

人工衛星画像のファジィ分類法 — GMDHとニューラルネットワークの比較 —

東京大学 正員 清水英範
岐阜大学 学生員 ○児島利治

1. はじめに

本研究では、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、衛星画像の分類において問題となる'mixed'ピクセル(複数の分類クラスが存在する)と'unknown'ピクセル(どのクラスにも分類されない)の存在をより理論的に考慮する手法を構築する。

いま、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)が定義されているものとする。もし、この特徴ベクトルを教師データとして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'ピクセル集合はファジィ集合の「交わり」、'unknown'ピクセル集合は、「補集合」として表現できる。このメンバーシップ関数 $\mu_m(x)$ は、特徴空間 X が多次元空間であるため、そ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。そこで筆者らは、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を提案している。本研究では新たな手法としてGMDHを取り上げ、ニューラルネットワークとの比較によって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

入力層、中間層、出力層の3層構造とし、特徴ベクトル $x_i = (x_{i1}, x_{i2}, \dots, x_{is})$ を入力変数とする。入力層ユニット s 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} と出力 O_{it} は、シグモイド関数を用いて以下のように定義される。

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

$$O_{it} = f(I_{it}) = \frac{1}{1 + \exp(-I_{it}/\theta_0)} \quad (2)$$

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、 θ_t はユニット t のバイアス(定数項)、 θ_0 はシグモイド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。

$$I_i = \sum_{t=1}^T W_{ti} O_{it} + \theta_i, \quad O_i = f(I_i) \quad (3)$$

ここで、 W_{ti} 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、 θ_i は出力層のバイアスである。

以上のようなニューラルネットワークをバックプロパゲーション法によって確定することにより、関数と等価な入出力システムが実現される。しかし、シグモイド関数の形状パラメータ θ_0 を系統的に推定できないこと、中間層のユニット数の決定は試行錯誤的に行わなければならない等の問題が生じ、総じて1回にかかる計算時間が非常に長いといった操作上の問題が生じた。この問題を克服するため、より簡便で、操作性のよい計算システムとして、GMDHの適用を試みる。

3. GMDHによる方法

特徴ベクトル x_i を入力変数としてGMDHの第1層へ入力する。第1層では、想定される全ての2組の入力変数 x_{i1j}, x_{i1h} ($j, h=1, 2, \dots, S; j \neq h$)を用いて関数 $G(x_{i1j}, x_{i1h})$ を設定し、その各々を教師データ O_i に近似するように回帰分析によって定め、第1層の出力 $O_{i1}, O_{i2}, \dots, O_{iN}$ ($N = S C_2$)を得る。この出力のうち近似度が良いものをいくつか(例えば P ($P \leq N$)個)選択し、新たな入力変数 $x_i = (x_{i1}, x_{i2}, \dots, x_{iP})$ として第2層へ入力する。第2層では、第1層からの入力変数 x_i を用いて第1層と同様に Q ($Q = P C_2$)個の関数 G を設定し、第2層の出力 $O_{i1}, O_{i2}, \dots, O_{iQ}$ を得、近似度が良いものを選択して第3層へ入力する。

ここで、各層で定義される同一構造の関数 G のことを部分表現といい、本研究ではニューラルネットワークとの比較のため以下のような関数を使用する。

$$G(x_{i1j}, x_{i1h}) = \frac{1}{1 + \exp\{-(c_0 + c_1 x_{i1j} + c_2 x_{i1h})\}} \quad (4)$$

c_0, c_1, c_2 : 未知のパラメータ

また、最終的な出力 O_i は G の合成関数であり、結局のところ以下のような入力変数 x_i の関数 F となる。

$$O_i = F(x_i) = F(x_{i1}, x_{i2}, \dots, x_{is}) \quad (5)$$

この関数 F を完全表現と呼び、以下各層の部分表現の中で最も近似度の良いものを完全表現とし、完全表現の近似度の上昇が収束するまで同様の作業を行う。

なお、近似度の高さは相関係数を用いて判断し、次層へ入力する部分表現に要求する近似度は、各層で試行錯誤的に決定する。

4. 適用

対象地域は横浜市港北区の一部(16km²)で、LANDSAT TMデータ(1988年10月)の、熱バンド(TM6)を除く6バンドのデータを使用し、表1に示すような5つの分類クラスを設定した。

