

リモートセンシングによる徳島市中心部の 土地利用状況解析

村井 礼

Land Cover Mapping of Tokushima City by Remote Sensing Analysis

Hiroshi MURAI

ABSTRACT

In this paper, we propose a pattern classification method for remote sensing data using two neural networks; one (NN1) is trained by a back-propagation method and another (NN2) by self-organized feature mapping and knowledge-based processing. The NN1 has the ability to recognize complex patterns and classify them. However, it has two disadvantages : it may misclassify the patterns, and it is difficult to choose a training set. On the other hand, the NN2 doesn't need the training set, and a knowledge-based system which uses human geographical knowledge improves the classification results, compared with the conventional statistical method.

We propose a pattern classification method that integrates advantages of both the neural networks and the knowledge-based system. The proposed system is divided into three sub-systems which consist of a preprocessing component, a recognition component, and an error correction component. We use the NN2 for choosing the training set as a preprocessor of the NN1, the NN1 for classification, and the knowledge-based system for correcting mis-classification created by the NN1. Experimental results illustrate the performance of the proposed system.

KEYWORDS : Neural Network, Remote Sensing, Pattern Classification, Knowledge-Based Processing, Back-Propagation Method, Self-Organized Feature Mapping

I. はじめに

宇宙からのリモートセンシングの幕開けは旧ソ連が人類初の人工衛星スプートニック1号を軌道に乗せた1957年10月4日と言える。その後、米国もNASA航空宇宙局を発足させ、米ソ両国による宇宙開発が主に防衛目的から展開されるようになった。このような背景の下、航空・宇宙技術の発展により、リモートセンシングデータの利用は世界的に急増している。1972年7月22日に米国から打ち上げられた地球資源技術衛星ERTS-1（2年後、LANDSAT-1と改名）から得られた地表面情報は我々に深い感銘を与えた。我が国においても、LANDSATから送られてくるデータの受信局を埼玉県鳩山村の地球観測センター内に誘致し、1979年1月29日より受信を開始した。以後、こうして得られた画像データは

広く配布されるようになり、産・学・官それぞれの立場から研究開発が推進され、数多くの実績をあげることに成功している。人工衛星や航空機により抽出されたリモートセンシングデータには、広範囲にわたる地域のデータを同時に調査することができ（広域同時性）、かつ人為的・自然的現象の変化を周期的に精密に観測できる（周期的観測性）という二つの利点がある。これらは、地上調査ではとらえることのできなかった特徴であり、地域的・時間的な要因に影響を受けずに、極めて広範多岐な分野に応用できることができることが判明した。具体的には、環境の保全、災害の防止、農林水産資源の把握、鉱物資源の探査、国土の合理的利用といった多くの面で利用できることができてきた¹⁾。

本報告では、LANDSAT 5号がもつ TM (Thematic Mapper) という多波長高解像度セン

サによって得られた、徳島市中心部の画像データを用いて、土地利用状況の解析を行う。また、従来手法を例に挙げ、それぞれの概略と問題点を指摘し、これを改善したシステムを提案し、実際のリモートセンシングデータに対する処理結果について考察する。

II. LANDSAT (TM) と処理対象データ

まず、処理対象となる TM データについて説明する。リモートセンシングでは、電磁波の波長域を大きく三つに区別する。すなわち、可視・近赤外波長域 VNIR (Visible and Near InfraRed)，中間赤外の一部 SWIR (Short Wave InfraRed)，それに熱赤外 THIR (THermal InfraRed) である。地表を対象とするリモートセンシングでは、放射源の存在、放射の検出器の存在、大気効果（大気の窓）を考慮して、これら三種類の波長域とマイクロ波域が用いられる²⁾。TM の波長帯を図1に示す。図1に示す通り、TM は広範囲の波長帯に対応した7種類のバンドからなる。バンド1は沿岸水域、バンド2は植生調査、バンド3はアルベド吸収作用、バンド4はバイオマス調査、バンド5は植生の含水量、バンド6は温度分布、バンド7は熱水変質帶識別などに利用される。

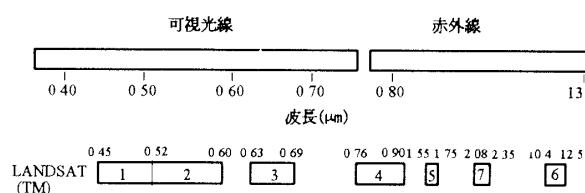


図1. LANDSAT (TM) の波長帯.

