

## リモートセンシングにおけるニューロ・ファジィモデルの適用性

信州大学工学部

○両川 英樹

信州大学工学部 正会員

奥谷 巍

## 1. はじめに

リモートセンシングデータによって土地被覆分類を行う場合、そこには様々なあいまい性が存在する。例えば、多くの場合分類カテゴリーの決定過程において、定量的判断だけでなく主観的な判断に任せられる部分が大きい。さらに、データ自身遠隔的に観察されるものであることから、大気中の分子や雲、塵などによる反射、吸収、散乱などさまざまな要因から生ずるノイズを含むことが多い。これらの問題に起因したあいまい性に対し、既存の確率論的推論や決定論による手法が充分対応しているとは言い難く、今後これらに変わる新たな手法の開発が望まれるところである。このことから、近年あいまい性をも加味した手法としてファジィ理論の研究、適用が進められ、特に土地被覆分類においては、ファジィ推論の適用が有効であることが報告されている。しかし、従来のファジィ推論を土地被覆分類に適用する場合、推論結果が最適な値となるよう推論過程を微調整する必要がある他、ファジィ関係の合成則に基づく推論法を用いる際には、入力データがいずれのファジィ規則に対しても全く適合しないケースが発生し、未判別画素を生じるといった問題が残されている。そこで本研究では、ファジィ規則の前件部の決定にニューラルネットワーク理論を用いることによって、前述したファジィ推論に関する問題点の解決を目指すと共に、実際のランドサットMSSデータに本研究で提唱する手法を適用し、その精度向上の可能性について検討する。

## 2. ニューロ・ファジィモデル

ファジィ関係の合成則に基づく推論法では、次式で表される複数のファジィ規則が $\circ r$ 結合されているものとして用いられる。

$$R^i: x_1 \text{ is } A_i \text{ and } x_2 \text{ is } B_i \text{ then } z \text{ is } C_i \quad j=1,2,\dots,n \quad (1)$$

ただし、 $x_1, x_2$ は入力変数、 $z$ は出力変数。さらに、 $A, B, C$ はそれぞれのあいまいな状態を表すファジィ変数であり、このファジィ変数としては、一般的に次式で表される三角型のメンバーシップ関数が用いられる。

$$\mu(x) = \max\left\{0, 1 - \frac{|x - q|}{p}\right\} \quad (2)$$

図1は、三角型メンバーシップ関数の形状を示したものである。以下 $A_i, B_i, C_i$ を表すメンバーシップ関数を $\mu_{A_i}(x_1), \mu_{B_i}(x_2), \mu_{C_i}(z)$ とする。今仮に $x_1^0, x_2^0$ という入力値が与えられた場合、まずそれぞれのファジィ規則の前件部に対し、入力がどの程度適合するかが適合度 $a_i$ によって計られる。

$$a_i = \mu_{A_i}(x_1^0) \wedge \mu_{B_i}(x_2^0) \quad (3)$$

この適合度 $a_i$ を用いて、 $i$ 番目の規則による推論結果 $\mu_{C_i}(z)$ が

$$\mu_{C_i}(z) = a_i \wedge \mu_{C_i}(z) \quad (4)$$

として求められる。さらに規則全体については、規則が $\circ r$ 結合していることから、

$$\mu_{C_0}(z) = \bigvee_{i=1}^n \mu_{C_i}(z) \quad (5)$$

によって推論結果が得られる。さらに、次式によってファジィ結果を非ファジィ化することによって1つの確定した推定値 $\hat{z}$ を得る。

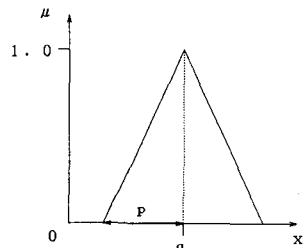


図-1 三角型メンバーシップ関数

$$\hat{z} = \int z \cdot \mu_{c0}(z) dz / \int \mu_{c0}(z) dz \quad (6)$$

以上のような推論法に対し、本研究では(3)式で求められる適合度 $\alpha$ にかえて、以下のような入出力関係をもつ3層構造のニューラルネットワークの出力を用いる。

