マルチスペクトル画像を用いた自動識別手法の比較†

藤 村 貞 夫* ・ 豊 田 弘 道**
愛 甲 敬*** ・ 鈴 木 康 志****

Comparison of Automatic Classification Methods for Multispectral Images

Sadao FUJIMURA*, Hiromichi TOYOTA**, Takashi AIKOH***
and Yasushi SUZUKI****

The use of remotely sensed multispectral data to construct a land use map was studied. The results of automatic supervised classification by the most likelihood ratio (MLH), the linear discriminant function (LDF), the minimum Euclidean distance (MED) and by the correlation coefficient methods (CCM and NCM) were compared. The data were obtained by an airborne multispectral scanner JSCAN-AT-12 M. For the comparison four channel data (blue, green, red, and near IR) were used. The training fields were selected for eight categories (pond, forest, field, marsh, bare soil, road, railway and concrete). If the distribution of the data were Gaussian, the correct classification rate (CCR) decreases as we change the methods of classification from one to another in the above mentioned order. This was the case for the training field data, but not so for those of the test fields. This means that an essential problem in practice is the generality of the training field data. The skewness and kurtosis calculated from the data of each channel for the training area show that the distribution are not Gaussian. This, however, does not have a serious effect on the classification in this case.

For the test data the best result (about 80% CCR) was obtained by MED, and the worst (about 60%) by MLH. In MLH, if the data had small variances slight differences were exaggerated because the data lacked generality. On the other hand, if the data had large variances, the differences between categories were likely underestimated.

1. ま え が き

リモートセンシングで得られるマルチスペクトル画像を環境評価や資源探査など種々の問題に適用する場合、自動識別は最も基本的な手法の一つに挙げることができる。

ここでは、航空機搭載のマルチスペクトルスキャナ(MSS)で得られたマルチスペクトル画像の自動識別における問題点について考察する。

ところで、自動識別には教師つき識別と教師なし識別とがあるが、ここでは、広域的环境計測への応用の第1段階としての土地利用図作成に5種類の教師つき自動識別法を適用してそれらの比較を行うとともに、自動識別における問題点を明らかにする。

従来も教師つき自動識別の手法は最尤法をはじめとして種々考案され利用されており^{1),2)}、それらの間の比較も行われている^{3)~6)}。これらの手法のうち最もよく用いられるのが最尤法であり⁷⁾、最も高い識別率を示すという報告もあれば^{3),4)}、そうでない結論の報告もある^{5),6)}。実際に航空機搭載のMSSによるデータに最尤法による識別を適用してみると、よい結果が得られるとは限らないことがわかる。

しかし、従来の比較の方法は必ずしも系統的でなく、結果の意味づけも明確でないため、実際に適用して最尤法がよい結果を与えない場合に、その原因を考察するのには向いていない。

† 第2回リモートセンシングシンポジウムで発表(昭 51-11)

電子通信学会画像工学研究会で発表(昭 52-5)

* 電気通信大学 調布市調布ヶ丘 1-5-1

** 東京大学工学部 東京都文京区本郷 7-3-1

*** 日本造船振興財団 東京都港区琴平町 35

**** 富士通ファコム(株) 東京都世田谷区奥沢 8-3-2

* University of Electro-Communication, Chofu, Tokyo

** Faculty of Engineering, University of Tokyo, Bunkyo-ku, Tokyo

*** JAFSA, Minato-ku, Tokyo

**** Fujitsu FACOM Co., Setagaya-ku, Tokyo

(Received August 10, 1977)

Table 1 Spectral bands of JSCAN-AT-12M

Ch No.	wave length (μm)
0	.25— .35
1	.35— .40
2	.40— .45
3	.45— .50
4	.50— .55
5	.55— .60
6	.60— .65
7	.65— .70
8	.70— .80
9	.80— .90
10	.90— 1.10
11	8 — 14

Fig. 1 Pictorial printout of ch. 11 data
Example of training (A) and test fields (B)

ここでは、最尤法がよくない結果を与える原因として考えられるデータの統計的性質（非正規性）とトレーニング用データの代表性の欠如とを分離して考察できる、一連の相互に関連の明らかな識別手法を適用する。このことにより個々の識別手法の特徴が明らかになると同時に、用いるデータの統計的性質についても知ることができ、自動識別の適用に当っての指針を得ることができる。