TMの空間分解能は約30m四方であり、鉱物・岩石のスペクトル特性に基づいて電子計算機を利用した地球表面物質の認識が可能である。

処理対象とするのは、1984年10月8日にLANDSAT 5号により抽出されたリモートセンシングデータの内、バンド3，4，5のデータである。図2にバンド3，4，5をそれぞれ光の三原色である青、緑、赤色に割り当てたフルカラー画像を示す。対象地域は図3に示す徳島市中心部であり、この地域は河川

の支流が入り組んでおり複雑な地形となっている。分類するカテゴリは、橋、市街地、田畠地、植生地、森林地、河川、砂地、裸地、雲、および、雲の影の10種類とする。図2から分かる通り、雲とその影が含まれている。このため、雲の影の影響を受けた地表面は、スペクトル特性をとらえることが困難であり、従来手法を用いた分類では誤認識となり易い。

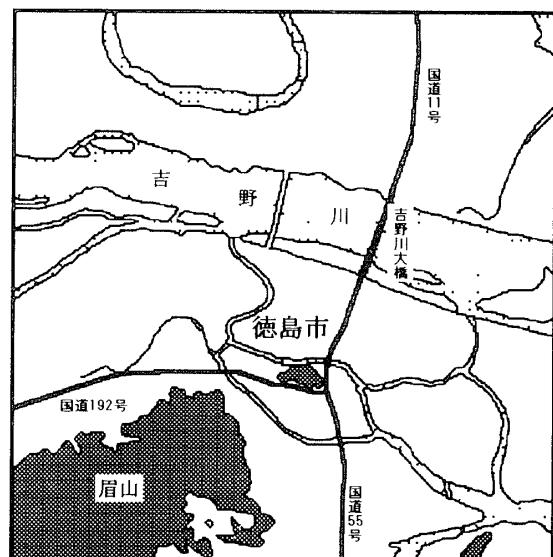


図3. 德島市中心部の地図.

III. 土地利用状況の解析手法

1. ニューラルネットワーク（誤差逆伝播法）の応用

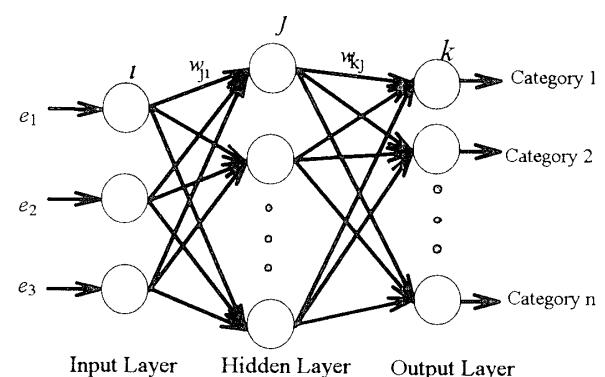


図4. 階層型ニューラルネットワーク (NN1) の構造

近年、パターン認識に優れた能力を有するニューラルネットワークを応用する手法が提案されている^{3) 4)}。この手法によれば、ネットワークの学習

が収束すれば、ガウス分布に従わないデータに対しても精度の良い分類が可能となる。本節では、教師付き学習法である誤差逆伝播法を用いたニューラルネットワークによる、カテゴリ分類手法について概略を述べる。

