

衛星データの土地被覆分類におけるニューロモデルの適用性

信州大学工学部 正会員 奥谷 巍
 信州大学工学部 正会員 高瀬 達夫
 信州大学工学部 ○ 染谷 純生

1. はじめに

遠隔的かつ広範囲にわたって、地表被覆情報の解析を行うリモートセンシングは、幅広い分野にわたってその利用方法が注目されている。また、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あげられており、近年急速に進む土地利用の高度化、多様化に伴い、土地利用を把握する上での、有効な手段として期待され、同時にその分類精度の向上が要求される。

そこで本稿では、小区域の土地被覆カテゴリの混在を前提とし、カテゴリ別面積割合を推定することに照準した2つの方法について検討するものとする。2つの方法は、いずれも入出力間の強い非線形的関数に対して柔軟性を発揮し得るニューロン機構を持つところに特徴がある。

2. 対象地域

本研究では神奈川県小田原市周辺の $4 \text{ km} \times 8 \text{ km}$ の矩形エリアを研究の対象地とした。また、この対象地域を2分割して、北側をトレーニングエリア、南側をテストエリアとする。

トレーニングエリアは、推定に用いるウェーブレットニューロンのパラメータ同定を行う地域である。テストエリアでは土地被覆状態の推定、つまり、面積割合の推定を行う。対象区域は、 $200\text{m} \times 200\text{m}$ の基本メッシュに区切り、その基本メッシュに対応して土地被覆カテゴリの面積割合の真値を、国土地理院発行の1/25,000 土地利用図及び同時期の1/10,000 航空写真を用いて求めた。

土地被覆カテゴリは、5種類（水域、農地、果樹園、森林、密集地）と13種類（水域、農地、果樹園、森林、草地、裸地、砂地、舗装路、鉄道路、構造物、鋼構造物コンクリート構造物、瓦屋根建物）のカテゴリを考えた。

3. ウェーブレットニューロンによる推定方法

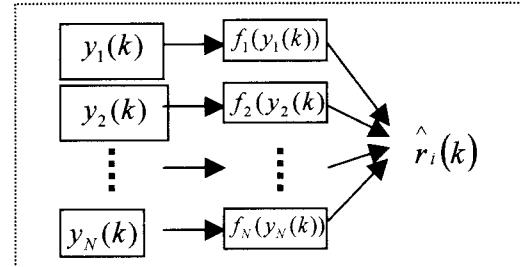
まず、最初にウェーブレットニューロンのパラメータの同定を行う。データとして与えられるものは、トレーニングエリア内のメッシュ k の土地被覆カテゴリ i の面積割合として $r_i(k)$ 、トレーニングエリア内のメッシュにおける衛星データのバンド j の平均値 $y_j(k)$ である。ただし、 $y_j(k)$ は輝度の最大値255で除して基準化しておく。

求める値は、土地被覆カテゴリ i のバンド j を入力とするニューロンの重み係数 θ_{ab}^{ji} である。

ウェーブレットニューロンは非線形のシナップスを持ち、ニューロン出力はそれら非線形シナップスの出力を加算するのみの単純な構造のものである。すなわち

$y_j(k)$ （但し $(j=1 \sim N)$ ）を入力とし、メッシュ k におけるカテゴリ i の面積割合の推定値 $\hat{r}_i(k)$ を出力値とするもので、ウェーブレットニューロンとして図1のような構造ものを考える。但し、 N は利用する衛星データのバンド数を表している。

図1 ウェーブレット構造図



各ウェーブレットシナップスでは、次式で表される特定の入力空間のみで定義されるコンパクトな“台”を持つウェーブレット関数を考える。¹⁾

$$\psi_{a,b}(x) = \psi(ax - b) \quad (1)$$

ただし

$$\psi(x) = \begin{cases} \cos \pi x & (-0.5 \leq x \leq 0.5) \\ 0 & (x < -0.5, 0.5 < x) \end{cases} \quad (2)$$

これらウェーブレットのうちのある特定のウェーブレットは、入力がある特定の範囲内の時のみ値を持つことから学習時間の格段の短縮が期待できる。

学習用データが K 組あるものとし、 $y_j(k)$ を k 組目のデータのシナップス j における入力値、 $f_j(y_j(k))$ を出力値としたとき

$$f_j(y_j(k)) = \sum_{a=0}^n \sum_{b=0}^a \theta_{a,b}^{ji} \psi_{a,b}(y_j(k)) \quad (3)$$

となる。ただし、 n は基底の深さである。また、総和の演算における b の範囲は一応 $0 \leq b \leq a$ としているが（1）、（2）式の関係を考慮すれば[]を端数打切りのガウス記号としたとき

$$b = [ay_j(k) + 0.5]$$

となるので、その b の値についてのみの加算でよいことがわかる。

（3）式よりメッシュ k の土地被覆カテゴリ i の面積割合 $r_i(k)$ の推定値 $\hat{r}_i(k)$ は

$$\hat{r}_i(k) = \sum_{j=1}^N f_j(y_j(k)) \quad (4)$$

と表される。

(1) 式の重み係数 θ_{ab}^{ji} は出力誤差の二乗 E を最小にするように調整していく。

$$E = \frac{1}{2} \sum_{k=1}^K \sum_{i=1}^M \left\{ r_i(k) - \hat{r}_i(k) \right\}^2 \rightarrow \min \quad (5)$$