以下、識別法と結果について述べ、その後、得られた結果に対して検討を加える。

2. 使用データ

本研究で使用したデータは、広島県福山地区において、1976年3月11日、午前11時59分から12時02分にかけての観測で得られたマルチスペクトル画像である。観測に用いたMSSはJ-SCAN-AT-12Mで、観測波長域とチャンネル番号との対応はTable 1に示すとおりである。以下のデジタル解析のために作成したCCT (Computer Compatible Tape) には、このうちのチャンネル番号1 (近紫外)、3 (青)、5 (緑)、7 (赤)、9 (近赤外)、11 (熱赤外) の合計6チャンネル分のデータのみが記録されている。

観測時の航空機の高度は約920m、したがって、以下の画像の1画素の大きさは地上で直径約2.3mに対応している。

CCTからのデータに基づいて作成したチャンネル11の濃淡マップをFig. 1に示す。これは観測された放射の強いところほど白くなるように出力したものである。

3. 識別と手法

識別の手法としては5種類の教師つき識別法と教師なし識別法を採用した。

教師つき識別に当っては、Fig. 1で既知のカテゴリに属する対象物（池、森、畑、裸地など）の存在する場所を見出し、トレーニング用サンプルとしてコンピュータにカテゴリと場所（トレーニングフィールド）を教える。実際に指定したのは9ヵ所、8カテゴリで、これらについての平均スペクトル特性をFig. 2に示す。これは上述の各場所についてチャンネルごとに観測値の平均値を求めてプロットしたもので、これから各場所に存在する対象物のおおよそのスペクトル特性を知ることができる。なお、使用したデータは、ゲイン・オフセットの補正がされておらず、Fig. 2は厳密な意味でのスペクトル特性ではない。つまり、一つのチャンネル内では相対的大小関係が保たれているもの

の、チャンネル相互間ではそれが保たれているとは限らないのである。ただし、ここでの識別ではそのようなデータの一部分をトレーニング用に選んであり、このことが本質の問題とはならない。

Fig. 2 の特性を求めるのに用いたトレーニングサンプルの数と、チャンネル 3, 5, 7, 9 のデータについて求めたおのおのに対する標準偏差の最小、最大値を Table 2 に示す。

データの自動識別は、上のようにして与えたトレーニングデータを各カテゴリーを代表する標準データとし、識別したいデータをデータ間の類似度を表す尺度を用いて最も類似している標準データの属するカテゴリーに分類することで実現する。具体的には、未知のデータを変数とする判別関数を最大あるいは最小にするカテゴリーに未知データを属させるという手順をとる。

使用した識別法は、最尤法 (MLH と略記)、線形判

Fig. 2 Mean spectral characteristics

Table 2 Sample points and standard deviation for training field data

	No. of sample Stand. dev.		
	points	min	max
Bare soil	128	8.1	10.6
Concrete	60	9.2	14.5
Field	135	5.4	7.9
Forest-1	92	2.2	6.6
Forest-2	49	3.7	6.1
Marsh	110	1.6	2.2
Pond	143	0.9	2.1
Railway	48	4.1	6.3
Road	36	4.0	12.1

$$\text{MLH} \xrightarrow{\Sigma_i = \Sigma} \text{LDF} \xrightarrow{\Sigma = I} \text{MED} \xrightarrow{M^T M = 1} \text{CCM} \xrightarrow{e^T M = 0} \text{NCM}$$

Fig. 3 Classification algorithms

別関数法 (LDF)、最短距離法 (MED)、相関法 (平均値を 0 に正規化しない場合 CCM, する場合 NCM) である。これらは、データの分布が正規分布に従う (条件 A) とすると、Fig. 3 で左から右の順にデータに対する前提条件が厳しくなる (図で矢印の上に記したものが前提条件に順次付加される条件である。記号の意味は 4 を参照)。換言すれば、条件 A のもとでは、次第に実際の性質とは異なる条件を付加してその分判別の手間を省くように配列してあるわけである。したがって、条件 A が成立していれば、識別結果はこの順に悪くなっていくことが予想されるのである。

一方、教師なし識別では、データの統計的性質のみを使用し、特性の類似したデータをまとめることによって識別を実行するが、類似度の尺度としてはユークリッド距離を用い (注 1)、識別結果がある基準を満たすまで繰返し識別を行った。上述のデータに適用した際には得られるクラスタの数を 14 と指定した。