本節で述べるニューラルネットワークは、図4に示すように、入力層、中間層、出力層の3層構造となっている。あるパターン $I_p = [e_1, e_2, e_3]$ が入力された時、対応する出力層のユニットが唯一つだけ発火するように学習を行う。(3.1)式に示す、出力層のユニット k の出力値 o_{pk} と教師パターン t_{pk} との誤差 E が収束するようにネットワークの結合荷重を繰り返し修正する。これをネットワークの学習と呼ぶ。

$$E = \frac{1}{2P} \sum_p \sum_k (t_{pk} - o_{pk})^2 \quad (3.1)$$

ただし、 P は教師パターンの数である。

n ステップから $n+1$ ステップへのネットワークの結合荷重の修正式は (3.2) 式に示す通りである。

$$\Delta w_{ji}(n+1) = \eta(\delta_j o_i) + \alpha \Delta w_{ji}(n) \quad (3.2)$$

ただし、 η は学習率であり、通常0.25から0.75の値をとる。また、 α は慣性項であり、1以下の正の実数値をとる。 η はネットワークの学習速度を表しており、この値が非常に大きい場合には、ネットワークが不安定になり、満足な学習を行うことが困難になる。一方、非常に小さな値の場合には、学習速度が急激に遅くなる。 α は学習が収束しやすくする働きをもつ。

δ_k は出力層における教師パターン t_k とユニットの出力値 o_k との誤差であり、(3.3)式で計算する。

$$\delta_k = (t_k - o_k) o_k (1 - o_k) \quad (3.3)$$

この誤差の計算を出力層ユニットから開始し、入力層ユニットへと伝播させていくことにより学習を行う。(3.3)式は、中間層では (3.4)式に示す通りに変形される。

$$\delta_j = o_j (1 - o_j) \sum_k \delta_k w_{kj} \quad (3.4)$$

ただし、 w_{kj} はユニット j から k への結合荷重の値である。

この手法では、最尤法と同じく教師パターンの選定により、処理結果が大きく影響されるという欠点がある。そのため、優れた教師の選定基準の明確化が望まれる。

2. Kohonen の自己組織化特徴地図法の応用

自己組織化特徴地図法は教師を必要としない分類手法である。この手法は T. Kohonen によって提案され、後に同じようなアイデアが S. Grossberg からも提案されている⁵⁾。本節では、Kohonen の提案した自己組織化特徴地図アルゴリズムについて概略を述べる。

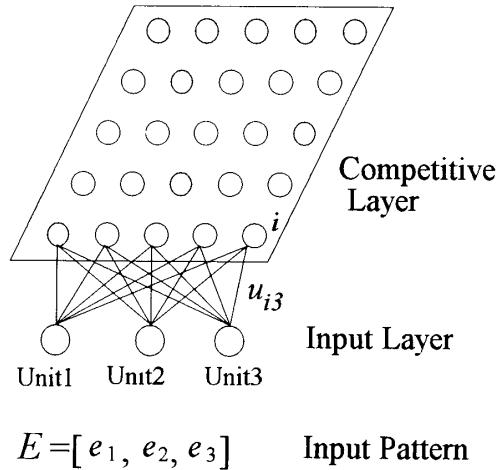


図5. Kohonen の自己組織化特徴地図法を用いたニューラルネットワーク (NN 2) の構造。

図5に本手法のネットワーク構造を示す。このニューラルネットワークは入力層と競合層の2層から成っている。競合層の各ユニットは、それぞれ入力パターンの次元数に等しい結合荷重を有しており、入力層ユニットと全結合している。入力層ユニットの入力は、各パターンのベクトルの要素である。あるパターン E が入力された時、 E と競合層のユニットの結合荷重との距離を (3.5) 式により計算し、その値が最も小さいユニットを求める。

$$\sqrt{\sum_j (e_j - u_j)^2} \quad (3.5)$$

このユニットと周辺の近傍 d 内に含まれるユニットの結合荷重を入力パターンに近づくように修正する。修正量は (3.6) 式を用いて計算する。

$$\Delta u_j = \begin{cases} \alpha(e_j - u_j) & \text{if unit } j \text{ is in the neighborhood } N_c \\ 0 & \text{otherwise} \end{cases} \quad (3.6)$$

