

リモートセンシングにおけるニューロモデルの比較

信州大学工学部 正会員 奥谷 巍
 信州大学工学部 ○両川 英樹
 信州大学工学部 南 賢

1. はじめに

地表被覆状態の情報抽出において、リモートセンシングのはたす役割は、近年の人口衛星、航空機の進歩に伴い幅広い分野で注目されている。現在でも、その利用により環境保全、資源探査等において多くの成果が上げられているものの、さらにリモートセンシングデータからの情報抽出精度が向上すれば、各方面におけるなお一層の有効利用が期待される。しかし、データのパターン認識に対して現在主に利用されている手法は、データの属性をサンプルとの類似度のようなある尺度から統計的に決定しているため、サンプルデータの影響を受けやすいうえ、統計的手法による弊害として、画素間相互に関連のない誤判別を生じることがしばしばある。さらに、データ自身のもつ問題として、大気による様々なノイズを含んでいるということが判別精度向上の妨げとなっている。そこで本研究においては、曖昧性を含んだデータに対しても自動的に最適化を行うことができ、さらに優れたパターン認識機能を有するニューラルネットワークに注目した。ニューラルネットワークのリモートセンシングへの利用法として、単純3層の階層型構造をもつネットワークにおいて、バックプロパゲーション法によって学習を行う手法が有効であることが報告されているが、ここでは、さらに精度向上を目的とし、3層構造を基本とした2つの変形型構造のニューラルネットを提案する。また、実際にランドサットMSSデータに適用することによりその有効性を検討する。

2. 基本ネットワーク構造

本研究で用いたニューラルネットワークの基本構造である3層のネットワークは、図-1に示すような入力層、中間層、出力層から構成されるものであり、図-1のネットワークの交点にあたる部分が、ニューロンをモデル化したユニットを示すものである。このユニットにおける入力値、出力値の関係は、次式のように表される。

$$x_j^k = \sum_i w_{ij}^{k-1} \cdot y_i^{k-1} + r_j^k \quad (1)$$

$$y_j = f(x_j^k) \quad (2)$$

ただし、 x_j^k : 第k層のユニットjへの入力、 w_{ij}^{k-1} : 第k-1層のユニットiから第k層のユニットjへの結合荷重、 r_j^k : 第k層のユニットjのオフセット、 y_j^k : 第k層のユニットjの出力。またユニットの特性関数fは、次に示すシグモイド関数を用いる。

$$f(z) = 1 / (1 + \exp(-\phi z)) \quad (3)$$

さらに、本研究で用いるバックプロパゲーション法は、ユニット間の重みを学習によって改善し、ネットワーク全体を最適化するものである。このとき結合荷重の修正量は、以下に示す式によって求められる。

$$\Delta w = -\alpha \frac{\Delta E}{\Delta w} \quad (4)$$

$$E = \sum_i (T_i - O_i)^2 / 2 \quad (5)$$

ただし、 α : 定数、 T_i : 出力層のユニットiに対する教師信号、 O_i : 出力層のユニットiの出力信号。つまり、バックプロパゲーション法は、(5)式で与えられる2乗誤差Eを最小化するようにwを変化させることによって行われる。

