

TRATAMENTO AUTOMÁTICO APLICADO À RESOLUÇÃO DE PROBLEMAS GEOLÓGICOS  
(PROJETO ESTUDO DE ROCHAS INTRUSIVAS)

A.R. dos Santos, C.E. dos Anjos, J.C. Moreira, M.P. Barbosa, P. Veneziani

Instituto de Pesquisas Espaciais

Conselho Nacional de Desenvolvimento Científico e Tecnológico

Caixa Postal 515, 12200 - São José dos Campos, SP, Brasil

RESUMO

O objetivo deste trabalho é testar a viabilidade do uso de algoritmos de extração de informações temáticas de imagens multiespectrais para avaliar o comportamento espectral de rochas graníticas intrusivas. Assim, foram usa dos algoritmos de classificação supervisionada e não-supervisionada. Esses algoritmos de extração de informações temáticas foram também testados em uma imagem modificada, obtida através do procedimento de extração de atributos es paciais implementados no I-100 do INPE. Na análise dos dados foram usadas as representações alfanuméricas das classificações temáticas. Os resultados da área teste mostraram que os algoritmos de classificação supervisionada carac terizaram melhor o corpo granítico, em relação aos outros alvos, o que demon tra a necessidade de um bom conhecimento prévio da região de estudo, quando da aplicação dos algoritmos de extração de informações temáticas.

ABSTRACT

The objective of this work is to test the feasibility of the use of algorithms of extraction of thematic information from multispectral imagery to evaluate the spectral behaviour of intrusive granitic rocks. Thus, algorithms of supervised and non-supervised extraction techniques were used. These algorithms of extraction of thematic information were also tested in a modified imagery, obtained by the extraction procedure of spatial attributes implemented in the Image-100 of INPE. The analysis of the data was performed using alphanumerical representation of thematic information. The results of the test area showed that the algorithms of supervised extraction techniques provided the best discrimination of granitic body from other targets. The results also demonstrated the need for previous knowledge of the study area to correctly apply the algorithms of extraction of thematic information.

1. INTRODUÇÃO

1.1 - LOCALIZAÇÃO DA ÁREA TESTE E JUSTIFICATI  
VA DE SUA ESCOLHA.

Como área teste do presente trabalho, foi escolhida a região do Município de Campos, no norte do Estado do Rio de Janeiro, onde loca liza-se o corpo granítico de Itaoca.

Do ponto de vista geológico, a área está representada por sedimentos de idade Quaternária e por rochas gnáissicas e charnockíticas de idade pré-Cambriana, além do próprio corpo granítico. (Figura 1).

Do ponto de vista fisiográfico, a área ca racteriza-se em sua parte oeste por um relevo serrano e por regiões planas em seu restante; é cortada pelo baixo curso do rio Paraíba do Sul.

Nela existe uma série de lagoas de tama nhos variados, regiões de várzea. As partes mais altas, incluindo o corpo granítico, que possui cotas mais elevadas que os terrenos vi zinhos, estão ocupadas por florestas e matas mistas. As partes mais planas estão representa das por campos e por vegetação associada a ter renos sujeitos a inundação que, em parte, estão ocupados pelo cultivo em grande escala, da ca na-de-açúcar, ou por ele substituídos. O prin cipal centro urbano é a cidade de Campos, se de do município (Figura 2).



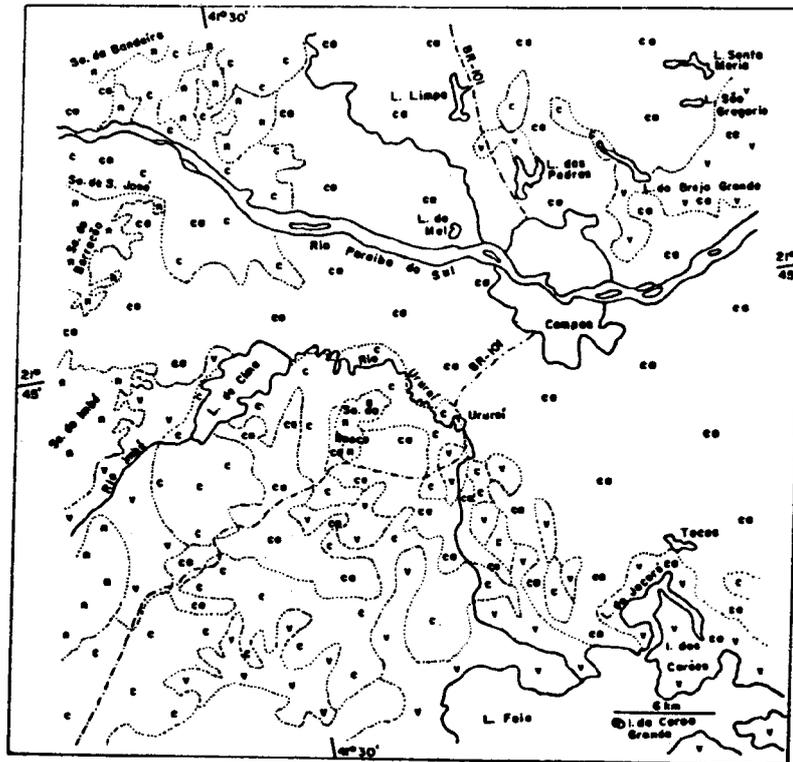


Fig. 2 - Distribuição aproximada dos domínios de vegetação na região do Município de Campos.

- n - Floresta, Mata, Cerrado, Macega, Caatinga;
- c - Campos (em parte ocupados pela cultura de cana de açúcar);
- v - Vegetação associada a terrenos sujeitos a inundação (em parte ocupados pela cultura de cana de açúcar);
- ca - Cana-de-açúcar;
- Limite aproximado dos domínios de vegetação

FONTE - IBGE (1975).

Assim, por suas características geológicas e fisiográficas, a área escolhida atendeu aos propósitos do trabalho, que consistem em testar a capacidade dos algoritmos de classificação na identificação espectral de um determinado tipo de rocha; no caso específico deste trabalho, as rochas testadas são graníticas intrusivas, em áreas de características não-homogêneas.

Deve-se frisar que o corpo granítico de Itaoca é facilmente delimitável através da interpretação visual das imagens LANDSAT, devido ao seu realce topográfico e ao contraste com o relevo plano dos sedimentos circunvizinhos, os quais permitem que se faça este teste em área com características geológicas e fisiográficas quase ideais.

A imagem utilizada no trabalho (359-27) é de 22.06.1976.

## 1.2 - PROCEDIMENTOS PARA EXTRAÇÃO DE INFORMAÇÕES TEMÁTICAS.

A principal função do Sistema Interativo de Análise de Imagens Multiespectrais (I-100) é a extração de informações temáticas de imagens multiespectrais e, secundariamente, a realização do processamento espacial. Como já foi descrito anteriormente, o presente trabalho visa testar os algoritmos de extração de informações temáticas, com o propósito de individualizar, através das características espectrais, corpos graníticos intrusivos; contudo, não pretende estabelecer um novo procedimento, pois foi utilizada uma sequência de metodologias já definida, partindo-se da mais simples para a mais sofisticada.

