

気象衛星の画像データによる客観的雲形判別方法について

Reviews of Objective Cloud Type Classification Using Satellite Image Data

加藤 一 靖

Kazuyasu Kato

はじめに

GMSS (Geostationary Meteorological Satellite System) における画像処理では人間の優れたパターン認識の能力と計算機の特徴である高速演算とを組み合わせた会話型処理を行なっている。会話型処理の典型である風計算処理、雲頂高度算出処理では雲画像の気象学的特徴を解析者が判断し、追跡雲の選択、測定点の位置、雲形、雲層の大小、等の情報を計算機に入力している。これらの処理では均質で、しかも多量のデータを短時間に出力することは困難であり、熟練した解析者の判断が必要である。

近年、計算機の処理能力の増大、画像データのデジタル化、多チャンネル化、パターン認識手法の発達、等によって、熟練した解析者の判断に近い情報を客観的にかつ多量に得る各種の方法が開発されるようになった。衛星で観測される画像データを入力として、計算機処理によって雲形を判別する方法（以下、雲形判別方法と称する）もその中の一つである。

画像データから気象要素（例えば、雲移動ベクトル、雲頂高度など）を抽出する場合には雲域の選択や雲形判別などの操作が必要であり、その精度が抽出される気象要素の品質に大きく影響する。雲移動ベクトルを算出する際に、周囲の大気の流れ（風）にそって移動すると考えられる小積雲を選択するという操作（雲指定という）などは、その典型である。Parikh (1977) は雲形判別の目的の一つに、この雲指定をあげている。また、雲形と降雨量、湿度などは密接な関係があることから、雲形判別方法を利用することによって、これらの量の推定に応用できる。

気象衛星センターでは雲形判別を客観的に行なうアルゴリズムの開発に必要な予備調査を1978年に着手し、1979年には一応の成果（文献12）が出されている。この報告は、アルゴリズムの開発に先立って行なった雲形判別アルゴリズムのモデル調査を中心に、最辺の成果を含めて、まとめたものである。予備調査の内容については次号に報告する予定である。

1. 判別方法の種類

リモートセンシングの分野では「分類」という言葉が一般的であるが、この報告では「判別」という言葉で統一した。判別方法を大別すると、教師付判別 (supervised classification) と教師なし判別 (unsupervised classification) に分けることができる。前者は、あるデータが確率的にどのグループに属するかを、グランドトゥースデータ (ground-truth data) をもちいて判別するもので、雲形の判別に利用される方法のほとんどはこれに属する。後者はデータの属性のみを使用して、属性が同一と思われるグループに判別するものである。

教師付判別方法では最短距離法 (minimum distance method)、最尤法 (maximum likelihood method)、などが良く知られた方法である。前者は距離の概念（これについては後述する）をもちいて、データからの距離が最小であるようなグループに判別するものである。これに対して後者の方法は、データの尤度（確率密度関数）が最大になるグループに属すると判別するものである。

以下の説明では最短距離法を中心に述べることにする。

2. 距離の概念と判別方法

多変量のデータを的確に評価する方法として多変量解析法 (Multivariate Analysis) があり、その手法の一つに判別分析法 (Discriminant Analysis) がある。これは、二つ以上の母集団から取り出した多変量のデータ（説明変数）にもとづいて、与えられたサンプルがどの母集団（目的変数）に属するかを判別する方法である。判別する尺度として多次元空間における「距離」の概念がもちいられる。多変量解析法については奥野忠一、他 (1971) や柳井晴夫、他 (1977) に詳細に述べられており、以下の説明では主として前者のものを参考にした。

雲形 i を特徴づけるパラメータ（以下、雲特徴パラメータとする）が p 個存在するとする。雲特徴パラメータの観測ベクトルを \mathbf{x} とすると、それが雲形 i で生ずる確率（確率密度関数） $P(\mathbf{x}|i)$ は p 次元正規分布を仮定す

れば (2.1) 式のようになる。

$$P(\mathbf{x}|i) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} \mathbf{Q}_i^2\right) \quad (2.1)$$

\mathbf{Q}_i^2 は一般にマハラノビスの距離 (Mahalanobis generalized distance) とよばれており次式で定義される。

$$\mathbf{Q}_i^2 = (\mathbf{x} - \boldsymbol{\mu}_i)^t \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \quad (2.2)$$

ただし、

- $\boldsymbol{\mu}_i$: 雲形 i の雲特徴パラメータの平均ベクトル、
- Σ_i : 雲形 i の雲特徴パラメータのベクトル分散行列 (群内分散・共分散行列)、
- Σ_i^{-1} : ベクトル分散行列 Σ_i の逆行列、
- $(\mathbf{x} - \boldsymbol{\mu}_i)^t$: ベクトル $(\mathbf{x} - \boldsymbol{\mu}_i)$ の転置行列、

$p=2$ (2変数) の場合のマハラノビスの距離を求めると次のようになる。観測値を x_1, x_2 , 共分散行列 Σ およびその逆行列を Σ^{-1} , x_1 および x_2 の分散を σ_1, σ_2 , 両者の共分散を $\sigma_{12} (= \sigma_{21})$, 相関係数を ρ とする。 Σ および Σ^{-1} は次のように定義する。

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{pmatrix} = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix} \quad (2.3)$$

$$\Sigma^{-1} = \begin{pmatrix} \sigma_2^2 & -\rho\sigma_1\sigma_2 \\ -\rho\sigma_1\sigma_2 & \sigma_1^2 \end{pmatrix} / (1 - \rho^2) \sigma_1^2 \sigma_2^2 \quad (2.4)$$

したがって \mathbf{Q}^2 は

$$\begin{aligned} \mathbf{Q}^2 &= (\mathbf{x} - \boldsymbol{\mu})^t \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) \\ &= (x_1 - \mu_1, x_2 - \mu_2) \begin{pmatrix} \sigma_2^2 & -\rho\sigma_1\sigma_2 \\ -\rho\sigma_1\sigma_2 & \sigma_1^2 \end{pmatrix} \\ &\quad \times \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix} / (1 - \rho^2) \sigma_1^2 \sigma_2^2 \\ &= \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} \right. \\ &\quad \left. - \frac{2\rho(x_1 - \mu_1)(x_2 - \mu_2)}{\sigma_1\sigma_2} \right\} / (1 - \rho^2) \\ &= (u_1^2 + u_2^2 - 2\rho u_1 u_2) / (1 - \rho^2) \quad (2.5) \end{aligned}$$

ただし、 $u_1^2 = (x_1 - \mu_1)^2 / \sigma_1^2$, $u_2^2 = (x_2 - \mu_2)^2 / \sigma_2^2$ であり、平方距離とよばれる量である。これを導入すれば (2.5) 式は

$$\mathbf{Q}^2 = \mathbf{u}^t \mathbf{R}^{-1} \mathbf{u} \quad (2.6)$$

ここで、 \mathbf{R}^{-1} は相関行列 \mathbf{R} の逆行列で以下のように定義される。

$$\mathbf{R} = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}, \quad \mathbf{R}^{-1} = \begin{pmatrix} 1 & -\rho \\ -\rho & 1 \end{pmatrix} / (1 - \rho^2)$$

$p=1$ の場合、平方距離 u^2 は (2.2) 式の形式をもちいと次式のように表現できる。

$$u^2 = (x - \mu) (\sigma^2)^{-1} (x - \mu) = \mathbf{Q}^2 \quad (2.7)$$

つまり、平方距離とマハラノビスの距離は等しいことがわかる。

2.1 距離による判別

2.1.1 母平均からの距離による判別 (1変数)

観測値 x ($p=1$) から雲形 G_1, G_2 に判別する場合を考える。観測値の平均値を μ_1, μ_2 , 分散を σ^2 (G_1 と G_2 では等しいとする) とする。マハラノビスの距離 $\mathbf{Q}_1^2, \mathbf{Q}_2^2$ は (2.7) 式から

$$\begin{aligned} \mathbf{Q}_1^2 &= (x - \mu_1)^2 / \sigma^2 \\ \mathbf{Q}_2^2 &= (x - \mu_2)^2 / \sigma^2 \end{aligned}$$

