

最尤法のトレーニングクラスの補充抽出法*

1P-4

寺崎 浩 小西 一也 外岡 秀行 星 仰†

茨城大学‡

1 はじめに

従来、教師付き分類法の一つである最大尤度法では、教師データとなるトレーニング地区を解析者が指定する。このトレーニングデータの抽出には、経験と技術が必要であるが、この経験をして画像全体として、あるトレーニングクラスが抽出されないことがある[1]。このクラスの存在を見出すためのマンマシン処理としてトレーニングクラスの補充抽出を試みたので、その概要を述べる。

2 提案手法

本研究で提案するトレーニングクラスの補充抽出方法は、以下に示す4つのステップからなる。

STEP1: トレーニングデータの選定

詳細な現地調査の結果をもとにトレーニングデータ領域を選定する。この時、小西、星[2]が提案した切り出し法を用いることにする。この手法は、トレーニングデータとして指定した部分において、透明度の高いアルファチャンネルを合成することにより、ユーザが視覚的にピュアなデータと他のデータを区別する手法である。これにより、通常、白線で切り取っていたために隠れていた線上の領域が、はっきり表示されるという利点もあり、ピュアなトレーニングデータの選定が可能になる。

STEP2: トレーニングデータの統計値の算出

STEP1により選定されたトレーニングエリアにより、分類するカテゴリごとの平均値、分散、共分散の算出を行う。

STEP3: ヒストグラムを用いた補充クラスの抽出

STEP2により算出された各クラスの分散の最小値、最小から2番目の値、平均値の3通りから補充クラスの算出に使用する分散値をユーザが選択する。次に、各バンドごとの画像データのヒストグラムからユーザがそのバンド b の平均値 μ_b となる値を指定する。このとき、理想的なガウス分布になっている場合には、すべてのバンドの値を取る必要がないため、仮の値として、各バンドの最大値をそれぞれ平均値としておく。これにより、あるバンドでは値を選択しなくても自動的に最大値が平均値になる。また、あるバンド b のヒストグラムについて

ユーザが値 μ_b を選択すると、他のバンドのヒストグラムは、選択した値 μ_b に関し、ある幅 I_b を持つデータのヒストグラムに更新する。この幅 I_b は、上記の平均値 μ_b と、前に指定した分散を用い、指定された信頼区間係数 λ (ここでは信頼度は98%,95%,90%を用いる)により、区間幅 I_b が求められる。また、指定した値が画像のどの部分に当たるのかを表示することにより、ユーザが補充クラスの位置関係を視覚的に分かるようにする。STEP3を繰り返した回数だけ、補充クラスが抽出される。

STEP4: クラス領域の教師付き分類

STEP1で選定したトレーニングデータにより求められたクラスとSTEP3により補充したトレーニングクラスをもとに、教師付き分類のなかで最も一般的な最大尤度法を用いて[3]、分類を行う。この手法は、Bayesの定理に基礎を置く統計的手法である。最大尤度法のアルゴリズムは、画像のバンド数を n 、グランドトゥールスデータのクラスを l 、第 k クラスのグランドトゥールスデータの個数を m とすると、グランドトゥールスデータ x_{ik} は、式(1)で表せる。

$$x_{ik} = \{x_{ijk} | i = 1, m; j = 1, n; k = 1, l\} \quad (1)$$

\bar{x}_k は、クラス k の平均を、 S_k は、クラス k の分散共分散行列とすると、各画像データ $x = \{x_j | j = 1, n\}$ に対する第 k クラスの尤度 $f_k(x)$ は、式(2)で表せる。

$$f_k(x) = \frac{1}{(2\pi)^{\frac{n}{2}} |S_k|^{\frac{1}{2}}} \exp\left\{-\frac{1}{2} d_k^2\right\} \quad (2)$$

ここで、 $|S_k|$ は、 S_k の行列式であり、 x と x_k の距離 d_k は、式(3)で表せる。

$$d_k^2 = (x - \bar{x}_k)^t S_k^{-1} (x - \bar{x}_k) \quad (3)$$

式(2),(3)を用いることで、未知データは各尤度のうち最大尤度 $f_k(x)$ をもつクラス k へと割り当てる。

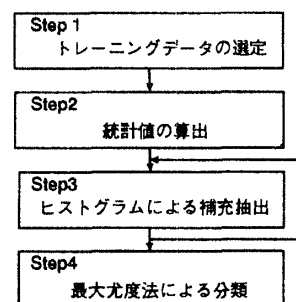


図1: 提案手法のフローチャート

*"Complementary extraction method of training class using maximum likelihood analysis"