Existem duas formas de realizar a extração de informações temáticas: a supervisionada e a não-supervisionada. A classificação supervisionada difere da forma não-supervisionada pelo fato de que as áreas de treinamento são definidas pelo analista. Na forma supervisionada foram utilizados algoritmos de classificação do tipo:

1- Determinístico- Método do Paralelepípedo (Dutra et alii 1981) ou Aquisição de Assinatura de Cella Única (GE, 1975) e Divisão em Intervalos de Intensidade (Dutra et alii, 1981) ou *Grey Level Slicer* (GE, 1975) - amostras pré-classificadas são apresentadas ao classificador para que ele possa, daí, extrair as características das classes a serem definidas ou seja, o algoritmo fornece ao usuário os valores de nível de cinza de um determinado "pixel" indicado pela área de treinamento;

2- Estatístico- Classificador Bayesiano (Dutra et alii, 1981) ou Sistema MAXVER (Velasco et alii, 1979) - destina-se à classificação estatística ponto a ponto de imagens multiespectrais através do classificador gaussiano por máxima verossimilhança.

Na forma não-supervisionada foi utilizado o algoritmo de agregamento Média-K (Hartigan, 1975), que considera como função discriminante a menor distância euclidiana de um ponto ao centro de várias classes.

Em relação ao Processamento Espacial, foram utilizados algoritmos de filtragem digital, que ressaltam aspectos de imagem, caracterizados pela existência de bordas; como exemplo de bordas, tem-se o relevo, que é caracterizado pelas transições de áreas sombreadas para áreas iluminadas, devido ao ângulo da iluminação solar, ou pelas transições naturais, como limites entre culturas agrícolas (Dutra et alii, 1981; Dutra, 1982).

Também foi usado um sistema de classificação híbrido, isto é, a fase de treinamento do classificador supervisionado (MAXVER) foi baseada no resultado de classificação de um algoritmo não-supervisionado (Média-K).

## 2 - AQUISIÇÃO DE ASSINATURA DE CELA ÚNICA

A aquisição de assinatura de cella única é realizada através de áreas de treinamento fornecidas pelo analista.

A finalidade da utilização deste algoritmo foi verificar o comportamento espectral do corpo granítico de Itaoca, em relação aos outros alvos da área teste.

Para isso, a área teste foi dividida em oito classes distintas:

Classe g - Definida sobre o corpo granítico de Itaoca.

Classe Q - Definida sobre os sedimentos quaternários.

Classe T - Definida sobre os sedimentos terciários.

Classe G - Definida sobre a área de predominância das rochas gnáissicas.

Classe Ch - Definida sobre a área de predominância de rochas charnockíticas.

Classe Ci - Definida sobre a área urbana da cidade de Campos.

Classe V - Definida sobre áreas sujeitas a inundações.

Classe A - Definida sobre as lagunas.

Na aquisição da assinatura espectral da cela única, procedeu-se de 2 modos:

1 - Usou-se uma área de treinamento com 36 pontos para cada classe.

2 - Usou-se uma área de treinamento com 180 pontos para cada classe.

O algoritmo fornece os histogramas das áreas de treinamento referentes a cada canal, com a possibilidade de modificar o limite inferior e/ou superior. No presente trabalho, a modificação dos limites dos histogramas não foi realizada, partindo-se do princípio de que todos os *pixels* amostrados de uma determinada área de treinamento definiam uma classe. Assim, os níveis de cinza compreendidos em um histograma caracterizam a classe através da assinatura espectral da cela única.

A Tabela 1 mostra os dados resultantes da análise da assinatura espectral de cela única, onde se pode ver que todas as classes estão caracterizadas em cada canal por um intervalo pequeno de níveis de cinza.

As Figuras 3 e 4 mostram um exemplo da representação das celas únicas em 3 dimensões, com dados das áreas de treinamento de 180 e 36 pontos, respectivamente. Estão representadas as celas únicas das classes g, Q e Ch.

A análise dos histogramas Fig.5 permitiu considerar que uma distribuição gaussiana para cada classe adapta-se melhor ao comportamento espectral das classes consideradas que o modelo determinístico. As distribuições de cada classe são perfeitamente caracterizadas na hipótese de gaussianidade, obtendo-se os parâmetros de média e variância que identificam as áreas sob estudo. A média está associada ao brilho médio da área e a variância ao seu contraste (Dutra et alii, 1981).

Como resultado da análise dos dados de aquisição de assinatura espectral, tem-se que a classe g, definida sobre o corpo granítico de Itaoca, apresentou menor sobreposição em relação às outras classes.

### 3. PROGRAMA DE DIVISÃO EM INTERVALOS DE INTENSIDADE

É um programa auxiliar que divide o histograma de um determinado canal em *fatias* de densidade (G.E. 1975). O programa consegue sectionar a imagem em até 8 faixas de níveis de cinza. Assim, no presente trabalho foram uti-

lizadas 8 faixas, número correspondente ao total de classe em que a área teste foi dividida anteriormente. O fatiamento é processado de maneira que não exista superposição de níveis de cinza.

Foi escolhido o canal 7 para ser submetido ao programa SLICER, por ser o canal que caracterizava melhor visualmente o corpo granítico de Itaoca.

O resultado obtido não foi satisfatório, pois mostrou que somente as classes A, Ci e V eram bem separadas.

### 4. SISTEMA MAXVER

O sistema MAXVER destina-se à classificação ponto a ponto de imagens multiespectrais, obtidas, em geral de satélites (Velasco et alii., 1979).

O sistema MAXVER é chamado de supervisionado, pois em sua etapa inicial o analista fornece o número de classes e as áreas de treinamento de cada classe correspondente. Na etapa de classificação não existe interferência do usuário. O programa é baseado na regra de decisão por máxima verossimilhança. Assim, pode-se ter 2 tipos de erros (Velasco et alii, 1979).

1) Quando se têm pontos ou objetos que não possuem identidade com as classes definidas, estes não serão classificados. Tal erro é chamado de *erro de omissão*.

2) Quando pontos ou objetos de uma determinada classe são classificados como pertencentes a uma segunda classe, tal erro é chamado de *erro de comissão*.

Nas Figuras 3 e 4 pode-se ver que existe a possibilidade de pontos das classes Q, Ch serem classificados como da classes g.

Para permitir a comparação do método estatístico (usado no classificador MAXVER) com os classificadores determinísticos anteriormente descritos, tomaram-se as mesmas áreas de treinamento e as mesmas classes utilizadas anteriormente.

O sistema calcula uma matriz de classificação a partir da análise das amostras, que fornece uma estimativa da separação entre as classes e dos erros prováveis de classificação (Ribeiro et alii, 1980).