$y_j(k)$ を入力した時の θ_{ab}^{ji} の修正量 $\Delta\theta_{ab}^{ji}$ は次式であらわされる。

$$\Delta\theta_{ab}^{ji} = -\alpha \frac{\partial E}{\partial \theta_{ab}^{ji}} = \alpha \sum_{k=1}^K \left\{ r_i(k) - \hat{r}_i(k) \right\} \psi_{a,b}(y_j(k)) \quad (6)$$

但し、 $0 < \alpha < 1$ である。(3) 式の重み係数は次式によって更新されていく。

$$\theta_{ab}^{ji} = \theta_{ab}^{ji} + \alpha \sum_{k=1}^K \left\{ r_i(k) - \hat{r}_i(k) \right\} \psi_{a,b}(y_j(k)) \quad (7)$$

ウェーブレットの重み係数が学習によって同定されると、テストエリアのメッシュ k における土地被覆カテゴリ i の面積割合の推定値は(4)式に当該メッシュのバンドデータを入力することにより求められる。

4. ニューラルネットワークにおける推定方法

本研究に用いた、3層ニューラルネットワークは、入力層、中間層、出力層からなるもので、階層型構造をもち、ユニット間の重みを教師つきで学習させるものでそれには、バックプロパゲーション法を用いている。

5. 5分類における推定結果の比較

図2は、5分類におけるニューラルネットワークとウェーブレットにおける学習スピード及び学習精度の比較である。これをみるとニューラルネットワークが学習回数1000回程度で一定の収束を終え、それ以降ほとんど変化がないのに対し、ウェーブレットの傾きは緩やかなものの最後まで収束に向かっていることがわかり、それは、図3の13分類についても同様なことがいえる。

また、学習スピードに対しても、ウェーブレットニューロンの学習スピードの方が速いということが分かる。

表1、表2は、ニューラルネットワークとウェーブレットの推定における各項目ごとのRMSEの値である。学習の段階では、ウェーブレットの値の方がニューラルネットワークの値よりも有効な値が出てることがわかる。

表3、4は、ウェーブレットとニューラルネットワークの全ての分類項目における誤差指標の比較である。表1、2と同様にニューラルネットワークの誤差指標値の方が効果的な値が出ている。

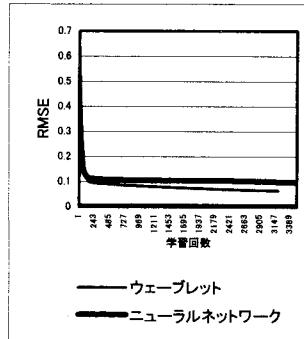


図2：ニューラルネットワークとウェーブレットの5分類におけるRMSEの変化

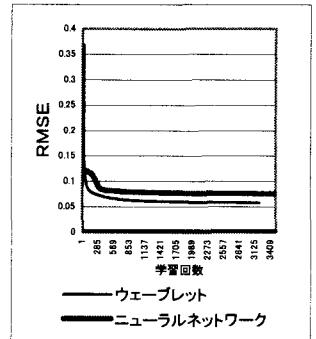


図3：ニューラルネットワークとウェーブレットの13分類におけるRMSEの変化

	NN	WV
水域	0.1008	0.1347
農地	0.0883	0.1004
果樹園	0.0944	0.1201
森林	0.1560	0.2132
密集地	0.1084	0.1423

表1：ニューラルネットワークとウェーブレットの5分類における各項目ごとのRMSEの値

	NN	WV	NN	WV
水域	0.1038	0.1339	舗装路	0.0871
農地	0.0522	0.0574	鉄道路	0.0757
果樹園	0.0663	0.0771	構造物	0.0503
森林	0.0915	0.0990	鋼構造物	0.0330
草地	0.1671	0.2321	C構造物	0.0980
裸地	0.1071	0.1147	瓦屋根建物	0.0982
砂地	0.0465	0.0498	全ての項目	0.0890
				0.1068

表2：ニューラルネットワークとウェーブレットの13分類における各項目ごとのRMSEの値（※C構造物はコンクリート構造物のこと）

	NN	WV
ρ	0.897	0.836
WRE	0.720	1.114
MAE	0.075	0.104
RMSE	0.112	0.147
η	0.820	0.747

表3：5分類におけるニューラルネットワークとウェーブレットの全ての分類項目における誤差指標の比較

	NN	WV
ρ	0.779	0.672
WRE	1.244	1.253
MAE	0.054	0.065
RMSE	0.089	0.107
η	0.679	0.592

表4：13分類におけるニューラルネットワークとウェーブレットの全ての分類項目における誤差指標の比較

6. 最後に

学習の段階では、ウェーブレットの方が効果的な値が出たが、推定においてはニューラルネットワークの方が効果的な値が出た。今後は、この結果を検討し精度の向上を行う必要があると考えられる。

【参考文献】

- 1) 中川嘉樹 他：ファジィ・ニューラルシステム 日本ファジィ学会
- 2) 奥谷巖 水谷好伸：ニューラルモデルによる信号交差点の遅れ関数の同定 土木学会中部支部研究発表論文