対象地域内において画像として均一と考えられるいくつかの箇所を設定し、その各々について各分類クラスへのメンバーシップグレードを与え、この中からさらに100個のピクセルを抽出しサンプルデータとした。

表1に示した推定結果(相関係数)からは、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事がわかる。しかし、例えばPC-9801RAを用いた、1つのクラスのメンバーシップグレードの推定に要する計算時間は、ニューラルネットワークの6時間に対しGMDHでは2分程度とその操作性、実用面での優位性は高いことが確認された。

表1 メンバーシップグレードの推定結果(相関係数)

分類クラス	ニューラルネットワーク	GMDH
高密度市街地	0.955	0.926
低密度市街地	0.959	0.851
農地	0.933	0.894
林地	0.925	0.817
水域	0.911	1.000

5. GMDHとニューラルネットワークの比較

(1) モデル構造

ニューラルネットワーク内での情報処理の過程と、GMDHの完全表現を定式化し比較した結果、両者は基本的に同じ構造であることがわかった。より具体的に言えば、GMDHの入出力関係は、ニューラルネットワークにおけるパラメータ W_{s_i}, W_c のうちいくつかを0としたもの、すなわち、ある特定のユニットとある特定のユニットの関係をなくしたニューラルネットワークと同じ入出力関係を持ち、GMDHとニューラ

ルネットワークは基本的に同じモデル構造を有していると言える。(図1参照)

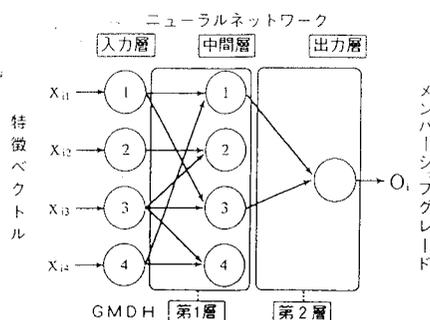


図1 GMDHとニューラルネットワークの入出力関係の対応(入力変数が4つ、中間層のユニット数が4つの場合)

(2) パラメータ推定法

ニューラルネットワークでは、バックプロパゲーション法によって、各パラメータの値が同時に推定される。それに対しGMDHは、部分表現の重ね合わせで完全表現を記述していることを利用し、回帰分析を繰り返すことによりパラメータが順次決定される。

このように、ニューラルネットワークとGMDHでは、パラメータ推定方法が異なる。

6. 結論

ニューラルネットワークは、非常に高い精度を得ることができるが試行錯誤的な処理が多く、操作性の面で決して満足のいくものとは言えない。

それにくらべてGMDHは、簡単な非線形関数である部分表現の重ね合わせによってモデルを近似しようとしたものであり、パラメータの数が少なく、また回帰分析という操作性に富む手法によって極めて容易かつ短時間に出力値を推定できる。

本研究の実験結果では、このGMDHの精度はニューラルネットワークに比べて多少劣るが、その操作性の良さが十分に確認できた。以上より、GMDHはニューラルネットワークの代替手法として、人工衛星画像のファジィ分類に十分適用可能であると考えられる。

【参考文献】

- 1) 清水英範: リモートセンシング画像のファジィ分類, 写真測量とリモートセンシング, Vol. 31, No. 4, pp. 37-44, 1992.
- 2) 清水英範, 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, 日本写真測量学会秋期学術講演会発表論文集, pp. 135-140, 1992.
- 3) 池田三郎, 井原二郎: GMDH(変数組合せ計算方法)の基礎と応用, システムと制御, Vol. 23, No. 12, 1979 ~ Vol. 24, No. 7, 1980.
- 4) 谷村秀彦, 梶秀樹, 池田三郎, 藤塚武志: 都市計画数理, 朝倉書店, pp. 180-201.