Foram usadas áreas testes no total de 736 pontos para cada classe, com intuito de testar o desempenho das áreas de treinamento, isto é, definir a melhor amostragem, principalmente em relação à classe g,

TABELA 1  
INTERVALO DOS NÍVEIS DE CINZA DAS AMOSTRAS

Classes	g							Q							T							G						
	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7				
Canais do LANDSAT	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7				
Pontos Amos	24-37	09-22	11-49	30-72	29-38	16-25	28-29	41-58	27-38	15-35	26-51	42-66	25-38	17-34	19-40	31-59	29-42	18-43	14-44	27-62	29-42	18-43	14-44	27-62				
trados	164	23-32	09-27	05-44	18-70	31-35	25-37	36-56	27-42	14-35	21-46	34-64	29-42	18-43	14-44	27-62	29-42	18-43	14-44	27-62	29-42	18-43	14-44	27-62				
Classes	Ch							Ci							V													
	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7				
Canais do LANDSAT	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7	4	5	6	7				
Pontos Amos	25-33	11-26	21-51	37-78	29-41	18-39	11-33	24-42	24-33	13-22	06-18	21-26	32-41	19-35	09-24	20-39	26-31	14-19	07-20	22-24	26-31	14-19	07-20	22-24				
trados	164	28-35	12-25	37-59	66-88	32-41	19-35	09-24	20-39	26-31	14-19	07-20	22-24	26-31	14-19	07-20	22-24	26-31	14-19	07-20	22-24	26-31	14-19	07-20	22-24			

Foram usadas áreas de treinamento com 36 e 180 pontos.

Observando-se as matrizes de classificação de áreas de treinamento de 36 e 180 pontos (Tabela 2 e 4) e as respectivas matrizes de classificação de áreas testes (Tabelas 3

e 5), verifica-se que os erros de comissão (pontos de uma classe que são classificados como pertencentes a outras classes) são menores para a classe *g* com amostragem de treinamento de 36 pontos, embora o desempenho médio (a média dos pontos classificados corretamente) para 180 pontos tenha sido maior para o restante das classes

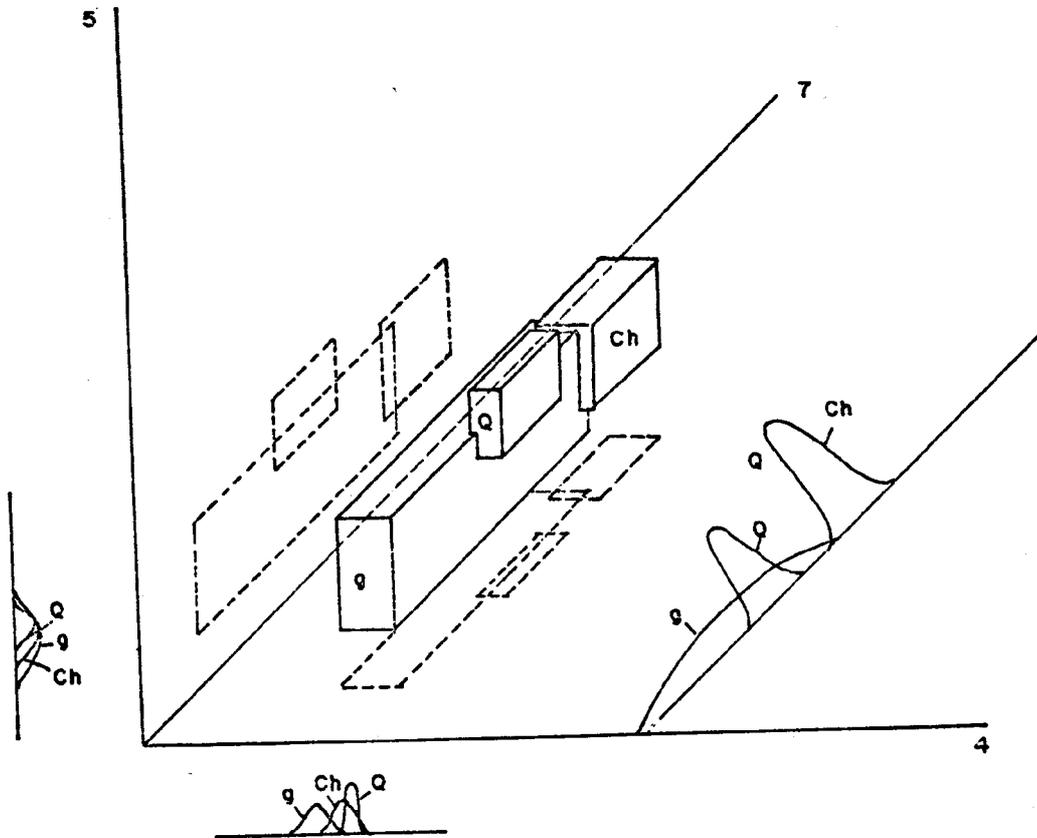


Fig. 3 - Aquisição de assinatura pela única, com dados das áreas de treinamento de 180 pontos.