\mathbf{Q}_1^2 と \mathbf{Q}_2^2 を比較して小さい方に雲形を判別すればよいので、 $\mathbf{Q}_1^2 > \mathbf{Q}_2^2$ ならば G_2 へ、 $\mathbf{Q}_1^2 < \mathbf{Q}_2^2$ なら G_1 として良い。ところで、 $\mathbf{Q}_1^2 - \mathbf{Q}_2^2$ を考えてみると次式のようになる。

$$\begin{aligned} \mathbf{Q}_1^2 - \mathbf{Q}_2^2 &= \{(x - \mu_1)^2 - (x - \mu_2)^2\} / \sigma^2 \\ &= \{-2(\mu_1 - \mu_2)x + \mu_1^2 - \mu_2^2\} / \sigma^2 \\ &= \frac{-2(\mu_1 - \mu_2)}{\sigma^2} \left(x - \frac{(\mu_1 + \mu_2)}{2} \right) \\ &= \frac{-2(\mu_1 - \mu_2)(x - \bar{\mu})}{\sigma^2} \quad (2.8) \end{aligned}$$

この式による判別では $\mu_1 < \mu_2$ のとき、 $x > \bar{\mu}$ なら G_2 へ、 $x < \bar{\mu}$ なら G_1 のようになる。つまり、二つの母平均の中心 $\bar{\mu}$ のどちら側に x があるかによって G_1 か G_2 が決る。

2.1.2 マハラノビスの距離による多群の判別

観測値 (x_1, x_2) の2群の母平均 $(\mu_1^{(1)}, \mu_2^{(2)})$, $(\mu_1^{(2)}, \mu_2^{(2)})$ からの $\mathbf{Q}_1^2, \mathbf{Q}_2^2$ を求め、 $\mathbf{Q}_1^2 = \mathbf{Q}_2^2$ になるような点の軌跡を考える。(2.5) 式によれば

$$Q_1^2 = \frac{1}{1-\rho^2} \left\{ \left(\frac{x_1 - \mu_1^{(1)}}{\sigma_1} \right)^2 + \left(\frac{x_2 - \mu_2^{(2)}}{\sigma_2} \right)^2 - 2\rho \left(\frac{x_1 - \mu_1^{(1)}}{\sigma_1} \right) \left(\frac{x_2 - \mu_2^{(2)}}{\sigma_2} \right) \right\} \quad (2.9)$$

$$Q_2^2 = \frac{1}{1-\rho^2} \left\{ \left(\frac{x_1 - \mu_1^{(2)}}{\sigma_1} \right)^2 + \left(\frac{x_2 - \mu_2^{(1)}}{\sigma_2} \right)^2 - 2\rho \left(\frac{x_1 - \mu_1^{(2)}}{\sigma_1} \right) \left(\frac{x_2 - \mu_2^{(1)}}{\sigma_2} \right) \right\} \quad (2.10)$$

$\bar{\mu}_1 = (\mu_1^{(1)} + \mu_1^{(2)})/2$, $\bar{\mu}_2 = (\mu_2^{(1)} + \mu_2^{(2)})/2$ とおけば, Q_1^2 と Q_2^2 の差は

$$Q_2^2 - Q_1^2 = \frac{1}{1-\rho^2} \left\{ \frac{2(\mu_1^{(1)} - \mu_1^{(2)})(x_1 - \bar{\mu}_1)}{\sigma_1^2} + \frac{2(\mu_2^{(1)} - \mu_2^{(2)})(x_2 - \bar{\mu}_2)}{\sigma_2^2} - \frac{2\rho}{\sigma_1\sigma_2} \left((x_1 - \bar{\mu}_1)(\mu_2^{(1)} - \mu_2^{(2)}) + (x_2 - \bar{\mu}_2)(\mu_1^{(1)} - \mu_1^{(2)}) \right) \right\}$$

x_1, x_2 の項ごとにとまとめると, 上式は

$$= \frac{2}{1-\rho^2} \left\{ \left(\frac{\mu_1^{(1)} - \mu_1^{(2)}}{\sigma_1^2} - \rho \frac{\mu_2^{(1)} - \mu_2^{(2)}}{\sigma_1\sigma_2} \right) (x_1 - \bar{\mu}_1) + \left(\frac{\mu_2^{(1)} - \mu_2^{(2)}}{\sigma_2^2} - \rho \frac{\mu_1^{(1)} - \mu_1^{(2)}}{\sigma_1\sigma_2} \right) (x_2 - \bar{\mu}_2) \right\} = a_1(x_1 - \bar{\mu}_1) + a_2(x_2 - \bar{\mu}_2) \equiv Z \quad (2.11)$$

一方, 母平均の差を次式のようにおくとする。

$$\delta_1 = \mu_1^{(1)} - \mu_1^{(2)}, \quad \delta_2 = \mu_2^{(1)} - \mu_2^{(2)}, \quad \delta = \begin{pmatrix} \delta_1 \\ \delta_2 \end{pmatrix} \quad (2.12)$$

(2.4) 式の逆行列を変形して, 次式のように書き直す。

$$\Sigma^{-1} = \frac{1}{(1-\rho^2)} \begin{pmatrix} \frac{1}{\sigma_1^2} & \frac{-\rho}{\sigma_1\sigma_2} \\ \frac{-\rho}{\sigma_1\sigma_2} & \frac{1}{\sigma_2^2} \end{pmatrix} = \begin{pmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{pmatrix} \quad (2.13)$$

したがって, (2.11) 式は

$$Z = 2 \{ (\sigma_{11}\delta_1 + \sigma_{12}\delta_2)(x_1 - \bar{\mu}_1) + (\sigma_{21}\delta_1 + \sigma_{22}\delta_2)(x_2 - \bar{\mu}_2) \} = 2(x - \bar{\mu})^t \alpha \quad (2.14)$$

ここで,

$$x - \bar{\mu} = \begin{pmatrix} x_1 - \bar{\mu}_1 \\ x_2 - \bar{\mu}_2 \end{pmatrix}, \quad \alpha = \Sigma^{-1}\delta = \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} \quad (2.15)$$

以上のように, 両群からの距離の等しい点 ($Q_1 = Q_2$) の軌跡は (2.11) 式または (2.14) 式のように直線となる。これを判別関数とよぶ。この直線を境界として, どちらの集団に属するかを判別することができる。

$p \geq 2$ の場合も同様に導くことができる。(2.2) 式の表現では

$$\begin{aligned} Q_1^2 &= (x - \mu^{(1)})^t \Sigma^{-1} (x - \mu^{(1)}) \\ Q_2^2 &= (x - \mu^{(2)})^t \Sigma^{-1} (x - \mu^{(2)}) \\ Q_1^2 - Q_2^2 &= 2x^t \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) - (\mu^{(1)t} \Sigma^{-1} \mu^{(1)} - \mu^{(2)t} \Sigma^{-1} \mu^{(2)}) \\ &= 2x^t \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) - \{ (\mu^{(1)} + \mu^{(2)})^t \Sigma^{-1} \mu^{(1)} - (\mu^{(1)} + \mu^{(2)})^t \Sigma^{-1} \mu^{(2)} \} \\ &= 2x^t \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) - 2\bar{\mu}^t \Sigma^{-1} (\mu^{(1)} - \mu^{(2)}) \\ &= 2(x - \bar{\mu})^t \Sigma^{-1} \delta = 2(x - \bar{\mu})^t \alpha = Z \end{aligned} \quad (2.16)$$

これは次式のように展開することができる。

$$Z = a_1(x_1 - \bar{\mu}_1) + a_2(x_2 - \bar{\mu}_2) + \dots + a_p(x_p - \bar{\mu}_p) = a^t(x - \bar{\mu}) \quad (2.17)$$

以上では, $i=2$ (雲形の数 (グループ) が 2) の場合について考察したが, 次に $i=3$ で雲特徴パラメータ数 p の場合を考える。今までの議論から, 観測ベクトルの各雲形の重心からの Q_i^2 を求め, その値が最も小さい雲形に属すると判定する (最尤法)。 Σ は各雲形で等しいとすると,

$$\left. \begin{aligned} Q_1^2 &= (x - \mu^{(1)})^t \Sigma^{-1} (x - \mu^{(1)}) \\ &= x^t \Sigma^{-1} x - 2x^t \Sigma^{-1} \mu^{(1)} + \mu^{(1)t} \Sigma^{-1} \mu^{(1)} \\ Q_2^2 &= x^t \Sigma^{-1} x - 2x^t \Sigma^{-1} \mu^{(2)} + \mu^{(2)t} \Sigma^{-1} \mu^{(2)} \\ Q_3^2 &= x^t \Sigma^{-1} x - 2x^t \Sigma^{-1} \mu^{(3)} + \mu^{(3)t} \Sigma^{-1} \mu^{(3)} \end{aligned} \right\} \quad (2.18)$$