訓練回数 t における、重みの修正係数 α_t および近傍 d_t は (3.7), (3.8) 式で求められる。

$$\alpha_t = \alpha_0 \left(1 - \frac{t}{T}\right) \quad (3.7)$$

$$d_t = \left[d_0 \left(1 - \frac{t}{T}\right) \right] \quad (3.8)$$

ただし、 T は全学習回数であり、 α_0 および d_0 は、それぞれ修正係数と近傍値の初期値である。

学習が完了した後に、分類カテゴリがあらかじめ分かっている評価パターンを入力し、競合層ユニットの発火状況を調べる。(3.5) 式で示される入力パターンと競合層ユニットの結合荷重との重みを計算し、その値がもっとも小さい競合層ユニット（発火ユニット）が対応するカテゴリの特徴を学習していると判断する。同様に、すべてのカテゴリについて評価パターンを入力し、競合層ユニットの学習結果を調べる。最後に未学習パターンを入力し、競合層ユニットの発火状況から分類されるカテゴリを決定する。

この手法には、アルゴリズムが簡単であり、クラスタリング法に比べて計算時間が短い、という利点がある。ところが、ネットワークの構造や初期値設定に関する明確な基準がなく、今後の検討が必要となっている。

IV. 応用システム

III. で紹介した種々の手法を考慮して、各々の利点を活かすように組み合わせたシステムを我々は提案する^{6) - 8)}。本章では提案システムについて概要を述べ、処理結果について従来手法との定量的な比

較を行う。

1. 概 要

本システムは、誤差逆伝播法を用いたニューラルネットワークによるカテゴリ分類の精度向上のためには、Kohonen の自己組織化法や知識処理を階層的に組み合わせており、それぞれ認識部、前処理部、および誤認識修正部と呼ぶ。以後、前処理部で用いられている自己組織化ニューラルネットワークを NN2 と呼び、認識部で用いられている誤差逆伝播ニューラルネットワークを NN1 と呼ぶことにする。

図 6 に処理の概要を示す。

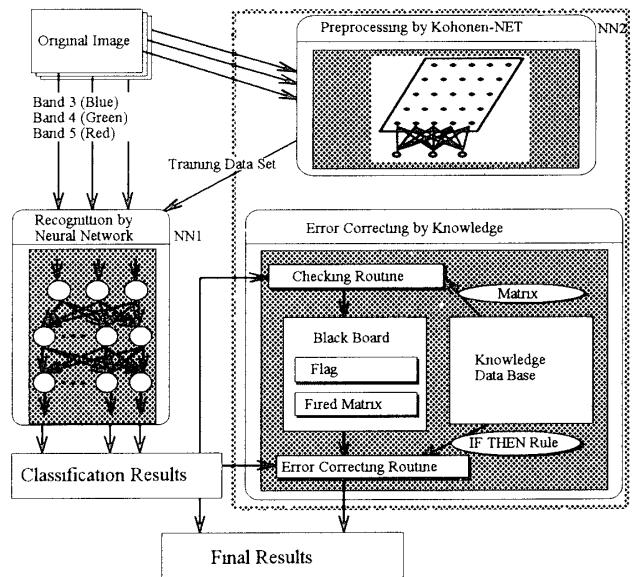


図 6. 提案するリモートセンシングデータ解析用パターン認識システムの流れ図。

まず、前処理部において、NN2 を用いて原画像データを学習させる。この処理結果から、分類しようとするカテゴリの特徴が顕著に表れている競合層ユニットの結合荷重を NN1 の教師パターンとして選定する。結合荷重を用いることにより、効率の良い学習が行える⁹⁾。NN2 の学習が収束すると、原画像データを入力し、カテゴリ分類を行う。分類結果はブラックボードに保存する。続いて、分類結果の中に誤認識が発生していないかを検出する。検出に用いるのは、予め実験者が予想される誤認識のタイプに応じて知識データベース上にマトリクス形式で記述しておいた誤認識検出用の知識である。この誤認識検出用マトリクスとカテゴリ分類結果の画素