4. 教師つき識別の結果

ここでは、5 種類の自動識別法による識別の結果を Fig. 2 に示した順に列挙する。識別率を求めるための対象は、トレーニングフィールドとして指定した場所以外で地上の状況が既知の場所 (テストフィールド) を濃淡マップ上から選択して用いた。

以下、各方法で用いた判別関数を表現するため、マルチスペクトル画像データを、使用するチャンネルの数を n として n 次元ベクトル

$$X = [x_1, x_2, \dots, x_n]^T$$

として表す。ここで、 x_i は使用チャンネル中 i 番目のチャンネルでの測定値を、 T は転置を意味し、 $n \leq 6$ である。

なお、以下では、チャンネル番号 3, 5, 7, 9 合計 4 チャンネル ($n=4$) 分のデータを用いて得た結果について比較を行う。

i) 最尤法

この方法は、判別関数

$$g_i(X) = -\frac{1}{2}(X - M_i)^T \Sigma_i^{-1}(X - M_i) - \frac{1}{2} \ln |\Sigma_i| \quad (1) \text{ (注 2)}$$

(注 1) 距離は類似度の逆で、分離度の尺度ともいうべきであろうが、記述の煩雑さを避けるため、ここでは、誤解のおそれはないものとしてこのような表現をとる。

Fig. 4 Aerophotograph for the classified area shown in Figs. 5 and 6

Fig. 5 Supervised classification result by MLH

を最大にするカテゴリ- i に、つまり、 X がカテゴリ- i に属する確率が最大となる i に分類する方法である。ここで、 M_i はカテゴリ- i の平均ベクトル、 Σ_i はカテゴリ- i の共分散行列を表す。

判別関数(1)に基づいて上述のデータの一部(Fig. 4)を分類した結果を Fig. 5

(注2) 厳密にはカテゴリ- i の事前出現確率を含んだ式となるが、ここではそれらが i によらず一定として省略してある。これは他の手法の判別関数にも同様に加えられるべきもので、これによる影響は今の場合本質的でないことが結果的にも確かめられるのでそうしてある。

Table 3 Correct classification rate (%) for test field data

(samples)	MLH	LDF	MED	CCM	NCM
Bare soil (752)	77.4	98.9	98.9	98.4	99.1
X: Concrete (312)	83.0	0.0	11.9	5.1	0.0
I: Field (657)	76.9	50.5	77.5	51.3	17.5
J.C: Forest (798)	54.6	85.7	86.7	71.8	88.2
/: Marsh (480)	94.0	100.0	100.0	100.0	96.0
=: Pond (758)	0.0	89.6	91.2	89.4	100.0
-: Railway (312)	83.7	99.4	99.4	63.5	66.0
Y: Road (342)	46.5	38.9	30.4	23.1	20.8
Av. CCR	60.1	76.2	80.9	70.3	69.4

に示す。各記号は Fig. 2 のそれぞれに対応させてある。

得られた結果からテストフィールドに対して識別率を求めると、各カテゴリ-に関する識別率は Table 3 に示すようになり、平均で 60.1% の識別率を示した。対象物の中で最も識別率の悪いのは池で、トレーニングフィールド以外ではほとんど正しく識別されていない。その他、繁った森が畑に分類されるなど、データの分散の小さいものが分散の大きいものへ誤って分類される傾向のあることがわかった。

なお、使用するチャンネルの数を2(チャンネル7, 9使用)、あるいは、6として行った識別でも結果に著しい差は見られなかった。

ii) 線形判別関数法

判別関数

$$g_i(X) = M_i^T \Sigma^{-1} M_i - 2X^T \Sigma^{-1} M_i \quad (2)$$

を最小にするカテゴリ- i に X を属させるものである。(2)式は(1)式で $\Sigma_i = \Sigma$ 、つまりカテゴリ-によって共分散行列が異なるという条件を付加して導かれ、線形の判別関数となるため i) に比して処理時間が大幅に短縮されるという利点がある。

共分散行列 Σ はトレーニングフィールド全体をカテゴリ-を問わずに一つに集めて算出する。こうして求めた共分散行列(対称)は

$$\Sigma = 10^2 \cdot \begin{pmatrix} 0.433 & & & \\ 0.284 & 0.282 & & \\ 0.379 & 0.315 & 0.519 & \\ 0.277 & 0.211 & 0.340 & 0.412 \end{pmatrix} \quad (3)$$