Q_i^2 の第 1 項は各雲形 (群) で共通であり, Q_i^2 の大小を比較する場合は考慮しなくてもよい。第 3 項は各雲

形で定まる定数と考えることができるので、これを改めて C_i とおく。したがって、実際に必要なものは第2項である。

$$2\mathbf{x}^t(\Sigma^{-1}\boldsymbol{\mu}^{(i)}) = \sum_{n=1}^p a_n^{(i)} x_n \quad (2.19)$$

各雲形間1, 2間の Q^2 の差を L_{12} のように示すと

$$\left. \begin{aligned} L_{12} &= Q_1^2 - Q_2^2 = \sum_{n=1}^p (a_n^{(2)} - a_n^{(1)}) x_n \\ &\quad + (C_1 - C_2) \\ L_{23} &= Q_2^2 - Q_3^2 = \sum_{n=1}^p (a_n^{(3)} - a_n^{(2)}) x_n \\ &\quad + (C_2 - C_3) \\ L_{31} &= Q_3^2 - Q_1^2 = \sum_{n=1}^p (a_n^{(1)} - a_n^{(3)}) x_n \\ &\quad + (C_3 - C_1) \end{aligned} \right\} \quad (2.20)$$

これらの式から、以下の三つの判別結果が得られる。

$$\left. \begin{aligned} L_{12} < 0 \text{ のとき, 雲形1に属する} \\ L_{23} > 0 \text{ のとき, 雲形3に属する} \\ L_{31} > 0 \text{ のとき, 雲形1に属する} \end{aligned} \right\}$$

したがって、二つの判別結果の一致した雲形1に属すると判別することになる。このような判別方法は、マハラノビスの距離を用いた最短距離法とよばれる。一般的には、“ $k \neq i$ のすべての $k(k=1, n)$ に対して、 $Q_i^2 < Q_k^2$ のとき観測ベクトル \mathbf{x} は雲形 i に属する” のように表現することができる。

2.1.3 事前確率を考慮した最尤法による判別

p 次元正規分布を仮定し、事前確率を考慮しない(等確率) $P(\mathbf{x}|i)$ は(2.1)式のように与えられる。(2.1)式の対数を求めてみると

$$\begin{aligned} L_i(\mathbf{x}) &\equiv \ln(P(\mathbf{x}|i)) \\ &= -\frac{1}{2}\{l_n(\Sigma_i) + Q_i^2\} - \frac{p}{2}l_n(2\pi) \end{aligned} \quad (2.21)$$

最尤法では $L_i(\mathbf{x})$ が最大であるような雲形 i に \mathbf{x} を割り当てると考えることができる。したがって、(2.21)式の右辺第1項を改めて $Z_i(\mathbf{x})$ のようにおくと(第2項は定数),

$$\begin{aligned} Z_i(\mathbf{x}) &\equiv \ln(\Sigma_i) + Q_i^2 \\ &= \ln(\Sigma_i) + (\mathbf{x} - \boldsymbol{\mu}_i)^t \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \end{aligned} \quad (2.22)$$

$L_i(\mathbf{x})$ が最大であることは $Z_i(\mathbf{x})$ が最小であること

を意味するので、最尤法では $Z_i(\mathbf{x})$ が最小であるような \mathbf{x} を雲形 i に判別するといえる。すなわち、“ $k \neq i$ のすべての $k(k=1, n)$ に対して、 $Z_i(\mathbf{x}) < Z_k(\mathbf{x})$ のとき観測ベクトル \mathbf{x} は雲形 i に属する” のように表現することができる。なお、各雲形で群内分散、共分散ベクトル Σ が等しい場合は(2.22)式の右辺第1項は定数になるので、最尤法とマハラノビスの距離をもちいた最短距離法とは等しくなる。

雲形の事前確率 q_i 、観測ベクトル \mathbf{x} が雲形 i に属する確率 $P(i|\mathbf{x})$ 、雲形数を m とすると

$$P(i|\mathbf{x}) = P(\mathbf{x}|i) \cdot q_i / \sum_{k=1}^m P(\mathbf{x}|k) \cdot q_k \quad (2.23)$$

(2.23)式の分母は各雲形で共通であるので、 $p(i|\mathbf{x})$ の大小の比較は分子のみ考慮すればよい。分子の対数をとり次のようにおく。

$$\begin{aligned} L_i(\mathbf{x}) &= \ln\{P(\mathbf{x}|i) \cdot q_i\} \\ &= -\frac{1}{2}\{l_n(\Sigma_i) + Q_i^2\} - \frac{p}{2}l_n(2\pi) + \ln q_i \end{aligned} \quad (2.24)$$

Σ_i が各雲形で等しいとすると ($\Sigma_i \equiv \Sigma$), Q_i^2 は

$$\begin{aligned} Q_i^2 &= (\mathbf{x} - \boldsymbol{\mu}_i)^t \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \\ &= \mathbf{x}^t \Sigma^{-1} \mathbf{x} - 2\left\{\boldsymbol{\mu}_i^t \Sigma^{-1} \mathbf{x} - \frac{1}{2}\boldsymbol{\mu}_i^t \Sigma^{-1} \boldsymbol{\mu}_i\right\} \end{aligned} \quad (2.25)$$

したがって(2.24)式は

$$\begin{aligned} L_i(\mathbf{x}) &= -\frac{1}{2}Q_i^2 + \ln q_i - \frac{1}{2}(l_n(\Sigma) + p l_n(2\pi)) \\ &= \left(\boldsymbol{\mu}_i^t \Sigma^{-1} \mathbf{x} - \frac{1}{2}\boldsymbol{\mu}_i^t \Sigma^{-1} \boldsymbol{\mu}_i + \ln q_i\right) \\ &\quad - \frac{1}{2}\{\mathbf{x}^t \Sigma^{-1} \mathbf{x} + l_n(\Sigma) + p l_n(2\pi)\} \end{aligned} \quad (2.26)$$

(2.26)式の第2項は各雲形で共通なので、 $L_i(\mathbf{x})$ の大小は第1項のみを考慮すればよく、これを改めて δ_i^2 とおくと

$$\delta_i^2 = \boldsymbol{\mu}_i^t \Sigma^{-1} \mathbf{x} - \frac{1}{2}\boldsymbol{\mu}_i^t \Sigma^{-1} \boldsymbol{\mu}_i + \ln q_i \quad (2.27)$$

したがって、与えられた q_i について、 δ_i^2 が最大になるような \mathbf{x} を雲形 i に判別すればよい。実際には各雲形の Σ や $\boldsymbol{\mu}$ も未知であるため、雲形判別を行なうためにはこれらの量の推定から初めなければならない。

分類すべか雲形数を m 、雲形 i から p 個の雲特徴パラ

メータをもつ観測ベクトルが n_i 個無作為抽出されたとする。雲形 i の観測ベクトルを $\mathbf{x}_{ii}(1 \leq i \leq n_i)$ とし、雲形 i の母数 μ_i の不偏推定量 $\bar{\mathbf{x}}_i$ 、群内分散・共分散 Σ の不偏推定量 \mathbf{u} とすれば、

$$\left. \begin{aligned} \bar{\mathbf{x}}_i &= \frac{1}{n_i} \sum_{l=1}^{n_i} \mathbf{x}_{il} \\ \mathbf{u} &= \frac{1}{\sum_{i=1}^m n_i - p} \sum_{i=1}^m \sum_{l=1}^{n_i} (\mathbf{x}_{il} - \bar{\mathbf{x}}_i) (\mathbf{x}_{il} - \bar{\mathbf{x}}_i)^t \end{aligned} \right\} \quad (2.28)$$

これらを (2.27) 式にもちいれば

$$\delta_i^2 = \bar{\mathbf{x}}_i^t \mathbf{u}^{-1} \mathbf{x} - \frac{1}{2} \bar{\mathbf{x}}_i^t \mathbf{u}^{-1} \mathbf{x}_i + l_n q_i \quad (2.29)$$

観測ベクトル \mathbf{x} が得られたとき、どの雲形に属するかは δ_i^2 が最大になるものをさがせばよいことになる。 δ_i^2 は \mathbf{x} の一次式なので以下のように展開することができる。

$$\begin{aligned} \delta_i^2 &= \sum_{j=1}^p \left(\sum_{k=1}^p \bar{x}_{ki} u_{kj}^2 \right) x_j \\ &+ \left(-\frac{1}{2} \sum_{j=1}^p \sum_{k=1}^p \bar{x}_{ki} u_{kj}^2 \bar{x}_{ji} + l_n q_i \right) \end{aligned} \quad (2.30)$$

