H=9 のほうが少なく、初期の段階で多少、誤差の値に差があるので H=9 が選ばれている。よって、シミュレーション結果より GA により最適化されたといえる。次に、学習回数による適応度関数の値の変化を示したトレーニング結果を図9に示す。




図9 トレーニング結果

学習回数が進むにつれて適応度関数の値が上がっていることがわかる。適応度関数の値は、最小二乗誤差の値が小さいほど大きくなるので BP 法の学習により誤差が小さくなっていることがわかる。このことから BP 法により誤差の少ないネットワークが構築されていくことがわかる。

5 リモートセンシング画像の分類結果

進化的ニューラルネットワークにより構築されたネットワークを用いて画像分類をした結果を以下に示す。図10は入力画像であり赤、緑、青のバンド別に分けた3枚の画像をネットワークの入力層ニューロンからそれぞれ1画素ずつ入力して分類を行う。その分類結果を図11に示す。図11は出力画像でクラス1が平地、クラス2が道路や道路と同じ性質を持った建物や広場などの市街地、クラス3がそれ以外の家屋や建物である。分類された画像は白い部分が分類された画素を表わしている。分類結果からクラス別に分類されているのがわかる。この結果から、ニューラルネットワークによるリモートセンシング画像の分類ができることがわかる。

6 まとめ

進化的ニューラルネットワークを用いることでニューラルネットワークの中間層ニューロン数を最適化できるので良い構造をもったネットワークを構築することができるので効率的であり、また、以上の結果からその有効性を示すことができた。


今後の課題として、従来法など他の分類法と比べてみてどのような違いがあるか比較、検討していくこと、分類するクラスのオブジェクトに対する分光輝度値の値などを詳しく調べて、より信頼性の高いサンプルデータとしてニューラルネットワークの学習に用いること、必要に応じて現地調査などを行い、より信頼性の高いデータとして提供することなどがあげられる。



a : バンド 1 (赤)




クラス 1 (平地)



b : バンド 2 (緑)



クラス 2 (市街地)



c : バンド 3 (青)



クラス 3 (家屋・建物)

図 10 入力画像

図 11 出力画像

参考文献

[1] 日本リモートセンシング研究会編：“画像の処理と解析”，共立出版（1981）  
 [2] 鳥脇 純一郎：“パターン情報処理の基礎”，朝倉書店  
 [3] F.Roli et al.,"Neural networks for classification of Remotely sensed images",Fuzzy Logic and NeuralNetwork Hand book, eds by C.H.Chen, McGraw-Hill, New York, 1996

[4] 白井 支郎：“基礎と実践 ニューラルネットワーク”：コロナ社(1995)  
 [5] Y.W.Chen et al., "A hybrid neural network training approach of back propagation and genetic algorithm for classification of remotely sensed image", Proc.of ICONIP'98, PP.1402-1405, 1998  
 [6] 安居院 猛, 長尾 智晴：“ジェネティックアルゴリズム”：