である。

得られた結果についての識別率は平均 76.2% で (Table 2), i) よりはるかに高い識別率を示すことがわかる。この改善は、上のようにしてカテゴリ-による分散の違いがなされたことによるものと考えられる。

iii) 最短距離法

n 次元空間における未知データと標準データとの間のユークリッド距離から定まる判別関数

$$g_i(\mathbf{X}) = \mathbf{M}_i^T \mathbf{M}_i - 2\mathbf{X}^T \mathbf{M}_i \quad (4)$$

を最小とするカテゴリー i に $\mathbf{X}$ を属させるもので、ここでは標準データとしては平均ベクトルしか使用しておらず、データの分散、共分散はまったく考慮していない。つまり、(2)式で $\Sigma = \mathbf{I}$ (単位行列) としたものが(4)式である。ただし、実際のデータについての Σ は(3)式から見られるように $\mathbf{I}$ とはまったく異なっている。この手法による識別結果の一部を Fig. 6 に示す。このときの識別率は平均 80.9% (Table 2) である。

得られた結果は地上での実態をよく表現したのとなっている。道路やコンクリートについては MLH とは逆に、湿地や池のように分散の小さいものへ誤識別される傾向がある。また、日陰の部分は池や線路などに分類されており、反射エネルギーが小さくなることによる影響が見られる (相関法参照)。

使用するチャンネルの数に関しては、この場合全般的には六つが最もよい結果を与えるが、一部では四つを用いたほうがよい結果を示す。このようなことは走査線の端に近いところで起きており、その原因としては、短い波長域のデータにはヘイズ (haze) などによる雑音成分が加わりやすく (ch. 1 のデータは全般に分散が大きい)、特に周辺部でその影響が大きいことが挙げられる。さらに一般的には、熱赤外域のデータには対象の性質以外の要因が入り込む可能性があり、また、チャンネル数が増すほど各チャンネルのデータ間のレジストレーションが悪くなつて識別に悪影響を及ぼすことが考えられるが、上述の結果からも知られるように、今の場合にはこれら一般的要因が主たるものではない。

iv) 相関法

これは、Fig. 2 に示したスペクトル特性曲線を正規化しておき、個々のデータのもつスペクトル特性ととの相関の大きさに基

Fig. 7 Mean spectral characteristics with only variance normalized

づいて分類を行うもので、判別関数

$$g_i(\mathbf{X}) = \mathbf{X}^T \mathbf{M}_i' \quad (5)$$

を最大にするカテゴリー i に $\mathbf{X}$ を属させるものである。ここで、 $\mathbf{M}_i'$ は正規化された標準平均ベクトルで、

$$\mathbf{M}_i'^T \mathbf{M}_i' = 1 \quad (6)$$

を満たしている。(4)、(5)式から知られるように、これは MED の特別な場合に相当している。

(a) 正規化 I ($\mathbf{M}_i' = \mathbf{M}_i / |\mathbf{M}_i|$) (7))

Fig. 2 の平均スペクトル特性を、(7)式に従って正規化すると、Fig. 7 に示すものとなる。これに基づき(5)式を用いて識別を行う。識別結果は全般的に LDF のそれに類似しており、日陰の部分が他の場合より正しく識別されているのが特色である。

(b) 正規化 II ($e^T \mathbf{M}_i' = 0$) (8) ただし、

$$\mathbf{e} = [1, \dots, 1]^T \text{ で } \mathbf{M}_i'^T \mathbf{M}_i' = 1)$$

これはスペクトル特性曲線の形にのみ注目し、直流分を無視する考えに基づくものであって、日陰の部分についても、対象物は本来のスペクトル特性を示しながら平均エネルギーのみが低くなっているのであれば、この尺度により正しい識別結果の得られることが期待されるわけである。

(8)式に従って正規化した平均スペクトル特性を Fig. 8 に示す。これを用いて得た結果では、他の場合にはほとんど識別されていなかった池が正しく識別されるなどの利点はあるものの、全体的に識別率は低く、日陰の部分が池と誤識別されることが多くなっていたり、森や林と畑との区別がつかなくなるなどの問題が生じている。

前者は、日陰の対象物のスペクトル特性が、平均値が小さくなって平行移動した形となるというモデルでは十分でないことを示しているし、後者は、一つには、ここでの正規化では、スペクトル特性が平坦なも

