

協調学習ニューラルネットによる
ランドサットTMデータの土地被覆分類解析

豊橋技術科学大学

正会員 河邑 眞

豊橋技術科学大学 大学院○学生員 辻子裕二

豊橋技術科学大学 大学院 学生員 大城博敏

1. 緒言 近年、リモートセンシングデータの統計的分布に対する非依存性およびクラス間分離の非線形性に対処するために、ニューラルネットこれを学習させ、分類精度向上に利用する試みがある。これらは主として、Rumelhart and McClellandにより提案され、任意の非線形写像を任意の精度で近似的に再現可能であることが数学的解析結果より証明されている逆誤差伝播法 (Back Propagation, 以下BPと略す) を用いている。これら3層・層間完全結合BPモデルは、筆者らの研究も含め、統計的手法と比較した結果有用であるとの報告¹⁾²⁾もなされている。以上を前提に、本研究は3層からなるカテゴリ抽出ネット (Extraction Net) と抽出されたデータを統合するネット (Unification Net) から構成される多層多段のBPモデルを提案する。協調学習 (Cooperative Learning, CL)³⁾ と呼ばれるネットワークを応用した本モデルは、時系列環境変化やデータの欠落・置換等の問題に対処でき、学習の収束性も向上する。また、カテゴリ抽出ネットに、着目するカテゴリの抽出に有利な多次元化データを独立に付加することも可能となる。ただし、ここで用いる多次元化データとは、スペクトルデータの他にカテゴリ分類に有利となるよう付加されるスペクトル加工データを指す。

本研究においては、ランドサットTMデータを用いて、以前より報告されている基本的な3層BPモデルと提案モデルを比較し本モデルの有用性を検討する。また、解析対象地域は精度検証データの整っている名古屋市とした。

2. 解析基本モデル 解析基本モデルとして3層BPモデルを定義する。このモデルは、入力層・中間層 (隠れ層)・出力層からなり、層間は完全結合とする。入力層にはランドサットTMデータの各バンド (バンド6は除く) のスペクトル値を8ビットで正規化して与える。 n 層・ i ユニットの出力値 X_i^n は、伝達関数 f (シグモイド) を用いて次式で与えられる。

$$u_i^n = \sum W_{ij}^{n,n-1} X_j^{n-1} \quad (1)$$

$$X_i^n = f(u_i^n - h_i^n) \quad (2)$$

ここに、 $W_{ij}^{n,n-1}$ は n 層・ i ユニット - $(n-1)$ 層・ j ユニットの結合重み (synaptic efficacies)、 h_i^n は n 層 i ユニットのしきい値 (bias) である。出力層 (N 層) における出力値から次式によりカテゴリ $c_{k,i}$ が決定される。

$$c_{k,i} = \max \{ X_i^N \} \quad (3)$$




Fig.1 Proposed network architecture

3. 提案モデル Fig.1 にこのモデルの構造を示す。カテゴリ抽出ネットは3層からなり、出力層ユニットは1とする。抽出ネットの出力層における出力値は、 $X_i^n = f_c(X_i^N)$ とコーディングされ、統合ネットの入力層に $X_i^{I,N}$ を与える。これは、カテゴリ抽出時における出力画素の重みを大きくするためであり、本解析中は実験的に $f_c(x) = \sqrt{x}$ としている。統合ネットの各ユニットは、抽出ネットの出力層の各ユニットと結合し、統合ネットの出力層ユニットはカテゴリ数存在する。このような環境で学習を行うことにより、より正確なカテゴリ分離を行うことができる。また、出力値から基本モデルと同様に式 (3) によりカテゴリが決定される。