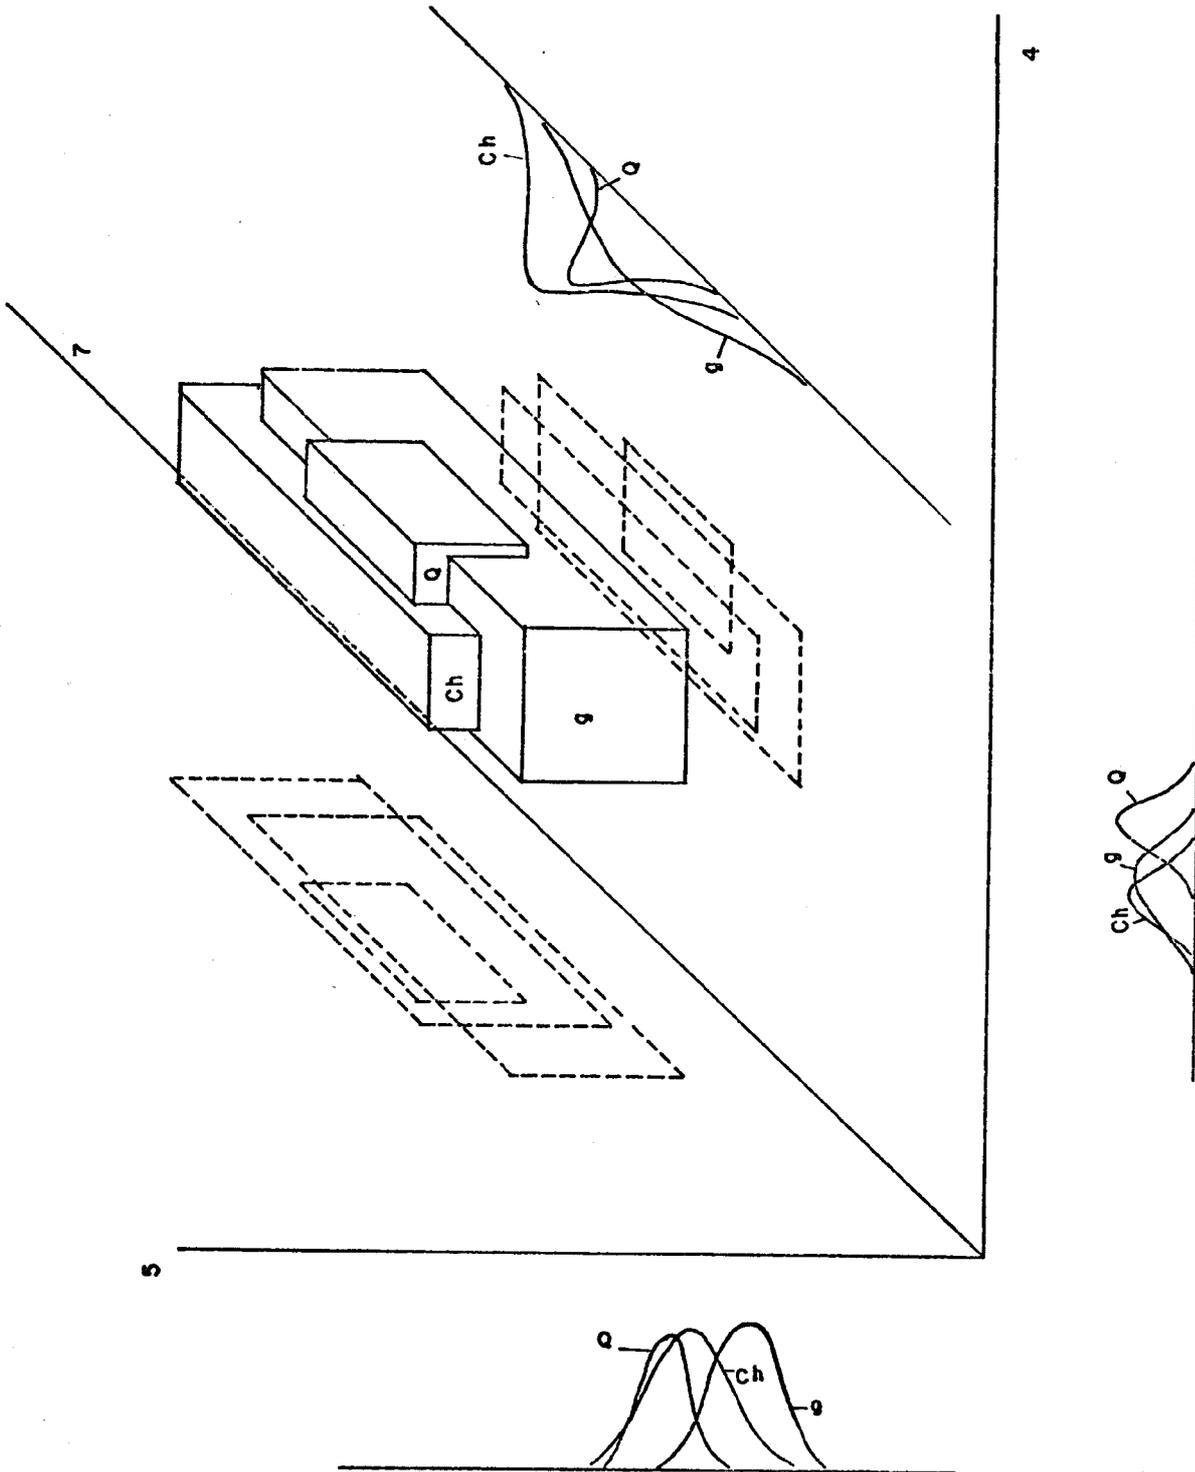


Fig. 4 - Aquisição de assinatura de cala única com dados das áreas de treinamento de 36 pontos.

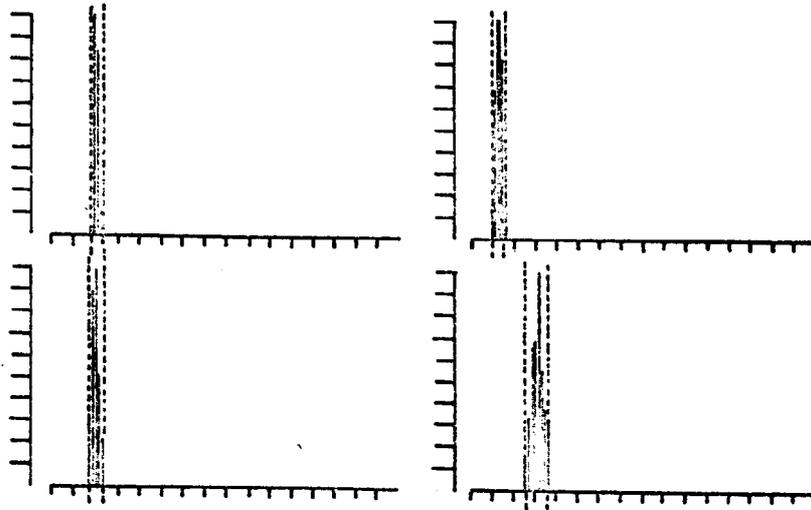


Fig. 5 - Histograma da classe Q, apresentado no terminal gráfico do I-100.

OVERVIEW

```

* LB UB DEL PEAK MEAN VAR +
1 29 38 10 16. 32.9 2.5 +
2 16 25 10 9. 21.3 4.8 +
3 28 39 12 10. 32.9 8.2 +
4 41 58 18 6. 50.1 15.9 +
TRAINING AREA = 36. PIXELS +
ALARMED AREA = 81762. PIXELS (31,2%) +
TYPE CHANNEL * OR E (X) IT
    
```

TABELA 2

MATRIZ DE CLASSIFICAÇÃO DE ÁREA DE TREINAMENTO - MAXVER DE 36 PONTOS

	N*	1	2	3	4	5	6	7	8
1.g	0,0	88,9	0,0	2,8	2,8	5,6	0,0	0,0	0,0
2.Q	0,0	0,0	63,9	11,1	29,0	0,0	0,0	0,0	0,0
3.T	0,0	8,3	0,0	58,3	22,2	0,0	11,1	0,0	0,0
4.G	0,0	5,6	2,8	22,2	58,3	0,0	2,8	8,3	0,0
5.Ch	0,0	5,6	0,0	0,0	0,0	94,4	0,0	0,0	0,0
6.V	0,0	11,1	0,0	0,0	0,0	0,0	88,9	0,0	0,0
7.CI	0,0	0,0	0,0	0,0	5,6	0,0	0,0	94,4	0,0
8.A	0,0	0,9	0,0	0,0	0,0	0,0	0,0	2,8	98,3

\* Porcentagem de pontos não-classificados de uma classe

TABELA 3

MATRIZ DE CLASSIFICAÇÃO DA ÁREA TESTE - MAXVER DE 36 PONTOS

	N*	1	2	3	4	5	6	7	8
1.g	0,8	42,7	12,0	28,9	9,4	1,0	3,7	1,6	0,0
2.Q	0,1	8,8	36,3	27,9	24,2	0,4	0,3	2,0	0,0
3.T	0,0	17,8	25,0	21,9	29,3	1,0	1,5	3,5	0,0
4.G	0,1	17,7	12,1	20,0	32,5	0,0	6,1	11,4	0,1
5.Ch	0,7	56,7	1,9	15,1	1,8	22,1	0,8	1,0	0,0
6.V	0,0	32,5	1,1	0,0	3,9	0,0	37,5	24,9	0,1
7.Ci	1,2	1,2	4,9	3,3	65,4	0,0	0,3	23,4	0,4
8.A	0,1	3,3	0,0	0,0	0,0	0,0	0,5	0,5	95,5

\* Porcentagem de pontos não-classificados de uma classe

TABELA 4

MATRIZ DE CLASSIFICAÇÃO DE ÁREA DE TREINAMENTO - MAXVER DE 180 PONTOS

	N*	1	2	3	4	5	6	7	8
1.g	0,0	43,3	8,9	8,9	3,3	32,2	3,3	0,0	0,0
2.Q	0,0	11,1	56,7	16,7	10,6	3,3	0,0	1,7	0,0
3.T	0,0	13,3	25,0	29,4	15,0	6,7	6,7	3,9	0,0
4.G	0,6	2,2	4,4	16,1	45,0	0,0	19,4	11,7	0,0
5.Ch	0,6	11,7	0,0	5,0	4,4	76,7	1,7	0,0	0,0
6.V	0,0	6,1	0,0	1,1	3,9	1,1	81,1	6,1	0,6
7.Ci	0,6	0,0	1,7	1,7	17,2	0,0	1,7	77,2	0,0
8.A	0,0	0,0	0,0	0,0	2,8	0,0	0,6	0,0	96,7

