

# GMDHを用いた人工衛星画像のファジィ分類

岐阜大学 工学部 正員 清水英輔  
 岐阜大学 工学部 学生員 ○森 光正  
 岐阜大学 工学部 学生員 児島利治

## 1.はじめに

ここでは、人工衛星画像の個々のピクセルをその特徴ベクトル  $x$  によってクラス  $C_m$  ( $m=1, 2, \dots, M$ ) のいずれかに割り当てる、いわゆる分類問題を扱う。衛星画像の分類においては、「mixed」ピクセル（複数の分類クラスの存在が予想されるピクセル）と「unknown」ピクセル（どのクラスにも分類されないピクセル）の存在が問題となる。

本研究は、人工衛星画像の分類クラスをファジィ集合と捉えることにより、これらのピクセルの存在をより理論的に考慮する手法を構築するものである。<sup>1)</sup>

クラス  $C_m$  ( $m=1, 2, \dots, M$ ) を特徴空間  $X$  上のファジィ集合と考え、ある特徴ベクトル  $x$  の集合  $C_m$  への帰属度（メンバーシップグレード） $\mu_m(x)$  が定義されているものとする。この時メンバーシップグレードは以下の範囲内に分布することになる。

$$\mu_m(x) = [0, 1] \quad (1)$$

もし式(1)の形で得られたいくつかの教師データから連続なメンバーシップ関数  $\mu_m(x)$  を同定することができれば、これにより「mixed」ピクセルや「unknown」ピクセルの扱いが可能になる。すなわち、 $m=A, B$  の場合を考えると、「mixed」ピクセル集合は以下のように表現でき、

$$\mu_{A+B}(x) = \mu_A(x) + \mu_B(x) \quad (2)$$

また、「unknown」ピクセル集合は、

$$\begin{aligned} \mu_{A-B}(x) &= 1 - \mu_{A+B}(x) \\ &= 1 - \{\mu_A(x) + \mu_B(x)\} \end{aligned} \quad (3)$$

のように表現することができる。ここで、 $A, B$  は各々  $\min, \max$  を示す。

メンバーシップ関数  $\mu_m(x)$  の同定にあたり特徴空間  $X$  は多次元空間であるため、メンバーシップ関数  $\mu_m(x)$  の構造形を推定することが大変困難であることが予想される。そこで構造形を設定せずに出力値を推定することができるニューラルネットワークを用いることにした。しかし、適用にあたり操作上の問題が生じている。

またファジィ分類法は、メンバーシップ関数を同定することが可能であれば有効な手法であって、ニューラルネットワークに左右される手法ではない。

本論文では以上の議論を背景に、人工衛星画像の分類における設定クラスをファジィ集合として同定する方法として新たに GMDH を取り上げ、先のニューラルネットワークとの比較により、その利用可能性について検討を行う。

## 2. ニューラルネットワークによる方法

### (1) ニューラルネットワークの概要

いま、特徴空間  $X$  は  $S$  次元ベクトルによって定義されているものとし、 $i$  番目の教師データの特徴ベクトルを  $x_{i:} = (x_{i1}, x_{i2}, \dots, x_{is})$  と表す。

ニューラルネットワークは、入力、中間、出力の3層構造とする。その入出力構成は、 $S$  個の入力層ユニットを用意し、 $x_{i:}$  を入力層ユニット  $s$  に入力し、中間層ユニット  $t$  に伝わり、1つの出力層ユニットから出力される。この出力値がメンバーシップグレードを表現する。

以上の前提のもとに、ニューラルネットワークの入力層に教師データ  $x_{i:}$  を入力したときの各ユニットの出力を以下のように表現する。

入力層ユニット  $s$  からの出力  $O_{is}$  は、 $O_{is} = x_{is}$  とする。中間層ユニット  $t$  の内部状態  $I_{it}$  は、入力層の出力  $O_{is}$  によって以下のように定義される。

$$I_{it} = \sum_{s=1}^S w_{st} O_{is} + \theta_t \quad (4)$$

ここで、 $w_{st}$  は入力層ユニット  $s$  と中間層ユニット  $t$  の結合強度、 $\theta_t$  は中間層ユニット  $t$  のバイアス（定数項）である。また、中間層ユニット  $t$  の出力  $O_{it}$  は以下のようなシグモイド関数を用いて定義される。

$$O_{it} = f(I_{it}) \quad (5)$$

$$f(I_{it}) = \frac{1}{1 + \exp(-I_{it}/\theta_0)} \quad (6)$$

ここで、 $\theta_0$  は関数の形状を決めるパラメータである。

出力層の内部状態  $I_{i:}$  及び出力  $O_{i:}$  は中間層の場合と同様に以下のように表現する。

$$I_{i:} = \sum_{t=1}^T w_{it} O_{it} + \theta_i \quad (7)$$

$$O_{i:} = f(I_{i:}) \quad (8)$$

ここで、 $w_{it}$  は中間層ユニット  $t$  と出力層ユニットの結合強度であり、 $\theta_i$  は出力層ユニットのバイアスである。

ニューラルネットワークを確定するためには、パラメータ  $w_{st}, w_{it}, \theta_t, \theta_i$  を求める必要がある。この過程を学習と呼び、教師データとしてのメンバーシップグレード ( $M_{im}$ ) とネットワークの出力  $O_{i:}$  の誤差を小さくするような以下の基準を設定し、最急降下法にて行う。

$$\min E_i = (M_{im} - O_{i:})^2 / 2 \quad (9)$$

この学習を繰り返すことにより、関数と等価な入出力システムが実現される。

(2) 適用にあたっての問題点<sup>2)</sup>

ニューラルネットワークをこのファジィ分類法に適用するにあたって、LANDSAT TMデータを用いた分類実験を行っている。対象地域は横浜市港北区の一部(1600km<sup>2</sup>)で、サンプルデータとしてランダムに抽出した100個のピクセルを教師データとした。5つの分類クラス(高密市街地、低密市街地、農地、林地、水域)を設定し、各クラスごとに分類を行った結果、良い精度で分類されているのがわかった。(表1参照)