ここで、

$$\left. \begin{aligned} C_{ji} &= \sum_{k=1}^p \bar{x}_{ki} u_{kj}^2 \\ C_{0i} &= -\frac{1}{2} \sum_{j=1}^p \sum_{k=1}^p \bar{x}_{ki} u_{kj}^2 \bar{x}_{ji} \\ &= -\frac{1}{2} \sum_{j=1}^p C_{ji} \bar{x}_{ji} \end{aligned} \right\} \quad (2.31)$$

のようにおくと、(2.30) は

$$\delta_i^2 = \sum_{j=1}^p C_{ji} x_j + C_{0i} + l_n q_i \quad (2.32)$$

なお、 \mathbf{x}^t 、 $\bar{\mathbf{x}}_i^t$ 、 \mathbf{u} はそれぞれ以下のようにおいた。

$$\begin{aligned} \mathbf{x}^t &= (x_1, x_2, \dots, x_m) \\ \bar{\mathbf{x}}_i^t &= (\bar{x}_{1i}, \bar{x}_{2i}, \dots, \bar{x}_{mi}) \\ \mathbf{u} &= \begin{pmatrix} u_{11}^2, & u_{12}^2, & \dots, & u_{1m}^2 \\ u_{21}^2, & u_{22}^2, & \dots, & u_{2m}^2 \\ \vdots & \vdots & & \vdots \\ u_{m1}^2, & u_{m2}^2, & \dots, & u_{mm}^2 \end{pmatrix} \end{aligned}$$

2.2 フィッシャーの距離

雲特徴パラメータとして多数のパラメータを使用する場合、判別効率の良いパラメータの選択、組合せを考える必要がある。その際、簡便な距離としてフィッシャーの距離 (Fisher distance) がもちいられる。Parikh (1977) は多数の雲特徴パラメータの中から有効なパラメータを選択する手段として、この距離を使用した。雲特徴パラメータ k の雲形 i, j における観測ベクトルの平均値を μ_{ik} 、 μ_{jk} 、その標準偏差を σ_{ik} 、 σ_{jk} とすると、フィッシャーの距離 J_k は次式のように定義される。

$$J_k = \frac{|\mu_{ik} - \mu_{jk}|}{\sigma_{ik} + \sigma_{jk}} \quad (2.33)$$

雲特徴パラメータ k による雲形 i, j の判別は J_k が大きい程、有効であるとするものである。

3. 雲特徴パラメータ

雲形判別に使用される雲特徴パラメータは大別するとスペクトラル特徴 (spectral feature) とテクスチャル特徴 (textural feature) に分類される。前者は観測する波長域に依存する情報で、測定領域内の画像データから得られる最低、平均、最大温度や温度の標準偏差などがその例である。後者は測定領域の表面状態に関する情報で、方向性を考慮した差分ヒストグラムから得られるコントラスト、エントロピーなどがその例である。

その他に雲の大きさの分布に関する情報としてパワースペクトラムがある。Booth (1973, a, b) が雲特徴パラメータとして使用した例があるが、一般にはあまり利用されていないようである。

以下では雲形判別方法でもちいられる雲特徴パラメータの種類とその算出方法の概略について述べる。

3.1 スペクトラル特徴

Parikh (1977) が使用した例を Table 3.1 に示す。測定領域内の画像データから得られるヒストグラムの形状に関する情報とみなすことができる。彼の場合、特徴番号 1~20 は可視、赤外画像データの両方で算出しているが、特徴番号 21~25 は赤外画像データのみを使用している。表中にある QUAD の意味は、測定領域を 4 等分した領域に関する情報であることを示している。Table 3.1 に示した雲特徴パラメータは代表的なものであるが、それ以外に変異係数、歪度、尖度などが考えられる。

n ライン、 m 画素から構成される測定領域内で、 i ライン、 j 画素目の画像データを x_{ij} 、画像データの平均値、標準偏差をそれぞれ \bar{x} 、 σ 、全画素数を $N (= n \times m)$

Table 3.1 Spectral features. Features 21-25 were calculated only on infrared data arrays. Features 1-20 were calculated on both visible and infrared data array. (after Parikh, 1977)

Feature number(s)	Feature description
1	Mean
2	Standard deviation
3-13	Values at 0%, 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90%, and 100% cumulative frequencies
14-20	Differences (ranges) between values at cumulative frequencies 0% and 100%, 10% and 90%, 0% and 50%, 50% and 100%, 20% and 80%, 30% and 70%, and 40% and 60%
21	Maximum of differences (R10-90 _{QUAD}) between quadrant values for cumulative frequencies 10% and 90%
22	Difference between maximum and minimum values of (R10-90 _{QUAD})
23	Difference between maximum and minimum of quadrant values for 0% cumulative frequency
24	Maximum of quadrant standard deviations
25	Difference between maximum and minimum of quadrant standard deviations

とする。変異係数，歪度，尖度はそれぞれ次式から求められる。

$$\text{変異係数} = \sigma / \bar{x} \quad (3.1)$$

$$\text{歪度} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m (x_{ij} - \bar{x})^3 / \sigma^3 \quad (3.2)$$

$$\text{尖度} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m (x_{ij} - \bar{x})^4 / \sigma^4 \quad (3.3)$$

$$M(\rho, \theta) = \frac{1}{nl} \sum_{i=1}^{nl} i \left(\frac{f(i)}{N} \right) \quad (3.4)$$

$$C(\rho, \theta) = \sum_{i=1}^{nl} i^2 \left(\frac{f(i)}{N} \right) \quad (3.5)$$

$$A(\rho, \theta) = \sum_{i=1}^{nl} \left(\frac{f(i)}{N} \right)^2 \quad (3.6)$$

$$E(\rho, \theta) = - \sum_{i=1}^{nl} \left(\frac{f(i)}{N} \right) \cdot \ln \left(\frac{f(i)}{N} \right) \quad (3.7)$$

3.2 テクスチャル特徴

Parikh (1977) が使用した例を Table 3.2 に示した。この表に示した各パラメータは以下のようにして算出している。

ある測定領域について，差分をとる2点間の距離，方向をそれぞれ ρ, θ とする。画像データの差分（輝度レベル，等価黒体温度，アルベードなど）の絶対値をクラス分けしたときの値を i ，その度数を $f(i)$ ，クラス数を nl とする。 $f(i)$ から平均値 $M(\rho, \theta)$ ，コントラスト $C(\rho, \theta)$ ，角二次モーメント $A(\rho, \theta)$ ，エントロピー $E(\rho, \theta)$ は，

ただし， N は与えられた ρ, θ で，差分をとる2点を1ペアとしたときのペア数である。

Harris and Barret (1978) は雲特徴パラメータとしてベクトル分散 (vector dispersion) をもちいた。Fig. 3.1 はベクトル分散の概念を示すものである。隣接する3点の画像データによって定まる平面の方向余弦を (l, m, n) ，極ベクトル (λ, μ, ν) の最尤値を (l, m, n) とすると，

$$l = \left(\frac{1}{R} \right) \sum l_i, \quad m = \left(\frac{1}{R} \right) \sum m_i, \quad n = \left(\frac{1}{R} \right) \sum n_i$$

Table 3.2 Textural feature. These were evaluated for four directions (θ =Horizontal, Vertical, Right Diagonal, Left Diagonal) and four distances ($\rho=1, 2, 4, 8$) on both visible and infrared data arrays. (after Parikh, 1977)

Feature number(s)	Feature description
26-41	Mean (ρ, θ)
42-57	Contrast (ρ, θ)
58-73	Angular Second Moment (ρ, θ)
74-89	Entropy (ρ, θ)
90-105	Mean ($\bar{\rho}$) of Mean ($\bar{\rho}, \theta$), of Contrast ($\bar{\rho}, \theta$), of Angular Second Moment ($\bar{\rho}, \theta$), and of Entropy ($\bar{\rho}, \theta$), all for $\rho = \bar{\rho}$
106-121	Standard Deviation ($\bar{\rho}$) of Mean ($\bar{\rho}, \theta$), of Contrast ($\bar{\rho}, \theta$), of Angular Second Moment ($\bar{\rho}, \theta$), and of Entropy ($\bar{\rho}, \theta$), all for $\rho = \bar{\rho}$
122-137	Minimum ($\bar{\rho}$) of Mean ($\bar{\rho}, \theta$), of Contrast ($\bar{\rho}, \theta$), of Angular Second Moment ($\bar{\rho}, \theta$), and of Entropy ($\bar{\rho}, \theta$), all for $\rho = \bar{\rho}$
138-153	Maximum ($\bar{\rho}$) of Mean ($\bar{\rho}, \theta$), of Contrast ($\bar{\rho}, \theta$), of Angular Second Moment ($\bar{\rho}, \theta$), and of Entropy ($\bar{\rho}, \theta$), all for $\rho = \bar{\rho}$
154-169	Range ($\bar{\rho}$) between Minimum ($\bar{\rho}$) and Maximum ($\bar{\rho}$) for Mean ($\bar{\rho}, \theta$), Contrast ($\bar{\rho}, \theta$), Angular Second Moment ($\bar{\rho}, \theta$), and Entropy ($\bar{\rho}, \theta$)