データとのマッチングをとることにより、誤認識の検出を行う。誤認識検出用マトリクスには、誤認識のタイプに応じて優先度を与えておく。誤認識と判断された画素については、IF THEN ルールを用いて修正を行う。修正するカテゴリは、人間のもつ地理的知識と認識部で教師として与えたパターンの各カテゴリ間の類似度に基づいて決定する。IF THEN ルールの条件部には、誤認識の検出の際に発火した知識を記述し、発生した誤認識のタイプに応じて修正カテゴリを決定する。もし、複数の修正ルールが発火した場合には、発火した誤認識検出用マトリクスの優先度に基づき、もっとも優先度の高いルールを適用する。

2. 処理結果の比較

誤差逆伝播法による処理結果の画像と本処理システムによる処理結果の画像を、それぞれ、図 7(a)と図 7(b)に示し、各カテゴリの色付けを図 7(c)に示す。両手法による処理結果画像を比較すると、前者には、(1) 雲の影が橋として誤認識されている、(2) 市街地に砂地が発生している、(3) 河川に雲の影が散らばっている、(4) 田畠地に植生地や森林地が現れている、などの誤認識が多数発生している。一方、後者には、(1) 河口付近の浅瀬が雲の影として誤認識されている、(2) 橋と陸地の境界部分が雲の影として誤認識されている、などの誤認識が見られる。しかし、これらは知識データベースの改良により、容易に修正できる誤認識であると言える。また、前者に見られた雲の影と橋との誤認識は全て修正されており、本システムの有効性が証明されている。

最後に処理精度の比較を行うために、評価パターンについての分類精度を求めるとき、従来手法による処理結果は 63.3% であるのに対して、本システムのそれは 73.0% と、約 10% 程度の認識精度の向上が実現された。

3. 今後の課題

本処理手法を用いることにより、リモートセンシング画像の分類精度を向上することが可能となった。

しかしながら、ニューラルネットワークの構造や初期値については、試行錯誤によるところが大きく、今後の改善が望まれる。さらに、誤認識の修正に用いた知識と修正ルールを一般性のあるものに拡張する必要があり、これについて現在考察中である。

V. おわりに

本報告では、リモートセンシングデータを用いた土地利用状況の解析について、従来手法を応用したシステムを提案し、従来手法との比較を行った。これにより、処理精度の向上が可能となった。今後の航空・宇宙技術の発展により、リモートセンシングデータの利用はさらに増えつづけるものと思われ、より精度の高い分類手法の開発が望まれている。

なお、この論文は、日本リモートセンシング学会論文誌 Vol. 14 No. 2 pp. 3-13 に掲載された「二種類のニューラルネットワークを用いたリモートセンシングのパターン認識精度の向上」を元に加筆・修正したものである。

VI. 参考文献

- 1) 科学技術庁資源調査会編, 1985. リモートセンシングの現状と動向, 東京, 大蔵省印刷局 : 1-173.
- 2) 資源観測解析センター, 1991. 宇宙からの地球観測システム, 東京, 千曲秀出版社 : 1-329.
- 3) 吉田知司, 大松繁, 寺西大, 1990. ニューラルネットを用いたリモートセンシングのパターン認識. システム制御情報学会論文誌 Vol. 4 No. 1 : 11-20.
- 4) M. S. Dawson and A. K. Fung, September 1993. Neural Networks and Their Applications to Parameter Retrieval and Classification. IEEE Geoscience and Remote Sensing Society News Letter : pp. 6-15.
- 5) 桂井浩, 1990. ニューラルネットワークアーキテクチャ入門, 東京, 森北出版 : 1-258.
- 6) 村井礼, 大松繁, 岡村雅宏, 1994. 二種類のニューラルネットワークを用いたリモートセンシングのパターン認識精度の向上. 日本リモートセンシング学会誌 Vol. 14 No. 2 : 3-13.
- 7) 村井礼, 大松繁, 1994. リモートセンシングデータ解析におけるニューラルネットワークの分類精度向上. 第 19