しかし学習を行う際、シグモイド関数(式(6))の形状パラメータθ<sub>0</sub>を系統的に推定できないこと、1回の計算時間が長いこと、といった操作上の問題が生じている。

## 3. GMDHによる方法

ここでは、メンバーシップ関数を同定する新たな手法としてGMDHの適用を試みる。

(1) GMDHの概要<sup>3)</sup>

GMDH(Group Method of Data Handling)は、定式化が困難な複雑なシステムの問題に対して、システムの入出力情報をもとに、その関係を多项式で近似することによって問題の解決を図る方法である。

GMDHは多層構造をなし、アルゴリズムは、対象とするシステムの特徴と定式化の目的にとって有益な方向に進むようにと開発された、5つの発見的規範(ヒューリスティクス)に何を採択するかによって非常に多くの変種ができる。しかし、その基本構成の概要は以下のようにになる。(図1参照)

システムへの入力変数をx<sub>1</sub>, x<sub>2</sub>, ..., x<sub>s</sub>、モデルの出力をM<sub>m</sub>と表し、各層で用いる近似式を

$$G(x_1, x_2) = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1 \cdot x_2 \quad (10)$$

とする。

① 第1層では、任意の2組の入力変数からなる関数

$$O_1^1 = G(x_1, x_2) \quad (11)$$

$$O_2^1 = G(x_1, x_3)$$

...

$$O_s^1 = G(x_{s-1}, x_s)$$

をシステムの出力M<sub>m</sub>に近似するように定める。

② 第2層では、前の層のO<sub>1</sub><sup>1</sup>, O<sub>2</sub><sup>1</sup>, ..., O<sub>s</sub><sup>1</sup>のうち、近似度が良いものが選択され、入力変数I<sub>1</sub><sup>2</sup>, I<sub>2</sub><sup>2</sup>, ..., I<sub>n</sub><sup>2</sup>として、

$$O_1^2 = G(I_1^2, I_2^2) \quad (12)$$

$$O_2^2 = G(I_1^2, I_3^2)$$

...

$$O_n^2 = G(I_{n-1}^2, I_n^2)$$

をシステムの出力M<sub>m</sub>に近似するように定める。

以下同様にして近似度が最大となるまで同じ操作が行われる。

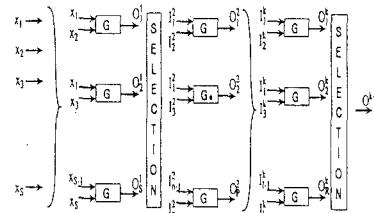


図1 GMDHの概略構成

## (2) GMDHによるメンバーシップ関数の推定方法

特徴ベクトル  $x = \{x_1, x_2, \dots, x_s\}$  を入力変数としてGMDHの第1層に入力する。各層において近似度(相関係数を用いている)の高い近似式  $G(x_i, x_j)$  が選択され、第k層における出力値  $O_1^k, O_2^k, \dots, O_s^k$  が得られる。第k+1層において近似度の高いものが選択され、 $I_1^{k+1}, I_2^{k+1}, \dots, I_n^{k+1}$  とし、それらの平均値  $I^{k+1}$  によりメンバーシップグレードを表現する。

## (3) 実験結果

TMデータを用いた同じサンプルデータによる実験を行った。100個のサンプルデータを用いた推定結果をGMDHとニューラルネットワークによる推定結果とを合わせて示しておく。

GMDHは、精度の面ではニューラルネットワークと比べ多少劣っている。しかし、その操作性、実用面での優位性は高く、衛星画像のファジィ分類へ適用する手法として十分有効なものと考えられる。

表1 ニューラルネットワークとGMDHによるクラス別推定結果

	ニューラルネットワーク	GMDH
高密市街地	0.955	0.916
低密市街地	0.959	0.790
農地	0.933	0.908
林地	0.925	0.833
水域	0.991	0.987

## 4. あとがき

現在、実験の結果をもとに全対象地域の分類を行い、また分類精度、操作性の比較を行う予定であり、その結果は当日発表時に行うこととする。

## 【参考文献】

- 1) 森水英樹: リモートセンシング画像のファジィ分類、空気測量とリモートセンシング、Vol.31, No.4, PP.37-44, 1992
- 2) 森水英樹、森光正: リモートセンシング画像のファジィ分類法の適用性の検討、日本空気測量学会秋季学術講演会発表論文集、PP.135-140, 1992
- 3) 地田三郎、井川二郎: GMDH(並列組合せ計算法)の基礎と応用、システムと制御、Vol.23, No.12, 1978 ~ Vol.24, No.7, 1980