†Hiroshi Terasaki, Kazuya Konishi, Hideyuki Tonooka, Takashi Hoshi

‡Ibaraki University

4-12-1 Naka-narusawa, Hitachi, Ibaraki 316, Japan

3 画像データおよび解析地区

本研究で用いた衛星データは、1994年4月22日に観測されたLANDSAT・TMデータ(PATH 107-ROW 35)である。分類精度を検証する上で繰り返し現地に赴けることを念頭におき、茨城県水戸市周辺を選定した。解析対象地区は水戸市周辺のサブシーンで、約15.3km×15.3km(512×512pixel)の地域である。この地域は、海洋(太平洋)、河川(那珂川)、湖沼(酒沼)と3種の水域が存在しているため、それらを考慮し、裸地、宅地、田畑、広葉樹、針葉樹、人工建造物と上記の3種の合計9種の分類項目とした。また、この画像を処理する前に、あらかじめ幾何補正、強調といった前処理を行う。

4 提案手法の適用結果

カラー合成画像には、バンド4,3,2を選定し、それぞれに3原色のR,G,Bを対応させた。まず、クラス毎に3つずつの教師データを与え、それらをトレーニングデータとした。ここで、クラスNo.と各カテゴリーの対応を、表1に示す。トレーニングデータにより求められた統計値のうち、適用画像のBand4における各クラスの平均値と標準偏差を表2に示す。また、本手法を用いるために必要な、各バンドに対する補充クラスの最小値、第2最小値、平均値のそれぞれの場合の標準偏差を表3に示す。ここで、Band4に対し、平均値として124.0を与えた。この時、他のバンドの分布がガウス分布に近似できる分布になったので、各クラスの最大値を平均値とした。通常の方法の分類画像と本手法を用いた分類画像の差画像を図2に示す。これにより新たに分類されたピクセルの全体画像に対する割合は、約10.7%であった。

表1: クラスNo.とカテゴリーの対応関係

クラスNo.	1	2	3	4	5
カテゴリー	海洋	湖沼	河川	裸地	宅地
クラスNo.	6	7	8	9	
カテゴリー	田畑	広葉樹	針葉樹	人工建造物	

表2: Band4の平均値と標準偏差

クラスNo.	平均値	標準偏差
1	7.8	4.1
2	31.5	4.3
3	41.6	6.7
4	97.5	12.7
5	144.6	18.5
6	169.5	11.3
7	163.9	17.0
8	222.8	23.3
9	199.9	24.2

5 分類結果に対する考察

図2,3より、新たに分類項目となった地区は、現地調査の結果、草地であることが判明した。用いた衛星データが4月下旬だったため、草地が全体にまんべんなく現われていることがわかる。よって、本手法を用いて新たにトレーニングクラスを抽出することで、誤分類されていた地区を少なく分類できたといえよう。

6 おわりに

本研究では、画像データのヒストグラムを利用することで、トレーニング地区データを補充抽出する一手法を提案した。実際の画像に適用することにより、この手法が有効であることが示された。また、ユーザが抽出するトレーニングデータに左右されてしまうことを考慮に入れ、今後、この手法の最適化や自動化をいかに行うかが課題となろう。

参考文献

- [1] Buttner, G., Hajos, T., and M. Korandi: "Improvement to the Effectiveness of Supervised Training Procedures", Int. J. Remote Sensing, Vol.10, No.3, pp.1005-1013, 1989
- [2] 小西 一也、星 仰: "アルファチャンネルによるカラー合成画像の切り出し効果", 情報処理学会第50回全国大会 2N-4, 1995.3
- [3] 土屋 清: "リモートセンシング概論", 朝倉書店, pp.206-209, 1990

表3: 補充クラスの標準偏差 (Band 2,3,4)

Band	最小値	第2最小値	平均値
4	4.1	4.3	15.4
3	6.3	6.8	14.9
2	8.0	8.1	17.2



図2: 追加トレーニングの有無による分類の差画像