\* Porcentagem de pontos não-classificados de uma classe

TABELA 5

MATRIZ DE CLASSIFICAÇÃO DE ÁREA TESTE - MAXVER DE 180 PONTOS

	N*	1	2	3	4	5	6	7	8
1.g	0,4	29,7	14,0	18,3	11,8	16,2	9,0	1,2	0,0
2.Q	0,0	9,6	49,0	22,8	8,6	3,9	1,9	4,1	0,0
3.T	0,1	9,8	24,7	32,3	17,5	5,6	3,9	6,0	0,0
4.G	0,3	3,3	7,5	26,9	31,5	3,0	17,5	9,9	0,1
5.Ch	0,3	33,2	1,1	6,4	4,8	50,8	3,3	0,3	0,0
6.V	0,0	0,8	0,7	1,5	6,0	0,3	83,0	7,7	0,0
7.Ci	0,3	0,1	3,7	4,9	28,7	0,4	0,5	61,0	0,4
8.A	0,4	0,3	0,0	0,0	2,7	0,0	1,4	0,3	95,0

\* Porcentagem de pontos não-classificados de uma classe.

Assim pode-se dizer que no presente trabalho o melhor resultado da classificação da classe g foi obtido com a menor amostragem.

5. ALGORITMO DE CLASSIFICAÇÃO MÉDIA-K

Segundo Dutra et alii (1982) o algoritmo de classificação média-K, tem a finalidade de determinar relações naturais de dados, que sejam similares segundo essas relações. Divide-se a massa de dados em classes, de uma maneira não-supervisionada, ou seja, sem a interferência do usuário. O algoritmo de classificação Média-K tem a capacidade de agrupar os dados em até 32 classes das quais selecionaram-se 8 no presente trabalho.

O trabalho com o algoritmo de classificação Média-K tem seu início a partir da determinação de uma área de treinamento, que pode ser toda a imagem ou parte dela (área definida pelo cursor ou por tema), que contenha as formações das classes de interesse. A esta área de treinamento é aplicado o programa ORDCEL, que, segundo Dutra et alii (1982), é executado para fazer contagem e ordenação das celas nela existentes. O programa adquire as celas em 2 ou 4 canais, e a ordenação é feita considerando-se a ordem decrescente de população de cada cela. População é o número de vezes que a cela ocorre na área de aquisição (Dutra, et alii, 1982).

Após a realização do programa ORDEL o algoritmo Média-K define as classes utilizando um algoritmo baseado na distância euclidiana entre celas. A classificação *pixel a pixel* da área teste será baseada no critério de máxima verossimilhança, em relação às classes definidas pelo algoritmo.

O resultado da classificação pelo algoritmo Média-K em 4 e em 2 canais não foi satisfatório, não permitindo, assim, que o corpo granítico fosse individualizado. Este fato pode estar relacionado com a limitação do algoritmo que utiliza somente as mil primeiras celas, isto é, as de maior frequência de ocorrência na área de treinamento.

Para testar o resultado da classificação Média-K, criaram-se áreas testes; o resultado da matriz de classificação (Tabela 6), que considerou como parâmetros de treinamento os definidos pelo algoritmo Média-K, mostra que os erros de comissão para as classes foi muito alto, embora a abstenção média (pontos não classificados ou erro de omissão) tenha sido baixa.

6. ALGORITMO DE EXTRAÇÃO DE ATRIBUTOS ESPACIAIS (SELATR), CONJUGADO COM O SISTEMA MAXVER E COM O ALGORITMO DE CLASSIFICAÇÃO MÉDIA-K.

Um atributo de imagem é uma propriedade que pode ser medida e divide-se em :

- a) atributos naturais, que derivam da aparência visual da imagem, como o nível de cinza, as bordas e a textura;
- b) atributos artificiais, que são obtidos por manipulação e medidas na imagem, como o histograma e a frequência espacial (Dutra, 1982).

TABELA 6

MATRIZ DE CLASSIFICAÇÃO DE ÁREAS TESTES - PARÂMETROS MÉDIA-K

	N*	1	2	3	3	5	6	7	8
1.g	3,1	0,4	12,6	20,8	2,9	32,3	11,8	14,0	2,0
2.Q	0,0	0,1	31,8	2,4	4,5	38,7	7,9	14,5	0,0
3.T	1,6	1,1	26,0	4,6	7,3	18,5	17,4	23,5	0,0
4.G	0,8	1,0	11,5	19,2	14,5	7,5	31,0	14,4	0,1
5.Ch	21,7	0,0	2,9	27,6	0,4	31,4	5,7	9,4	0,5
6.V	0,3	0,0	0,7	0,7	8,6	0,0	86,4	2,7	0,7
7.Ci	0,1	0,7	4,1	1,1	42,9	1,2	2,6	46,9	0,4
8.A	0,4	0,0	0,0	2,9	0,0	0,0	0,0	0,0	96,7

\* Porcentagem de pontos não-classificados de uma classe.

Segundo Dutra (1982), a extração de atributos é um fator importante na determinação da precisão que se pode alcançar em tarefas de classificação de imagens multiespectrais, pois a classificação ponto a ponto não utiliza toda a informação disponível, porque despreza o relacionamento espacial existente entre os pontos da imagem que pertencem a uma mesma classe.

Em síntese, o procedimento de criação e extração de atributos espaciais, cria 12 novos canais, a partir dos 4 canais originais do LANDSAT e dos quais são escolhidos os 4 melhores.

Estes 4 melhores canais são conseguidos através de filtragens. São usados os seguintes algoritmos:

- 1 - MD5FIL - é um filtro 5 x 5 (matriz de pontos) para realce e amaciamento de bordas. A opção utilizada neste trabalho foi a de amaciamento, pois podendo haver uma variação grande de uma mesma classe quando se faz o amaciamento por um filtro *passa baixo*, tende-se a eliminar esta variação dentro da classe, o que resulta uma melhor separação entre as classes.
- 2 - VARIHV - é um filtro de 3 x 3 para extração de atributos de rugosidade. Foi usada a opção soma, que mede a variação horizontal e vertical, como o parâmetro divisor com o valor 1, obtendo-se assim a variação máxima entre os níveis de cinza numa área de 3 x 3 pixels.

Os filtros utilizados são operadores que fazem transformações de imagens utilizando propriedades locais.

Após o processamento de extração de atributos espaciais, foram aplicados o sistema MAXVER e o algoritmo de classificação Média-K.

Para o sistema MAXVER foram usadas as áreas de treinamento com 36 e 180 pontos, por terem apresentado um resultado satisfatório em relação à classe *g*, na aplicação deste sistema aos dados originais. O resultado foi satisfatório quando se verificou a identificação do corpo granítico de Itaoca na classificação temática. As Tabelas 7 e 8 mostram as matrizes de classificação das áreas testes, onde se pode observar que, no processamento com áreas de treinamento de 180 pontos, o desempenho médio da classe *g* melhorou, embora os erros de comissão tenham sido maiores.