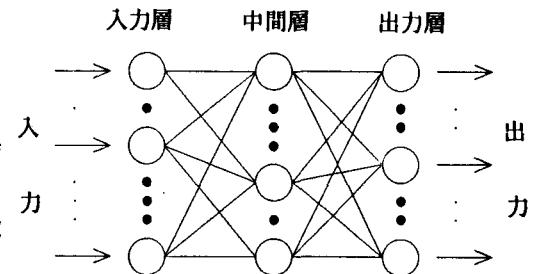


図-1 基本ネットワークモデル

3. 適用例

まず、推定対象地域を選定するに際し、次に上げるような点について考慮した。推定後に行う各手法との比較、および推定精度の検討の必要性から、広範囲な利用項目、つまり都市部から山林部、水域にわたる多くの利用項目を含む地域であること。さらに、地表被覆状態の推定過程で、真値として国土地理院発行の土地利用図より定量的なデータを得るために、土地利用図の発行年月日と推定対象地域をカバーするMSSデータの観測年月日に時間的開きがないことである。以上のような理由から対象地域として選定したのは、三重県津市周辺の一部であり、使用観測データは、1977年11月1日ランドサット衛星によって観測されたMSSデータから、該当するデータを抽出したものである。さらに本研究では、対象地域を一辺750mからなる正方形地域に区分し、この正方形を単位とした推定を考えた。つまり、正方形エリア内に含まれる画素のもつ各バンドの輝度データに統計的処理したものを入力データとし、出力信号は正方形エリア内における各分類項目の含有率として得られるものとした。ただし、本研究で使用したMSSデータは4~7の4バンド分であり設定した土地状態の分類項目数は6である。そこで、入力データとして次のような3通りのデータセットを考えた。

データセット1：正方形エリア内の各バンド輝度データの平均値

データセット2：正方形エリア内の各バンド輝度データの分散

データセット3：正方形エリア内の各バンド輝度データの共分散

この3通りの入力データを組み合わせて入力信号とし、図-1の

ような3層構造のネットワークで推定を行った場合の推定精度は、表-1に示す通りである。ただし、比較の為に採用した定量的指標は平方根平均2乗誤差（RMSE）、すなわち

$$RMSE = \sqrt{\frac{1}{N} \sum [x(k) - \hat{x}(k)]^2} \quad (6)$$

である。ただし、N：データ数、x(k)：真値、 $\hat{x}(k)$ ：推定値を表すものとする。表-1から読みとれる通り、ただ1つのニューラルネットに1~3のデータセットをすべて入力することが精度向上にはつながっていない。そこで、各データセットの特性を活かすために、図-2のような2つの変形型構造のニューラルネットを適用した。以下それをモデル1、モデル2とよぶ。モデル1、2は、共に3層構造を基本とした第1、第2、第3のニューラルネットから構成されている。モデル1では第1、第2のニューラルネットにおいて、それぞれ単一のデータセットから予備推定値1、2を求め第3のニューラルネットでそれらを入力データとした推定を行っている。さらにモデル2では、第3のニューラルネットにおいて予備推定値1、2に加え、新たなデータセットを入力することによって推定を行っている。また、この他に各バンドデータの組み合わせによるデータセットの入力も考えられる。

表-1 入力データによる精度の違い

入力データ	RMSE
データセット1	3.500
データセット1, 2	9.146
データセット1, 2, 3	7.643

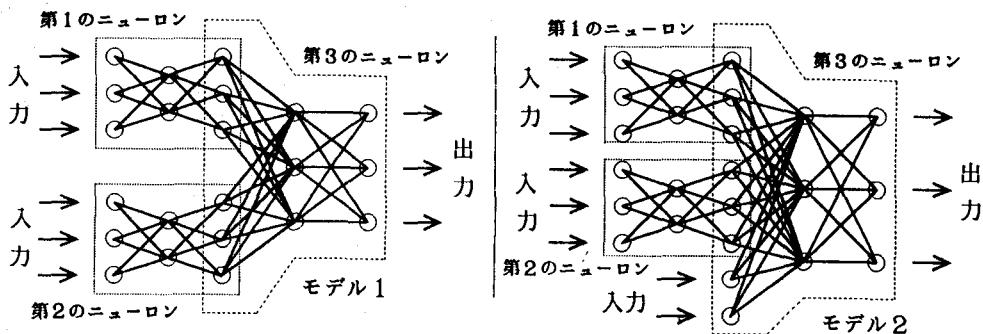


図-2 変形型ネットワーク構造

なお、モデル1、モデル2の具体的な計算結果については、当日講演時に発表する。