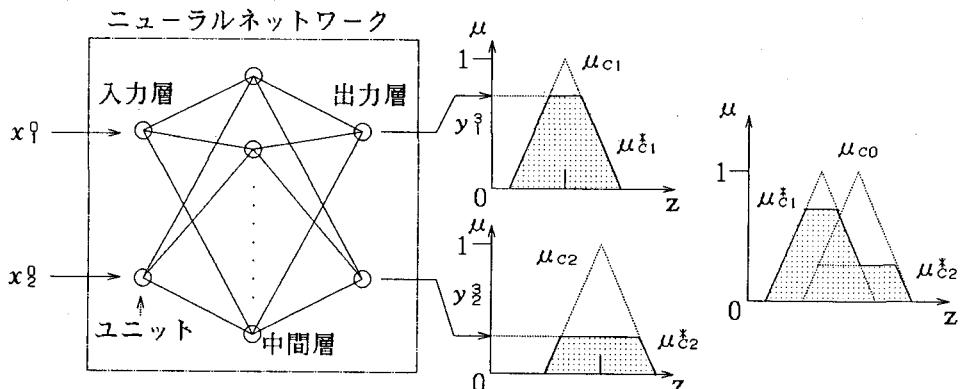
$$x_j^k = \sum_i w_{j,i}^{k-1} \cdot y_i^{k-1} + \gamma_j^k \quad (7)$$

$$y_j^k = f(x_j^k) \quad (8)$$

$$f(x) = 1 / \{1 + e^{-\phi \cdot x}\} \quad (9)$$

ただし、 $x_j^k$  : 第 $k$ 層のユニット $j$ への入力、 $w_{j,i}^{k-1}$  : 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、 $\gamma_j^k$  : 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として用いたのは、(9)式で表されるシグモイド関数である。

つまり、図-2に示すように(1)式で表される各ファジィ規則の後件部を、ニューラルネットワークの各出力層ユニットに対応させ、そこからの出力を適合度として用いる。したがって(4)から(6)式までの計算は、 $\alpha$ を $y_j^k$ に置き換えることによって行われる。ただし、ここで用いるニューラルネットワークについては、各規則の前件部においてファジィ変数を表すメンバーシップ関数の中心値、つまり図-1における $q$ を入力とし、その規則に対応する出力層ユニットの教師信号を1、他のものを0とし、すべての規則についてバックプロパゲーション法で学習したものを用いる。



3. 適用性の検討 図-2 ニューロ・ファジィモデルの推論過程（規則数が2つの場合）

本手法のリモートセンシングへの適用性の検討を行うため、三重県津市周辺を対象地域とし実際に土地被覆分類を行った。その際使用した観測データは、ランドサットMSSデータ4~7バンドであり、分類カテゴリ数は6と設定した。そこで、通常入力変数4、出力変数6の形で表現されるファジィ規則と対応したモデルを用いることになる。モデル構築にあたっては、対象地域と同一シーンから抽出したランドサットデータをニューラルネットワークのトレーニングデータとして学習を行い、抽出した画素に対応する地域の土地被覆状態を、後件部出力変数を表すファジィ変数

形成のために用いる。このモデルを用いることにより、前件部ファジィ変数を表すメンバーシップ関数のパラメータ同定が不要となる他、表-1に示す通り、ファジィ推論で規則数に左右され増減していく未判別画素がまったく発生しないという結果を得た。

なお、推定精度等からみた有効性の検討については、既存手法との比較を踏まえ当日会場にて発表する。

表-1 規則数による未判別画素発生割合 (%)

| 規則数 | ファジィ推論 | ニューロ・ファジィ |
|-----|--------|-----------|
| 10  | 22.60  | 0         |
| 20  | 18.71  | 0         |
| 50  | 15.15  | 0         |
| 100 | 7.54   | 0         |