O algoritmo de classificação Média-K foi aplicado também em duas modalidades, usando-se 4 e 2 canais. Nenhuma das duas modalidades forneceu resultados satisfatórios, provavelmente devido à limitação do número de celas (máximo igual a 1.000) que, após a aplicação dos algoritmos de atributos espaciais, tornam-se mais diferenciadas. A Tabela 9 mostra a matriz de classificação de áreas testes, criadas para testar a classificação do algoritmo Média-K, que usou como parâmetros de classificação os definidos pelo algoritmo. Nela pode-se ver que os erros de comissão foram tão altos quanto os de classificação Média-K sobre os canais originais.

A seguir aplicou-se um processamento "híbrido" (Média-K + MAXVER).

Usando-se o resultado da classificação temática através do algoritmo Média-K, processou-se a individualização de áreas de treinamento para o sistema MAXVER. Na classificação temática final deste sistema híbrido, o corpo granítico foi bem identificado. As Tabelas 9 e 10 mostram as matrizes de classificação para áreas de amostragem de 36 pontos.

TABELA 7

MATRIZ DE CLASSIFICAÇÃO DE ÁREAS TESTES - SELATR. MAXVER DE 36 PONTOS

	N*	1	2	3	4	5	6	7	8
1.g	61,7	21,6	2,9	9,8	4,1	0,0	0,0	0,0	0,0
2.Q	64,5	0,0	33,2	2,3	0,0	0,0	0,0	0,0	0,0
3.T	53,4	1,5	15,9	21,5	7,7	0,0	0,0	0,0	0,0
4.Q	49,3	0,5	1,0	29,5	19,7	0,0	0,0	0,0	0,0
5.Ch	54,3	38,3	0,0	6,2	0,0	1,1	0,0	0,0	0,0
6.V	86,1	0,0	0,7	0,1	0,0	0,0	8,3	4,8	0,0
7.Ci	89,4	0,0	0,4	1,4	0,7	0,0	0,0	8,2	0,0
8.A	31,7	0,0	0,0	0,0	0,0	0,0	0,0	0,0	68,3

\* Porcentagem de pontos não-classificados de uma classe

TABELA 8

MATRIZ DE CLASSIFICAÇÃO DE ÁREAS TESTES - SELATR. MAXVER DE 180 PONTOS

	N*	1	2	3	4	5	6	7	8
1.g	7,5	27,9	18,6	23,9	18,1	4,1	0,0	0,0	0,0
2.Q	0,1	3,1	52,7	36,8	6,5	0,0	0,0	0,7	0,0
3.T	3,0	3,5	9,1	58,3	24,3	1,6	0,0	0,1	0,0
4.G	0,1	1,0	3,0	22,0	72,6	0,0	0,0	1,4	0,0
5.Ch	3,4	34,8	0,1	5,0	1,9	54,8	0,0	0,0	0,0
6.V	0,8	0,1	0,3	0,0	5,3	0,0	86,6	4,9	0,0
7.Ci	5,0	0,0	3,3	2,7	10,3	0,0	0,1	78,5	0,0
8.A	17,7	0,5	0,0	0,0	0,0	0,0	3,5	0,0	78,3

\* Porcentagem de pontos não-classificados de uma classe

TABELA 9

MATRIZ DE CLASSIFICAÇÃO DE ÁREAS DE TREINAMENTO-SELATR. MÉDIA-K. MAXVER.

	N*	1	2	3	4	5	6	7	8
1.g	0,0	97,2	0,0	0,0	0,0	2,8	0,0	0,0	0,0
2.Q	0,0	0,0	100,0	0,0	0,0	0,0	0,0	0,0	0,0
3.T	0,0	0,0	0,0	100,0	0,0	0,0	0,0	0,0	0,0
4.G	0,0	0,0	0,0	0,0	97,2	0,0	2,8	0,0	0,0
5.Ch	0,0	0,0	0,0	0,0	0,0	100,0	0,0	0,0	0,0
6.V	0,0	0,0	0,0	0,0	16,7	0,0	83,3	0,0	0,0
7.Ci	0,0	0,0	0,0	5,6	0,0	0,0	0,0	94,4	0,0
8.A	2,8	0,0	0,0	0,0	0,0	0,0	0,0	0,0	97,2

\* Porcentagem de pontos não-classificados de uma classe

TABELA 10

MATRIZ DE CLASSIFICAÇÃO DE ÁREAS TESTES - SELATR. MÉDIA-k. MAXVER

	N*	1	2	3	4	5	6	7	8
1.g	33,3	29,3	5,7	7,3	5,3	0,0	0,0	1,4	
2.Q	7,3	0,7	31,4	51,5	1,6	0,0	7,5	0,0	0,0
3.T	19,3	1,0	9,1	47,3	11,1	0,0	12,2	0,0	0,0
4.G	10,5	0,0	0,1	25,0	51,0	0,0	12,8	0,7	0,0
5.Ch	55,7	2,0	0,0	4,8	3,5	34,0	0,0	0,0	0,0
6.V	73,8	0,0	0,0	0,3	3,4	0,0	15,5	7,1	0,0
7.C	9,4	0,0	0,5	17,4	3,9	0,0	0,1	68,6	0,0
8.A	41,8	0,0	0,0	0,0	0,3	0,0	0,4	0,0	57,5

\* Porcentagem de pontos não-classificados de uma classe

## 7 - ANÁLISE DOS DADOS

Os resultados dos programas do I-100 são apresentados no vídeo de um monitor de TV e podem ser registrados das seguintes formas:

- 1 - através de fotografias (em papel ou dia positivos) com máquinas fotográficas comuns;
- 2 - através do Gravador de Imagens DICOMED, que fornece fotografias polaróides ou filmes negativos e diapositivos;

3 - através da impressão de um mapa alfanumérico pela impressora de linhas *printout*, no caso da extração de informações temáticas.

Para realização da análise dos dados foi escolhida a última modalidade, o *printout* (Figura 6). Em relação a fotografias coloridas e/ou diapositivos, o *printout* tem a vantagem de não forçar a interpretação dos resultados. As combinações de tons podem induzir a uma subjetividade o que força a interpretação visual.