Fig. 3.1 A graphical representation of the vector dispersion technique. A smooth surface is represented by (a) and a rough surface by (b). The left side of the diagram shows the plane normals (vectors) located at a common origin. (Source, Hobson, 1972) (after Harris and Barret, 1978)

ただし、 R^2 は次式で定義される。

$$R^2 = (\sum l_i)^2 + (\sum m_i)^2 + (\sum n_i)^2 \quad (3.8)$$

一方、極ベクトルの中心からの角度を θ とすると、法線ベクトルの分布密度は $\exp(K \cos \theta)$ に比例する。 K の最尤値は次式を満足する。

$$\coth k - \frac{1}{k} = \frac{R}{N} \quad (3.9)$$

N はサンプル数である。(3.9) 式の近似解は、

$$k = \frac{N-1}{N-R} \quad (3.10)$$

k はテクスチャル特徴を示すパラメータであり、1 に近いほど滑らかな表面(層雲など)といえることができる。

Parikh and Ball (1980) はテクスチャル特徴としてロバーツ勾配をもちいた。2 ライン、2 画素の画像データを点 P から切り出したとき、 2×2 の画像データが以下のように得られたとする(点 P の値を p のように示した)。

$$\begin{pmatrix} p & q \\ r & s \end{pmatrix}$$

ロバーツ勾配 G は次式のように定義される。

$$G \equiv \text{Max}(|p-s|, |q-r|) \quad (3.11)$$

ここで、 Max は $|p-s|$ 、 $|q-r|$ のうち大きい方をとるオペレータである。

3.3 パワースペクトラム

Booth (1973 a, b) がもちいた雲特徴パラメータを Table 3.3 に示す。パラメータ番号 1~16 はスペクトラル特徴に属するものである。17~32 はパワースペクトラムに関する情報である。

測定領域の大きさが $N \times N$ (ライン \times 画素) の画像データがあり、点 (I, J) における画像データの値を $f(I, J)$ とする。2次元 fFT (fast Fourier Transform) をもちいて $f(I, J)$ を周波数空間 $F(\mu, \nu)$ に変換すると、

Table 3.3 Visual and infrared cloud parameters.
Quad refers to a 6×6 subarray of the 32×32 observation. (after Booth, 1973b)

Parameter	Statistic
1	Mean
2	Standard deviation
3	Coefficient of variation (CV)
4	Skewness
5	Kurtosis
6-10	Value at 1, 16, 50, 84, and 99% cumulative frequencies
11	Range
12	Mean-median
13	Primary mode/secondary mode
14	Average gradient
15	Maximum quad CV - minimum quad CV
16	Maximum quad Range - Minimum quad Range
17-27	Spectral energy at wavenumbers 1-11
28	Spectral energy at wavenumbers 1+2
29	Spectral energy at wavenumbers 2+3
30	Spectral energy at wavenumbers 3+4+5
31	Spectral energy at wavenumbers 5+6+7
32	Spectral energy at wavenumbers 8+9+10+11

$$F(\mu, \nu) = \sum_{I=0}^{N-1} \sum_{J=0}^{N-1} f(I, J) \exp\{-2\pi i(\mu I + \nu J)/N\} \quad (3.12)$$

$$(-N/2 \leq \mu \leq N/2, -N/2 \leq \nu \leq N/2)$$

$F(\mu, \nu)$ の複素共役を $F^*(\mu, \nu)$ とすると、パワースペクトラム $C(\mu, \nu)$ は、

$$C(\mu, \nu) = F^*(\mu, \nu) F(\mu, \nu) \quad (3.13)$$

4. 雲形判別モデル

以下では雲形判別の事例について、入手できた文献の範囲でその概要を述べる。ただし、GMS (Geostationary Meteorological Satellite) で観測可能な波長域の画像データを使用した雲形判別に限定した。それ以外の例として以下の2例がある。Stowe et al (1978) は Nimbus-G に搭載された THIR (Temperature Humidity Infrared Radiometer) の $11 \mu\text{m}$ 、 $6.7 \mu\text{m}$ 帯を使用して3雲形の雲形判別を試みた。Shenk et al (1976) は、Nimbus-3 の MRIR (Medium Resolution Infrared Radiometer) の4チャンネル ($0.2 \sim 4.0 \mu\text{m}$ 、 $10 \sim 11 \mu\text{m}$ 、 $20 \sim 23 \mu\text{m}$ 、 $6.5 \sim 7.0 \mu\text{m}$) をもちいて、4~7雲形の雲形判別を行なっている。

4.1 Parikh の研究

Parikh は雲形判別の分野で優れた研究成果を出しており、特に、1977年に出した論文は示唆に富む内容なので、以下にその概略を紹介する。目的は雲移動ベクトルの算出に適した追跡雲を自動的に抽出する方法の開発で

ある。

使用した衛星は NOAA-1 (VIS, 0.52~0.72 μm ; 分解能 2n.mi : IR, 10.5~12.5 μm ; 分解能 4n.mi) で、フィルム画像をデジタルに変換したものを画像データとして使用した。測定領域の大きさは 64×64 (ライン, 画素) で、その大きさは衛星直下点で 111×192n.mi² である。対象にした雲形は下層雲 (Low; 積雲, 雄大積雲, 層雲, 層積雲), 混合雲 (Mix; 絹雲と下層雲あるいは中層雲との混在), 絹雲 (Ci), 積乱雲 (Cb) である。3 雲形に分類するときは Mix を含まない。雲形は NESS (National Environmental Satellite Service) の解析者によるものをグランドトゥースとした。雲特徴パラメータについては Table 3.1, 3.2 に示したものを使用している。

雲形判別の際、雲形をどのような順序で判別するかが大切である。判別トリー構造 (Decision Tree Structure) を Fig. 4.1 に示した。トリー-1 は各雲形に一度の判別で分類するものである (Single-Stage Decision Tree)。トリー-2 は、トリー-1 では Mix が Low に判別される恐れがあるので、Low を再び Low それ自身と Mix に判別する。トリー-3 は、他の雲形から Cb のみを判別、Cb を除いた他の雲形から Ci を判別、最後に誤判別となりやすい Low と Mix を判別する (Binary Decision Tree)。

判別関数として以下のものを使用した。なお、確率密度関数は多変量正規分布を仮定している。観測ベクトル \mathbf{x} , 雲形 i , その事前確率 $p(i)$ とする。

1) Maximum Likelihood Classifier

すべての $i \neq j$ について次式を満足するとき、 \mathbf{x} は j と判別する。事前確率はサンプル数に含まれる雲形の頻度から求める。

$$\ln P(\mathbf{x}|j)p(j) > \ln P(\mathbf{x}|i)p(i)$$

群内分散・共分散マトリックスは等しくないとする。

2) Multiclass One-Against-the-Rest Classifier

$$\ln P(\mathbf{x}|j) > \ln P(\mathbf{x}|not\ j)$$

また、すべての $i \neq j$ について

$$\ln P(\mathbf{x}|not\ i) > \ln P(\mathbf{x}|i)$$

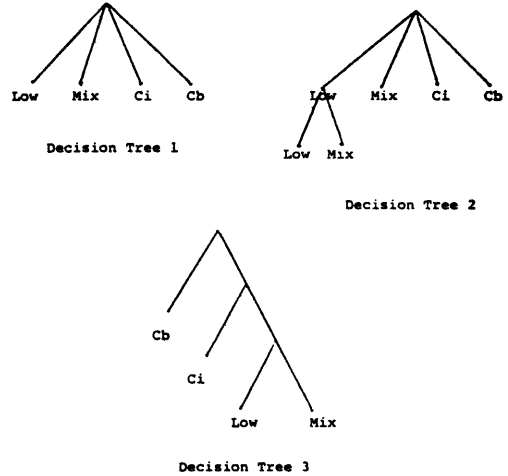
のとき、 \mathbf{x} は j と判別する。

3) Multiclass Voting Classifier


すべての $i \neq j$ について、

$$\ln P(\mathbf{x}|j) > \ln P(\mathbf{x}|i)$$

これを満す不等式の数が最大の雲形に \mathbf{x} を割り当てる。



Decision trees for the four-class problem.