Fig. 6 Supervised classification result by MED

Fig. 8 Mean spectral characteristics with both mean and variance normalized

のほど個々のスペクトル特性の平均からのずれが拡大されることになって不利になるため（事実，Fig. 2 の平均スペクトル特性のなめらかなものは識別率が低い），もう一つには，対象に関するスペクトル情報はその形だけでなく直流分にも含まれているためと考えられる。

5. 考 察

5.1 教師なし識別

観測データのスペクトル情報のみに基づき，対象領域のデータを 14 クラスに分類^(注 3)して得られたクラスタの平均スペクトル特性を Fig. 9 に示す。これらはユークリッド距離を類似度の尺度として分類されているが，なおクラス間で類似のものが含まれており，分離度として Swain-Fu 距離⁷⁾を用いればさらにまとめることができる。

上記 14 クラスのうち相互間の Swain-Fu 距離が 0.7 以下のもののみの関係を Fig. 10 に示す。これに基づいてクラスタをまとめると，記号でいって，I と =，T と B，F と G，/ と C と Z をそれぞれ一つのクラスとみなしてよいことがわかる。

これらの平均スペクトル特性を Fig. 2 のそれと比較すると，裸地が一，森が R，湿地が＊，池が W，畑が B，線路が Q にほぼ対応することがわかり，しかもこれらについては MED による教師つき識別の識別率も高いことがわかる。

このことはこれらのデータの統計的性質そのものが分離しやすいものであることを意味しており，その他については対象物と統計的性質が必ずしも対応づけられないことを意味しているといえる。この原因として

(注 3) LARSYS を用いて実行した。クラスタを表す記号は Fig. 9 のものを用いる。

Fig. 9 Mean spectral characteristics of clusters

Fig. 10 Separability (Swain-Fu distance) of clusters

は，トレーニングフィールドや画素自身の中に複数の物質が含まれていることが考えられる。

5.2 正規性と代表性

3 で述べたように，データの分布の正規性(条件 A) が成り立つとすれば，Fig. 3 の左に書かれた手法ほど識別率が高くなければならない。しかし，4 で示した結果 (Table 2) はこのことと矛盾している。この原因には (i) 条件 A が成立しないこと，(ii) 代表性 (条件 B) が成立しないこと，つまり，トレーニングフィールドのデータの統計的性質が同じ対象物に対するデータの統計的性質を代表していないことが考えられ

Table 4 Skewness and kurtosis for training field data

Object Channel no.	Pond		Forest	
	skew.	kurt.	skew.	kurt.
1.	-0.29	2.66	-0.23	2.34
3	-0.49*	1.87*	1.70*	8.11*
5	0.09	3.51	-0.53	2.64
7	-0.04	2.43°	-0.72°	2.69
9	0.09	2.82	0.29	3.54
11	-0.35°	3.14	-0.24	1.98°

Table 5 Correct classification rate (CCR) for training field data

Method	CCR (%)
MLH	98.5
LDF	94.0
MED	92.6
CCM	89.8
NCM	78.5

る。なお、多次元分布が正規分布であれば周辺分布も正規分布となる（逆は成立しない）ことから、トレーニングフィールドの各チャンネルのデータに対してひずみ (skewness) と尖度 (kurtosis) を求め、それらが1次元正規分布に従うか否かを調べた。

代表的データについての結果を **Table 4** に示した。データが正規分布に従うとすれば、ひずみは0、尖度は3なる値をとるが、Table 4(注4)から知られるようにこのデータは正規分布に従っておらず、したがって多次元分布も正規分布ではないことがわかる。

同様に他のトレーニング用データについても調べたがいずれも厳密な意味では正規分布に従っていないことがわかった。

そこで、この条件が成立しないことによる識別への影響を見るために、条件Bのほうは満たされているものとみなせるトレーニングフィールドのデータを各手法を用いて識別した。結果の識別率を **Table 5** に示す。

Table 4 の手法による識別率の順序は、データが正規分布に従う場合に予想される順序とちょうど一致しており、このことは、データの正規性が厳密には成立していなくても、Table 4 に示された程度の相違であれば、そのことが識別結果に対して本質的な影響を及ぼさないことを意味している。

(ii) 条件B

以上のことからテストフィールドについても非正規性による影響は無視してよい程度と考えられ、事実テストデータに対して求めたひずみや尖度はトレーニング用データのそれらと類似の値を示した。

したがって、上記の矛盾は代表性の欠如に帰着させられる。代表性に関してはデータ解析の段階では、地上のことはよくわかっていて特定の対象物の占める面積を求めるなどの場合以外は本質的解決方法は存在しない。つまり、対象領域の一部分しか既知でないと