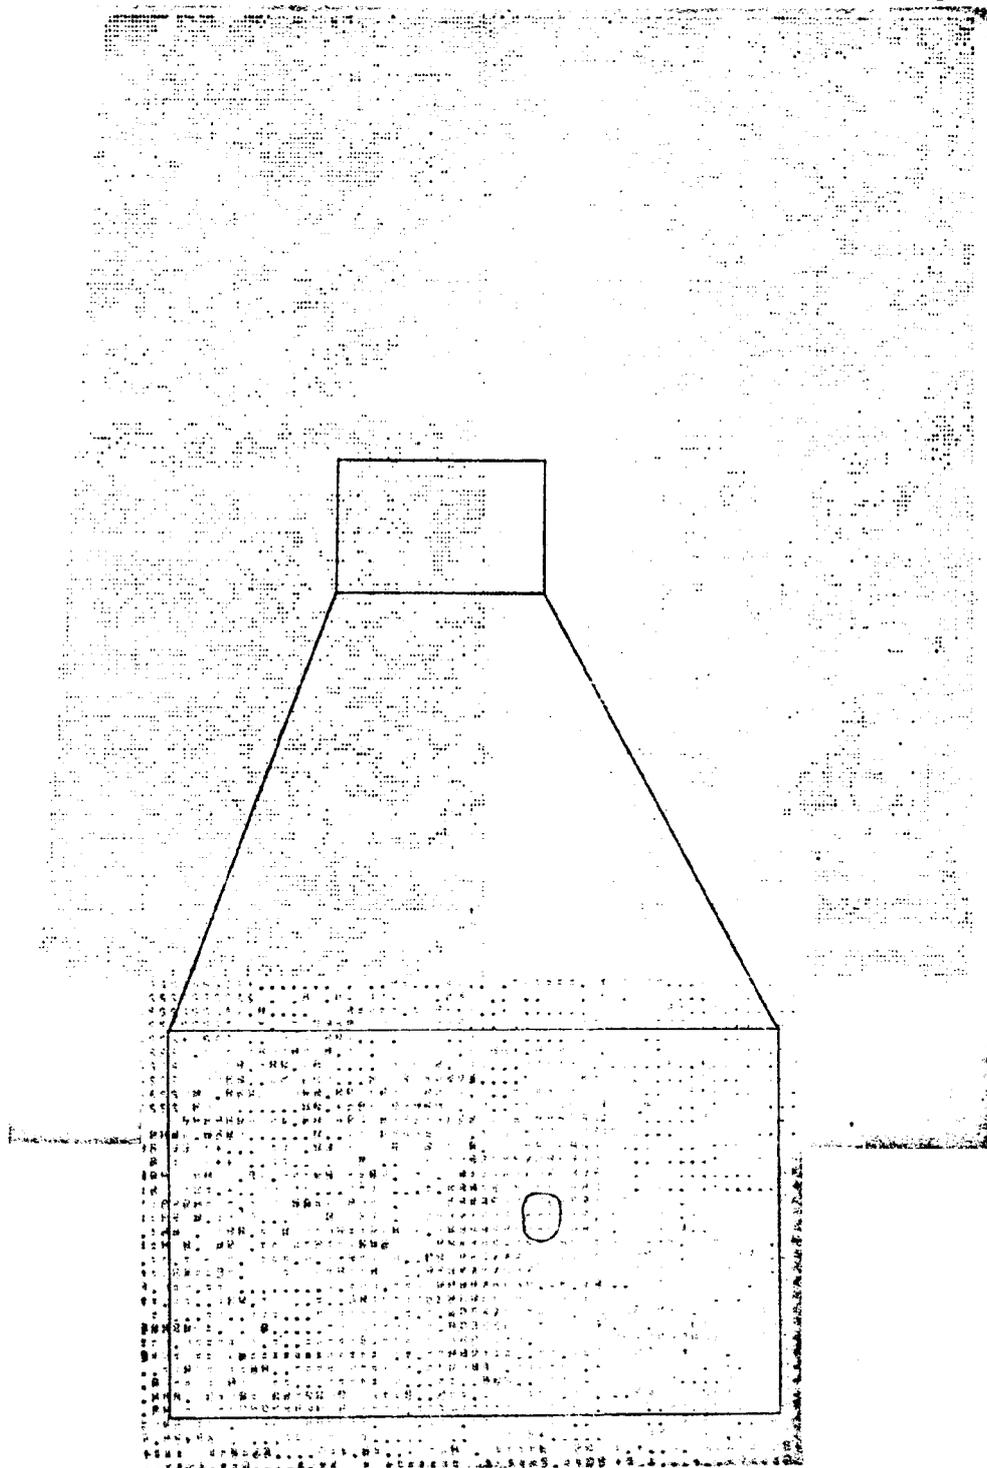


Fig. 6 - *Printout* do resultado do MAXVER de 36 pontos, em que se destaca à área do corpo granítico de Itaoca.

Sobre os *printouts* foi feita uma identificação da cada símbolo e sua associação com uma determinada classe. Na Figura 6, por exemplo, o símbolo que está dentro do círculo foi considerado como representante da classe *g*, por estar bem relacionado com as áreas do corpo granítico, onde tal classe foi definida. O símbolo *ponto* foi associado à classe *G*, por ter uma maior distribuição na área de ocorrência das rochas gnáissicas, procedeu-se dessa maneira com todos os outros símbolos. Na individualização dos símbolos optou-se pela quantidade significativa; o número significativo escolhido foi 3, em linhas ou colunas diferentes. As áreas não classificadas foram integradas a uma ou mais classes, às quais estavam associadas. Os pontos considerados não significativos foram absorvidos pelos de maior ocorrência. Depois dessa individualização, separaram-se as classes predominantes (Figura 7) e o resultado da análise dos *printouts* está exemplificado pelas Figuras 8 e 9.

## 8 - CONCLUSÕES

- 1 - O emprego da aquisição da assinatura espectral de celsa única foi de grande utilidade, pois mostrou que as amostras estavam distribuídas gaussianamente, o que indicou a viabilidade do emprego de técnicas mais rigorosas de extração de informações temáticas, como por exemplo o sistema MAXVER, além disso, também ajudou na escolha das áreas de treinamento.
- 2- O corpo granítico de Itaoca caracteriza nos algoritmos de classificação supervisionada (MAXVER; Extração de Atributos Espaciais + MAXVER) ou num sistema híbrido (Extração de Atributos Espaciais + Média-K + MAXVER).
- 3- Não foi possível caracterizar o corpo granítico de Itaoca através dos algoritmos de classificação não-supervisionada.
- 4- O trabalho mostrou que não é possível isolar um intervalo de nível de cinza, característico somente de um determinado alvo geológico.
- 5- Para obter um resultado satisfatório é necessário que haja um bom conhecimento prévio de toda a região de estudo, como mostram os resultados dos algoritmos de classificação supervisionada.
- 6- Para obter uma separabilidade ideal, onde somente o alvo de interesse fique caracterizado por um determinado intervalo espectral (de nível de cinza), é necessária uma diferença brusca entre os níveis de cinza do alvo de interesse e de seus vizinhos.

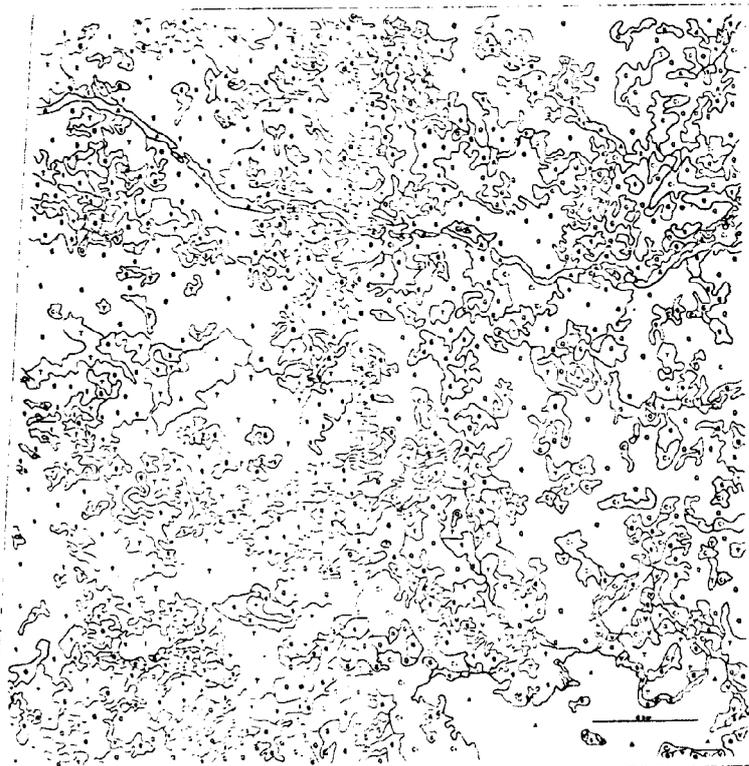


Fig. 7 - Individualização das classes a partir do *printout* - MAXVER de 36 pontos.