Decision trees for the three-class problem.

Fig. 4.1 Decision trees for the three-class problem and the four-class problem (after Parikh, 1977)

4) Fisher-Two-Class Classifier

二つの雲形 1, 2 間で、次式を満足するとき \mathbf{x} は雲形 1 と判別する。

$$\ln P(\mathbf{x}|1)p(1) > \ln P(\mathbf{x}|2)p(2)$$

事前確率は 1) と同様求め、群内分散・共分散マトリックスは各雲形で等しいとする。

4.1.1 雲特徴パラメータの考察

Low は他の雲形にくらべて高温、IR によるコントラストは小、角二次モーメントは大きいという特徴がある。VIS では Mix と Low, IR では Mix と Ci の判別が困難である。Low と Mix の VIS の輝度範囲や平均値は Ci より大きく、Cb より小さい。Ci および Mix の IR の温度範囲や平均値は Cb より小さい。Ci の輝

度の分布は均質であり、Ci の最低温度は、Cb, Low のそれらとは明らかに異なるので判別できる。Cb は高輝度、低温であり、その表面の凹凸が激しいことはコントラスト、エントロピーなどが他の雲形より大きいことで明らかである。

4.1.2 雲特徴パラメータの選択

テクスチャル特徴を算出するときの ρ は1, 2, 4, 8のうち、1が適している。南北方向のほうが東西方向にくらべてフィッシャーの距離が大きい。この原因は衛星データが東西方向にオーバーラップしていること、対象にした領域の風向が東西方向に卓越していること、などが考えられる。IR によるエントロピーは Low と他の雲形、Mix と Cb を判別するのに有効である。VIS によるエントロピーと角二次モーメントは Ci と Cb, Mix を判別するのに適している。フィッシャーの距離の最大値は、スペクトラル特徴（温度範囲、輝度範囲）にみられた。

4.1.3 最尤法による判別結果

トリー1, 4雲形の場合で、雲特徴パラメータとして最大輝度、輝度範囲、最低温度、温度範囲、IR エントロピー ($\rho=1$, 左上方および右上方)、累積度数10%と90%の温度差の7つをもちいたとき、89%の正当率を得た。

トリー1とトリー2の比較では前者の正当率は89%、後者は91%で大差はなかった。トリー2の前段で使った雲特徴パラメータは温度範囲、輝度範囲、累積度数10%と90%の温度差、輝度差、温度の標準偏差、最低温度、IR エントロピー ($\rho=1$, 左下方向) である。後段で使った雲特徴パラメータは温度の標準偏差、四分領域の温度の標準偏差の最大値、最低温度、四分領域の最低温度間の範囲、四分領域の累積度数10%と90%の温度差の最大値と温度差の範囲である。トリー3とトリー1の比較では両者の間に、ほとんど差がなかった。3雲形によるトリー4と5の比較では両者とも98%の正当率であった。トリー5で第1段の判別で使った雲特徴パラメータは温度の標準偏差、第2段の判別では最大輝度を使用した。

4.1.4 判別関数の比較

同一の雲特徴パラメータ (5個) を使用して、判別関数別の正当率を比較した。4雲形でトリー1による正当率は maximum likelihood で86%, multiclass voting, 82.3%; multiclass one-against-the-rest で28.7%であった。3雲形でトリー4による正当率はそれぞれ98.1%,

98.1%, 94.2%であった。

4.1.5 結論

雲移動ベクトル算出のための自動雲形判別システムでは、雲特徴パラメータは可視、赤外のスペクトラル特徴の組合せ、判別トリー構造は single stage, 判別方法は最尤法が良い。

Parikh (1978) は上記の結果にもとづいて、SMS—1 (VIS, 0.55~0.75 μ m; 分解能 2n. mi. IR, 10.5~12.6 μ m; 分解能 2 \times 4n. mi²) の画像データで雲形判別を試みた。使用した雲特徴パラメータを Table 4.1 に示した。4雲形、トリー1, 最尤法を使用したときの従属データ

Table 4.1 Features used in SMS—1 experiments. (after Parikh, 1978)

FEATURE	FEATURE NUMBER*
Mean	1
Standard Deviation	2
Value at 100% cumulative frequency (brightest visible value or coldest temperature value)	13
Difference between values at 100% and 0% cumulative frequencies	14
Difference between values at 90% and 10% cumulative frequencies	15
Difference between values at 0% and 50% cumulative frequencies	16
Maximum of Quadrant Standard Deviations	24
Entropy (Distance 1, Right Diagonal)	76
Entropy (Distance 1, Left Diagonal)	77

*Feature numbers refer to features described in Section II and Tables 1-2 of Parikh (1977).

に関する正当率を Table 4.2 に示した。この表には使った雲特徴パラメータも示されている。試験番号1~5は NOAA—1 で実施したものと同一であり、SMS—1 では 81.4~88.9%, NOAA—1 で 86.0~88.1%の正当率であった。試験番号6~8では雲特徴パラメータの数を7個としており、NOAA—1 では 87.2~89.7%, SMS—1 では 85.2~88.9%の正当率である。独立データに適用してみた結果を Table 4.3 に示した。Table 4.2 で正当率の良かった試験番号3, 6, 7, 8を独立データに適用した結果では 77.6~81.3%の正当率で、NOAA—1 による正当率は 86.4~89.7%であった。NOAA—1 の結果と SMS—1 による結果とではほとんど差異がないことがわかる。Table 4.2, Table 4.3 からみる限り、誤判別は Low, Ci, Cb が Mix に判別されることが最も大きな原因である。

Parikh and Ball (1980) は GATE (GARP Atlantic Tropical Experiment) の Phase—III の期間中、SMS—1 の画像データから得られる雲形、雲量と観測船の観測結果を比較した (雲量の比較は、以下の説明では

Table 4.2 Maximum likelihood, single-stage classification of SMS—1 design samples.
(after Parikh, 1978)

EXPERIMENT NUMBER	NUMBER OF CLASSES	FEATURE NUMBERS ^a	PERCENTAGE OF SAMPLES CORRECTLY CLASSIFIED				
			LOW	MIX	C _I	C _B	TOTAL
1	4	14V, 2, 13, 14, 15	100.0	86.2	75.0	46.7	82.7
2	4	14V, 13, 14, 15, 24	100.0	82.8	75.0	53.3	82.7
3	4	13V, 14V, 13, 14, 15	96.6	96.6	87.5	60.0	88.9
4	4	14V, 13, 14, 15, 76	100.0	86.2	75.0	40.0	81.4
5	4	13V, 14V, 13, 15, 76	93.1	86.2	87.5	53.3	82.7
6	4	14V, 15V, 2, 13, 14, 15, 76	100.0	86.2	100.0	46.7	85.2
7	4	13V, 14V, 13, 14, 15, 76, 77	100.0	89.7	100.0	60.0	88.9
8	4	14V, 15V, 2, 13, 14, 15, 16	100.0	86.2	100.0	66.7	88.9
9	3	14V, 14	100.0	—	75.0	80.0	90.4
10	3	13V, 2	100.0	—	75.0	93.3	94.2
11	3	14V, 2, 13, 14, 15	100.0	—	75.0	100.0	96.2

^aFeature names corresponding to feature numbers are given in Table 1. The suffix "V" appended to the feature number refers to features calculated from visible data. Feature numbers with no suffix refer to features calculated from infrared data.