- 回知能システムシンポジウム資料・155-160
 8) 村井礼, 大松繁, 1994 リモートセンシング画像解析におけるニューラルネットワークの分類精度向上, 第38回システム制御情報学会研究発表講演会論文集・383-384.
 9) 村井礼, 大松繁, 1995 Kohonen-NETを用いたリモートセンシング画像解析の主成分による考察 第39回システム制御情報学会研究発表講演会論文集 99-100

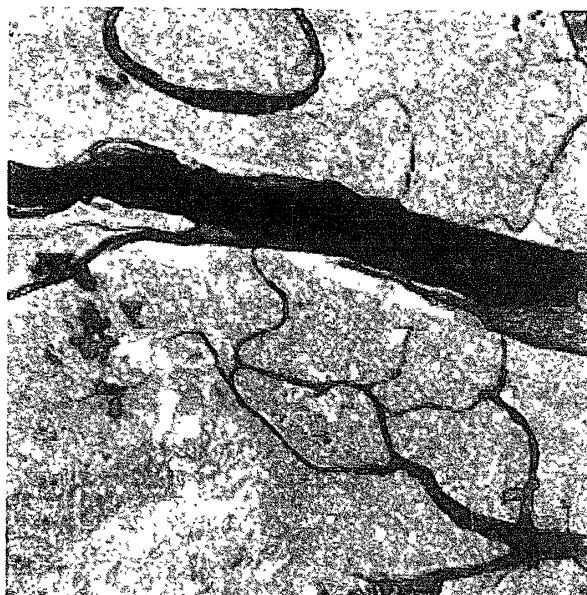
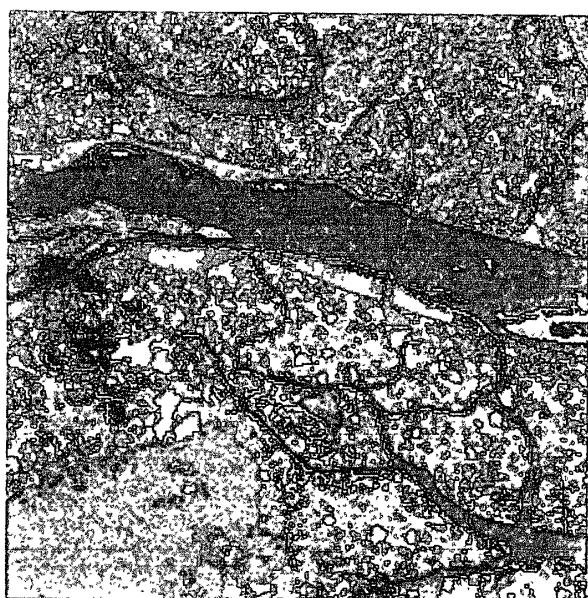


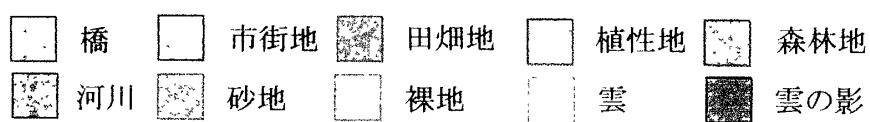
図2. LANDSAT (TM) 画像.



(a)BP法による分類結果



(b)提案システムによる分類結果



(c)各カテゴリの色付け

図7. 従来手法と提案システムによる分類結果の比較.