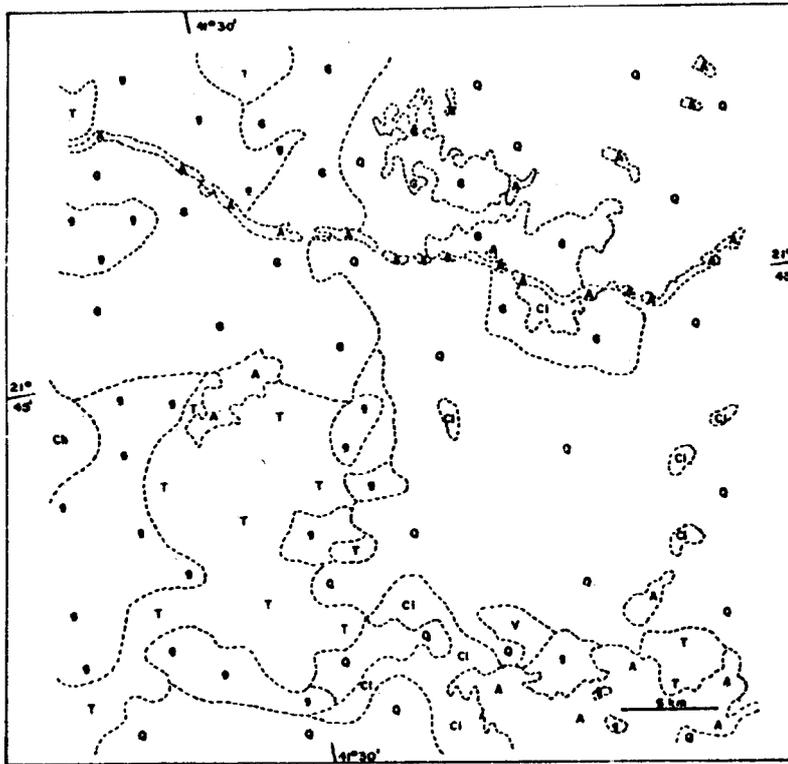


Fig.8 - Mapa das classes predominantes-  
MAXVER de 36 pontos

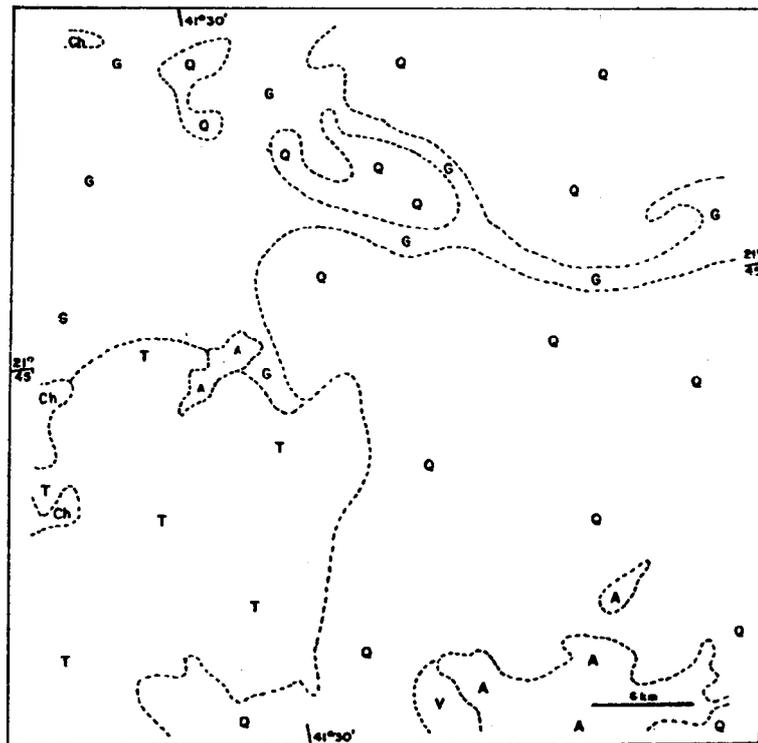


Fig. 9 - Mapa das classes predominantes  
Extração de Atributos Espaciais  
+ Algoritmo de classificação  
Média-K.

- 7 - O emprego das técnicas de extração de informações temáticas só é válido para uma mesma área. Não é possível nem recomendável extrapolar dados de um alvo conhecido para outros não conhecidos e identifica-los como sendo alvos com características físicas e químicas semelhantes. Eles serão semelhantes e pertencerão somente a uma mesma classe de assinatura espectral, mas não pertencem obrigatoriamente a um mesmo alvo, como mostra a Figura 8, em que, além do corpo granítico, outras áreas foram também classificadas como pertencentes à classe de assinatura espectral g.

#### REFERÊNCIAS BIBLIOGRÁFICAS

- DUTRA, L.V. *Extração de Atributos Espaciais em Imagens multiespectrais* - São José dos Campos, INPE, 1982.
- DUTRA, L.V.; MOREIRA, J.C.; II, F.A.M. *Manual de Usuário dos Sistemas de Tratamento de Imagens Digitais* - São José dos Campos, INPE (no prelo)
- DUTRA, L.V.; SOUZA DE, R.C.M.; II, F.A.M.; MOREIRA, J.C. *Análise Automática de Imagens Multiespectrais* - São José dos Campos, 1981.
- GENERAL ELECTRIC COMPANY - *Image - 100, User Manual* - Daytona Beach, Florida, USA, 1975.
- HARTIGAN, J.A. *Clustering Algorithms*. New York, John Wiley, 1975.
- IBGE - Superintendência de Cartografia - *Carta do Brasil - Esc. 1: 250.000*, Rio de Janeiro, 1975.
- RIBEIRO, E.A.; II, F.A.M.; MOREIRA, J.C.; DUTRA, L.V.; OLIVEIRA, S.B.M. *Processamento de Imagens e Classificação de Padrões in: Curso de Treinamento: Aplicações de Sensoriamento Remoto, Com Ênfase em imagens LANDSAT, no levantamento de Recursos Naturais*, 1980.
- SANTOS, A.R.; ANJOS, C.E.; BARBOSA, M.P., VE NEZIANI, P. *Projeto Estudo de Rochas Intrusivas*, São José dos Campos, no prelo.
- VELASCO, F.R.D.; PRADO, L.O.C.; SOUZA, R.C.M. *Sistema MAXVER. Manual do Usuário* - São José dos Campos, 1979