Table 4.3 Maximum likelihood, single-stage classification of SMS—1 test samples.
(after Parikh, 1978)

EXPERIMENT NUMBER	CORRESPONDING EXPERIMENT NUMBER IN TABLE 2	PERCENTAGE OF SAMPLES CORRECTLY CLASSIFIED				
		LOW	MIX	C _I	C _B	TOTAL
1	3	90.9	80.8	100.0	50.0	79.4
2	6	87.3	92.3	100.0	54.2	81.3
3	7	87.3	80.8	100.0	50.0	77.6
4	8	85.5	96.2	100.0	37.5	77.6
5	11	96.4	—	100.0	95.8	96.3

省略する)。雲形は1：下層雲のみ，2：上層雲があまり卓越しない中層雲，3：下層雲があまり卓越しない上層雲，4：下層雲が卓越した上層雲，5：積乱雲，とした。観測船の位置から5×5 (4n. mi.²) の画像データを切り出し，雲特徴パラメータを算出している。テクスチャル特徴としてロバーツの勾配，スペクトラル特徴としてIRレベルの平均値を採用した。判別方法として最尤法をもちい，確率密度関数は多変量正規分布とした。事前確率は各雲形で等しいと仮定している。群内分散・共分散マトリックスΣは次式のように定義している。

$$\Sigma = \frac{\sum_{i=1}^5 (N_i - 1) \Sigma_i}{\sum_{i=1}^5 N_i - 5} \quad (3.1)$$

ここで， N_i は雲形*i*のサンプル数， Σ_i は雲形*i*の共分散マトリックスである。平均観測ベクトル M_i とロバーツの距離，IRレベルの平均値から得られる等価黒体温度の関係を Fig. 4.2 に示した。ロバーツの距離で M_1, M_2, M_3 の判別が容易であることがわかる。観測船による雲形の観測規準は全雲量，上，中，下層雲量を加味して雲形を決定するもので，Table 4.4, Table 4.5 のように定められている。Table 4.4 は衛星による雲形に対応するものであるが，観測船による雲形は Table 4.4 の内容に加えて Table 4.5 のように新たに4雲形が追加されている（この表中にある Table 1 とは本文の Table 4.4 を示している）。比較結果を Table 4.6 に表した。例えば，観測船による雲形1（下層雲のみ，Table 3.4 の定義によれば全雲量，下層雲量が50%以




Fig. 4.2 Mean vector for training sets of five cloud-type classes.
(after Parikh and Ball, 1980)

下で、積乱雲がない) は、衛星による雲形1に47%、雲形2に27%、雲形3に12%、のように出現している。事例解析としてもう1例を追加しているが、結論として、下層雲のみと、下層雲をともなう中層雲あるいは中層雲のみの判別、および下層雲をともなう上層雲と積乱雲の判別は困難であること、下層雲が卓越していない上層雲は下層雲に誤判別されやすいとしている。

4.2 その他の研究

Booth (1973 a, b) は ITOS (Improved TIROS Operational Satellite) に搭載された SR (Scanning Radiometer; VIS, 0.5~0.7 μm; IR, 10.5~12.5 μm: 分解能, 6n. mi) の画像データを使用して雲形判別を行なった。測定領域の大きさは 32×32 (画素, ライン: 54×96n. mi²) である。判別する雲形は、雲形1: 雲なし, 雲形2: 積雲と雄大雲雲, 雲形3: 層積雲と層雲, 雲形4: 積乱雲, 雲形5: 絹雲, 雲形6: 下層雲をともなう絹雲, 雲形7: 中層雲をともなう絹雲, 雲形8: 下層,

中層雲をともなう絹雲, の8雲形とした。雲特徴パラメータは Table 3.3 に示したものでスペクトル特徴とテクスチャル特徴を併用している。後者にはいろいろな波数におけるパワースペクトラルを使用しているのが注目される。Table 4.7 は従属データ, 独立データの各雲形における度数と事前確率を示した。確率密度関数は多変量正規分布を仮定しており, 判別方法は最尤法をもちいた。8雲形としたが実際には雲形7, 8の出現頻度が小さく, 解析者も判別困難であったので, これらを雲形6として一つにまとめた。このようにして得られた6雲形と雲形2, 3を一緒にした5雲形とで実施している。実際に使用した雲特徴パラメータはステップワイズ法 (Stepwise Method) による重回帰分析の t 検定値 (5% で50個, スペクトラル特徴パラメータ28個, テクスチャル特徴パラメータ22個: 1% で32個, スペクトラル特徴パラメータ18個, テクスチャル特徴パラメータ14個) で示されているので, 不明である。判別結果を Table 4.8, 4.9 に示した。正当率 (表では HITS と示さ

Table 4.4 Criteria for training set selection and average cloud coverage for ship observations in each class. (after Parikh, 1978)

CLOUD TYPE CLASS		MINIMUM SELECTION CRITERIA	NUMBER OF SHIP OBSERVATIONS ^a	AVERAGE CLOUD COVERAGE FROM SHIP OBSERVATION (%)			
NUMBER	NAME			NT	NL	NM	NH
1	Low Clouds Only	NT & NL > 50% NM & NH < 25% No Cumulonimbus (Cb)	6	67.5	56.7	13.3	5.0
2	Middle Clouds With No Significant High Clouds	NT & NM > 50% NH < 25% No Cb	22	85.7	15.9	69.1	12.1
3	High Clouds With No Significant Lower Clouds	NT & NH > 50% NL & NM < 50% No Cb	9	92.8	25.0	14.9	78.9
4	High Clouds With Significant Lower Clouds	NT & NH > 50% NL & /or NM > 50% No Cb	14	98.5	38.9	46.0	79.1
5	Cb	NT > 95% NL > 75% Cb Not first hour reporting Cb.	28	98.5	87.7	94.8 ^b	92.1 ^b

^aTotal ship observations = 79.

^bIt is assumed that cloud amounts associated with Cb occupy middle and high cloud layers as well as the low cloud layer.

Table 4.5 Cloud-type classification criteria for ship observations (after Parikh, 1978)

SHIP OBSERVATION CLOUD TYPE CLASS		
NUMBER	NAME	SELECTION CRITERIA
0	No significant clouds	NT < 40% No Cumulonimbus
1-5	Same as Table 1	Same as Table 1
6	Some cumulonimbus	Cumulonimbus reported, but criteria of Class 5 are not satisfied.
7	Scattered clouds at more than one level	NT > 50% NL < 40% NM < 40% NH < 40% No Cumulonimbus
8	High and/or middle clouds unknown	NM and/or NH are uncertain. No cumulonimbus

Table 4.6 Comparison of satellite cloud-type classification with ship observation on 4 September. (after Parikh, 1978)

SHIP CLOUD-TYPE CLASS	FREQUENCY OF SATELLITE CLOUD-TYPE CLASS					NUMBER OF CASES
	1	2	3	4	5	
0	0.542	0.231	0.200	0.027	0.000	9
1	0.467	0.273	0.117	0.090	0.053	12
2	0.469	0.400	0.080	0.051	0.000	7
3	0.310	0.164	0.328	0.125	0.073	22
4	0.076	0.222	0.138	0.269	0.295	20
5	0.069	0.090	0.045	0.185	0.611	35
6	0.138	0.194	0.136	0.125	0.407	51
7	0.460	0.146	0.182	0.123	0.069	14
8	0.015	0.034	0.056	0.099	0.797	35
All Classes	0.186	0.158	0.130	0.136	0.390	205

Table 4.7 Group frequencies and estimated a priori probabilities. (after Booth, 1973b)

Group	Dependent Data	Independent Data	Total	Estimated Probability
1	113	126	239	.11
2	258	245	503	.24
3	155	50	205	.10
4	117	120	237	.11
5	174	236	410	.20
6	182	273	455	.22
7	38	0	38	.02
8	13	0	13	.00
Total	1050	1050	2100	1.00

Table 4.8 Classification matrix for 6-group dependent and independent data. Cloud type groups are: 1-clear, 2-Cu, 3-Sc, 4-Cb, 5-Ci, and 6-Ci with lower clouds. (after Booth, 1973b)

CLASSIFICATION GROUP							
Dependent Data							
Group	1	2	3	4	5	6	% HITS
O	1	87	14	1	0	6	77
B	2	11	214	8	0	1	83
S	3	8	44	98	0	0	63
F	4	0	0	0	93	1	79
R	5	9	2	1	9	136	78
V	6	1	16	2	10	31	74
E	Overall						76
Independent Data							
G	1	111	6	0	0	5	88
R	2	59	130	16	0	3	53
O	3	0	41	4	0	1	8
U	4	0	0	0	91	8	76
P	5	6	2	0	67	139	59
	6	3	17	1	20	49	67
	Overall						63

Table 4.9 Classification matrix for 5-group dependent and independent data. Cloud type groups are: 1-clear, 2-Cu/Sc, 4-Ci and 5-Ci with lower clouds. (after Booth, 1973b)

CLASSIFICATION GROUP						
Dependent Data						
Group	1	2	3	4	5	% HITS
O	1	88	15	0	6	78
B	2	20	365	0	1	88
S	3	0	0	92	1	79
F	4	9	3	9	134	77
R	5	1	19	11	31	73
V	Overall					81
Independent Data						
E	1	109	8	0	5	87
D	2	54	199	0	4	67
G	3	0	0	92	8	77
R	4	6	1	68	138	58
O	5	3	14	21	49	68
U	Overall					69