4. 多次元化データの付加 入力データにおける画素単位のスペクトル空間分布特性および各バンドの2次元方向パターンベクトルのみではカテゴリ間分離の非線形性を認識することが困難な場合がある。こういった際の誤差は、異カテゴリの混在によってデータの置換が行なわれるエッジ近傍であることが多い。したがって、カテゴリ間の分離に有利な情報 (多次元化データ) を付加することでこれに対処する。多次元化データとしてテクスチャ情報を用いる報告があるが、本解析ではエッジ形状から得られる特徴に着目し多次元化を試みた。予備的実験としてこのエッジ情報のみで対象画像のパターン認識を行った結果、スペクトルデータに対して変わらぬ学習収束と、スペクトル特性とは異なった画素の抽出が可能であることが確認できた。また、提案モデルに対しては各カテゴリの抽出に有利な多次元化データを各抽出ネットの入力層に独立に付加することが可能となることも特筆すべき点である。

5. 結果および考察 Fig.2に縦軸に学習誤差 (Mean Square Error, MSE)、横軸に学習回数 (Epochs) をとった学習収束曲線を示す。基本3層モデル (A) と提案モデル (C) の学習曲線を比較すると、提案モデルの学習収束に関する有用性が確認できる。

また、Table 1(分類結果) に示すように、基本3層モデル (A) では認識が不可能であったカテゴリ 3 (agricultural area) が、提案モデル (C) においては統合ネットでの相互作用により再現できた。これは、カテゴリ 3 の学習パターンがカテゴリ 4 の学習パターンと似た特性をしているために、基本3層モデルにおける学習誤差の最少化に際して、小数学習パターンのカテゴリ 3 がすべて誤差として認識されてしまったと考えられる。これに対し提案モデルは、抽出ネットの出力値 (統合ネットの入力値) がすべてのカテゴリに対して同じ重みをもつため重複学習パターンが減少し、こういった効果が表れたと考えられる。汎化能力 (未学習パターンに対して目標出力を発揮する能力) の観点から分類結果を判断しても、実用的に十分であると考える。

エッジから得られる特徴による、パターン認識効果について概説する。Fig.3 (抽出ネットの出力値の誤差画素および着目ライン上のスペクトル・エッジ特性) に示すように、多次元化エッジデータによりエッジ部分の誤差画素が減少しているのが認められる。図中の円で囲まれた領域は、スペクトルデータの濃淡分布の太め細め処置 (closing) より得られる効果であると考えられる。このエッジ成分の影響により誤分類となった画素もあるが全体精度としては向上しており本モデルの有用性を確信する。しかしながら、基本3層モデルに対しては、エッジ情報を独立に付加できないことから、学習収束および全体精度に顕著な効果を発揮することは不可能であった。

6. 結語 本研究において提案したモデルは以上に示したように、学習収束・汎化能力の点で有用性が見い出せた。また、エッジ情報の適切な付加により高認識結果が期待できることも確認できた。しかし、今後完全な特異点の解消、局所的最小 (local minima) の回避、中間層ユニット・その他パラメータの最適化および高汎化能力学習法の検討等の課題が残る。




Fig.2 Learning curves

Table 1 Classification results
(percentages of correctly classified pixels)

Category	Category1 (waters)	Category2 (forest)	Category3 (agricul.)	Category4 (built-up)
A: 3 layers BP	45.1	37.3	0.0	99.0
B: A+Edge	46.2	35.1	0.0	99.2
C: Coop. Learning	46.2	46.4	5.2	97.9
D: C+Edge	46.2	46.9	5.2	98.3




Fig.3 Edge data and its effects

<参考文献>

- 1) H. Bischof, W. Schneider, and A. J. Pinz: Multispectral classification of Landsat-images using neural networks, IEEE trans. Geosci. Remote Sensing, vol. 30, no. 3, pp. 482-490, 1992.
- 2) 河邑眞、大城博敏、辻子裕二: LANDSAT/TM データによる豊橋市周辺地域の土地利用経年変化に関する検討, 土木学会中部支部講演会概要集, pp. 463-464, 1992.
- 3) 田中啓夫、古村光夫: 誤差逆伝搬量の特異点解消による学習の高速化, 信学論 (D-II), vol. J75-D-II, no. 5, pp. 1000-1008, 1992.