る。
以下この二つの条件について検討する。

(i) 条件A

多次元分布をそのまま扱うことは困難であるので、その周辺分布とみなせる各チャンネルのデータについて考える。

き、トレーニングフィールドを代表性をよくするように領域全域から選択することは不可能である。

ただし、このような状況でなぜ MLH の結果が悪くなるのかを明らかにしておくことは意味がある。

すでに触れたように、MLH での誤識別の傾向を検討すると、データの分散の小さいものが分散の大きいものに誤識別されていることがわかる。MLH が類似度の尺度として、いわば分散を単位とした距離を用いていることを考慮すれば、上の傾向は分散の小さいものほど同じ対象物に対する標準データと現実のデータとの相違が過大評価されること、一方、分散の大きいものほどカテゴリーの相違による特性の相違までもが過小評価されることに依っていると考えることができる。

したがって、LDF や MED で誤識別が減少するのは、これらの分散の相違がならされるため上述の過大評価や過小評価が少なくなるためと考えられる。

さらに、LDF より MED がよい結果を示すことは、LDF における共分散行列による標準データの一種の方向性が、必ずしも現実のデータの標準データからのズレの方向と一致しないことを意味しているといえよう。

このようにトレーニングフィールドの代表性が特に問題となるのは、逆の面からいえば、土地利用図作成のように、データの分散が大幅に異なる種々のカテゴリーを扱う場合である。

6. あとがき

リモートセンシングデータの自動識別において五つの識別手法を実際のデータに適用し、おのおのの持つ特徴を示した。同時に、それを通して自動識別における問題点をデータの統計的性質とトレーニング用データの代表性とを分離できる方法で考察し、後者が識別結果に重要な影響を与える場合のあることを明らかにした。

代表性の成立しない原因は種々挙げられるが、それをあらかじめ知ることはできないとすれば、トレーニング用データの統計的性質が不揃いな場合には、最尤法よりむしろ単純な最短距離法などを用いるほうが高い識別率の得られることも示した。

データの代表性に関しては、それが成立しない原因を明らかにすること、さらに、一つの飛行コースのデータから求めたパラメータを他のコースのデータに拡張して適用する場合の問題を考察すること、一方、識別手法に関しては、スペクトル情報のみならず形状に関する情報をも加味した手法を開発することなどが今

(注4) 表で*、○印は帰無仮説 H_0 「データの分布は正規分布である」が危険率それぞれ1%、5%で棄却されることを示す。

後の課題である。

謝 辞

本研究は「日本国土海洋総合学術診断」プロジェクトの一環として実施したものである。

観測に際しては、国立教育研究所 恩藤知典先生、都立葛飾野高校 新城昇先生、広島大学付属福山中等学校 橋本雅巳先生ほか諸先生方ならびに生徒諸君、日本鋼管福山製鉄所 橋瓜総務部長はじめ諸氏、ならびに気象協会、中日本航空の諸氏からご援助をいただいた。また、上記学術診断プロジェクト、測定解析本部の諸氏からもご援助をいただいた。ここに深く感謝の意を表する次第である。

なお、本研究で使用したプログラムの一部を作成する際、著者の一人 藤村が文部省科研費の援助により、東京大学大形計算機を使用したことを付記する。

参 考 文 献

- 1) K. Fukunaga: Introduction to Statistical Pattern Recognition, Academic Press (1972)
- 2) G. Nagy: Digital Image-Processing Activities in Remote Sensing for Earth Resources, Proc. IEEE, **60-10**, 1177/1200 (1972)
- 3) A. J. Richardson et al.: Computer Identification of Ground Pattern from Aerial Photographs, Proc. of 7th Int. Symp. on Rem. Sens. of Environ., II-1357/1376 (1971)
- 4) A. G. Wacker et al.: Minimum Distance Classification in Remote Sensing, LARS Inf. Note (1972)
- 5) K. S. Fu et al.: Information Processing of Remotely Sensed Agricultural Data, Proc. IEEE, **57-4**, 639/653 (1969)
- 6) R. B. Crane et al.: Performance Evaluation of Multispectral Scanner Classification Methods, Proc. of 8th Int. Symp. on Rem. Sens. of Environ., 815/831 (1972)
- 7) P. H. Swain: Pattern Recognition; A Basis for Remote Sensing Data Analysis, LARS Inf. Note 111572 (1972)