れている)は6雲形より雲形のほうが良い。これは判別の困難な積雲と層雲を同一の雲形に判別したことによる。全体的には積乱雲、絹雲と下層雲をとまなう絹雲、積乱雲と下層雲をとまなう絹雲の判別が困難である。特に、独立データでは絹雲と積乱雲あるいは下層雲をとまなう絹雲との判別が困難であった。これらの結果はVISとIRの両方の雲特徴パラメータを使用した場合であるが、一方のみを使用して判別した結果との比較をFig. 4.3, Fig. 4.4に示した。従属データではIRをもちいたとき、6雲形、5雲形の全雲形に対する正当率はそれぞれ57, 63%であるが、VISのそれは43, 44%であり、IRのほうが良い。雲がない領域の判別はVISのほうが良い。独立データでは絹雲の判別を除けば、VISとIR

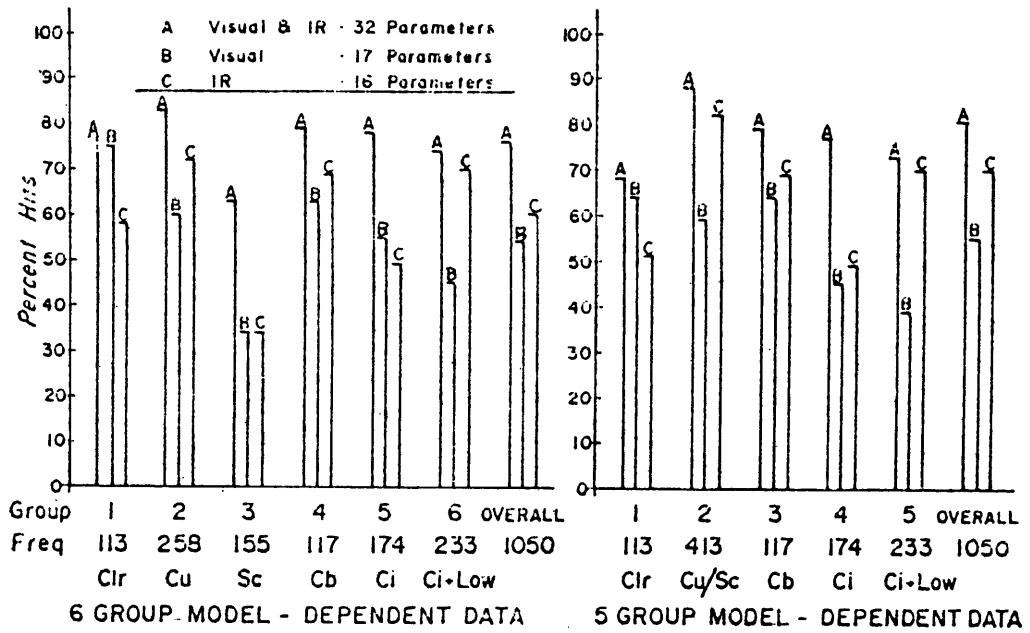


Fig. 4.3 A comparison between dependent dual- and single-channel classification. (after Booth, 1973b)




Fig. 4.4 A comparison between independent dual- and single-channel classification. (after Booth, 1973b)




Fig. 4.5 A linear discriminant analysis defines boundary between (1) the stratiform cloud type samples and the mixed cloud type samples, (2) the cumuliform cloud type samples and the mixed cloud type samples.

In (1) $0.7578 - 0.0167V + 0.0057S = 0$,

In (2) $0.3451 - 0.0177V + 0.0069S = 0$,

where V is the vector dispersion and S the standard deviation. (after Harris and Barret, 1978)




Fig. 4.6 Defence Meteorological Satellite Program (DMPS) high-resolution (0.61 km) visible (0.4-1.1 μm) image of a part of western Europe and the North Atlantic, 0804 GMT 30 April 1975. The area measures approximately 4000 \times 2800 km (Courtesy, SSEC, Madison, WI.). (after Harris and Barret, 1978)

を併用したときの正当率と IR のみ使用したときの正当率はほとんど同じである。全雲形に対する正当率は、6雲形、5雲形の両方について VIS と IR を併用したときのほうが IR のみよりも5%良い。これは絹雲の判別には VIS と IR の併用が良いことを示している。

Harris and Barret (1978) は雲解析の自動化を目的として、雲量の算出および雲形判別を行なった。使用した衛星は DMPS (Defense Meteorological Satellite, VIS, 0.4~1.1 μm; 分解能 0.61 km; IR, 8~13 μm; 分解能 0.61 km) である。フィルム画像をデジタル化 (分解能は 1.6 km に低下) して、5×5 (ライン, 画素) の測定領域とした。

雲特徴パラメータはフィルム濃度値から求めた標準偏差, ベクトル分散の二つを使用した。雲形は3雲形で、層雲形, 積雲形, 層積雲形/混合雲形である。判別方法については詳細な記述がないので不明であるが, 判別式は一次式である。Fig. 4.5 に雲特徴パラメータと各雲形の関係, および判別式を示した。この結果では積雲形と層雲形の判別は標準偏差が大きく寄与していることがわかる。この判別式をもちいて Fig. 4.6 の雲パターンを




Fig. 4.7 The objective nephanalysis computed from the image shown in Fig. 4.6. The spatial resolution of this map is ~40 km (after Harris and Barret, 1978)

Table 4.10 A contingency table for the manual/automatic classifications of the DMSP visible image shown Fig. 4.6 (after Harris and Barret, 1978).

Automatic classification	Manual classification				Total
	Stratiform	Cumuliform	Stratocumuliform	Clear	
Stratiform	177	1	61	5	244
Cumuliform	12	323	20	9	364
Stratocumuliform	35	25	325	8	393
Clear	12	157*	88	315	572
					1573

Overall accuracy, 72.5%.

* Accuracy with this value omitted was 80.5%.

解析した結果を Fig. 4.7 に示した。東側にある前線にともなう層雲形と, その北, 西側にある積雲とがよく判別されている。解析者による雲形とこの方法による判別結果を Table 4.10 に示した。全雲形に対する正当率は72%である。誤判別は積雲形と雲なし領域の間で大きく, これはデジタル化するときの濃度計のスポットサイズが大きいためとみられる。

おわりに

計算機による雲形判別は気象衛星の画像データ処理という意味では新しい分野である。熟練した解析者による雲形判別と同等な結果を得るのは不可能としても, それに近づけようとする努力が続けられている。雲形判別の精度を向上させるためには, 画像前処理 (キャリブレーション, 位置合せ, など) を別にすれば, 雲特徴パラメータの適正な選択と観測波長帯を多くすることが必要であろう。

References

- Booth, A. L. (1973a): Cloud Type Pattern Recognition Using Environmental Satellite Data. Proceedings of the 1st International Joint Conference on Pattern Recognition, IEEE Inc., 526-533, 1978.
- Booth, A. L. (1973b): Objective Cloud Type Classification Using Visual and Infrared Satellite Data. The 3rd Conference on Probability and Statistics in Atmospheric Science. Boulder, Colorado, published by American Meteorological Society, 163-170, 1978.
- Harris, R., E. C. Barret (1978): Toward an Objective Nephanalysis. J. App. Meteor., 17, 1258-

- 1266, 1978.
- 4 Koffler, R., A. G. DeCotis and P. Krishna Rao (1973) : A Procedure for Estimating Cloud Amount and Height from Satellite Infrared Radiation Data. *Mon. Wea. Rev.*, **101**, 240-243, 1973.
 - 5 Parikh, J. (1977) : A Comparative Study of Cloud Classification Techniques. *Remote Sensing of Environment*, **6**, 67-81, 1977.
 - 6 Parikh, J. (1978) : Cloud Classification from Visible and Infrared SMS-1 Data. *Remote Sensing of Environment*, **7**, 85-92, 1978.
 - 7 Parikh, J. and J. T. Ball (1980) : Analysis of Cloud Type and Cloud Amount During GATE from SMS Infrared Data. *Remote Sensing of Environment*, **9**, 225-245, 1980.
 - 8 Shenk, W. E., R. J. Holub and R. A. Neff (1976) : A Multispectral Cloud Type Identification Method Developed for Tropical Ocean Area with Nimbus-3 MRIR Measurements. *Mon. Wea. Rev.*, **104**, 284-291, 1976.
 - 9 Stowe, L. L., M. Chen, H. Jacobowitz and I. Ruff (1978) : Third Conference on Atmospheric Radiation of the American Meteorological Society, June 28-30, California, 103-106, 1978.
 - 10 奥野忠一, 久米 均, 芳賀敏郎, 吉沢 正 (1974) : 多変量解析法, 日科技連出版社, pp. 430.
 - 11 柳井晴夫, 高根芳雄 (1977) : 現代人の統計2, 多変量解析法, 朝倉書店, pp. 210.
 - 12 気象衛星センター : VISSR 画像データの位置対応の精度向上に関する調査報告(1), 昭和54年3月。