

CLASSIFICAÇÃO DE CENAS EM IMAGENS GOES MULTIESPECTRAIS MEDIANTE UM MÉTODO DE "AGRUPAMENTO DINÂMICO".

Marcus Jorge Bottino e Juan Carlos Ceballos

Centro de Previsão de Tempo e Estudos Climáticos

CPTEC/INPE - Cachoeira Paulista - SP

bottino@cptec.inpe.br, ceballos@cptec.inpe.br

Resumo

Foi desenvolvido um método de classificação de alvos em imagens GOES 8, baseado no uso de quatro variáveis: reflectância (canal 1) e temperatura de brilho (canal 4), e suas respectivas texturas (variâncias locais). O princípio do método reside em classificar cada elemento de imagem segundo a menor distância euclidiana a um conjunto de centróides de referência num espaço multidimensional. O método é iterativo, de forma que os centróides são definidos por sucessivos processos de classificação até atingir um critério de estabilidade. A aplicação a imagens do setor Sul-Sudeste do Brasil permitiu estabelecer coordenadas típicas dos centróides para diferentes tipos de coberturas. Estes podem ser utilizados para classificação de novas imagens, agora por um processo não supervisionado. Neste trabalho apresentamos a utilização da classificação de um conjunto de imagens mensais para definir reflectâncias típicas relativas a transição de uma cobertura cumuliforme para estratiforme.

Introdução

Para diversos fins, é desejável caracterizar a nebulosidade (tipo de cobertura de nuvens) sobre um local baseando-se em imagens de satélite mas utilizando-se de um "método objetivo", o que permite eliminar o processo "subjetivo" de análise de cenas visualizadas (usualmente no canal infravermelho termal de um satélite). Em particular, a nefanálise baseada num único canal (ou mesmo em mais canais) requer o trabalho de um técnico com experiência neste tipo de identificação. Por outro lado, um único canal de satélite (por exemplo o canal 4 do GOES) fornece informação incompleta. Por exemplo, campos de nuvens baixas com pouco desenvolvimento vertical aparecem no canal 4 com pouco brilho e textura tênue com respeito a superfície; em contrapartida, nuvens cirros finas não são "enxergadas" no canal visível mas são capazes de ocultar a radiação térmica proveniente dos níveis inferiores, e portanto, contrastando nas imagens infravermelho. Entre outras aplicações, a classificação objetiva de imagens permite diferenciar os tipos de cobertura e definir parâmetros associados a cenários próprios.

Para diversos modelos de estimativa de radiação solar à superfície por satélite é importante o conhecimento da fração coberta por nuvens num alvo. O método usual baseia-se na suposição de nuvens estratificadas onde a nebulosidade é função do brilho detectado pelo satélite. Nestas expressões é relevante o conhecimento de dois valores característicos: o brilho na ausência de nuvens e o brilho quando a cobertura é total. Segundo Ceballos e Bottino (2000) é conveniente definir a variável brilho como uma reflectância bidirecional para que seja minimizada a influência por variações espaciais e temporais na definição dos parâmetros. A reflectância na ausência de nuvens R_{\min} é normalmente avaliada por mapas de valores mínimos. Entretanto, o valor da reflectância para cobertura total R_{\max} é relativamente mais difícil de ser definido; neste trabalho utilizamos um método de classificação objetivo para separar as nuvens cumuliformes e estratiformes e observar a distribuição da reflectância.

A classificação ou identificação de cenas numa imagem de satélite consiste em agrupar por algum critério definido os seus elementos. Em geral, procura-se determinar cada elemento a uma determinada classe. Encontram-se diversos métodos de classificação de imagens na literatura corrente com diversas metodologias e tratamento dos dados. Vários métodos de classificação de nuvens foram testados por Rossow et al. (1987). Todos estes métodos consistem essencialmente de dois passos. O primeiro passo, a detecção de nuvens e superfícies, determina a distribuição da cobertura na imagem. O segundo passo, a análise, determina as suas propriedades.

O uso da informação multiespectral permite uma diferenciação mais abrangente de diversos tipos de nebulosidade. Métodos de classificação de imagens foram desenvolvidos por diversos autores, com maior ou menor complexidade. Por exemplo, os mais simples se limitam a fixar "regiões" da reflectância R e ou da temperatura de

brilho T dentro dos quais podem encontrar-se os principais tipos de nuvens ou superfícies (Tokuno e Tsuchiya, 1993; França et al., 1995; Ellrod, 1995). Outros mais elaborados são mais acurados, contudo apresentam o comprometimento de requerer uma caracterização estatística de amostras previamente reconhecidas e um maior tempo computacional.

Nos métodos estatísticos a identificação e análise do tipo de cobertura não são realizadas em cada pixel da imagem, mas globalmente em um segmento da imagem, usando propriedades estatísticas das variáveis espectrais e ou funções de textura das imagens. Por variável espectral entendemos o sinal associado a um canal de satélite, já uma variável de textura refere-se a parâmetros de variação espacial de brilho associado a um pixel, seja um gradiente, seja uma medida de dispersão ou semelhança com relação aos pixels vizinhos. Dentre os conceitos de medida de semelhança entre dois pixels, encontramos métodos que utilizam probabilidades condicionais e marginais e critérios como o teorema de Bayes para agrupar os elementos de imagem (Baum et al., 1997; Welch et al., 1989). Outros métodos baseiam-se em aspectos como a distância euclidiana entre o elemento a ser classificado e o centróide de uma classe, definidos no espaço multidimensional de suas variáveis (Desbois et al., 1982; Ceballos e Bottino, 1998).

Para classificação de cenas no período diurno, a análise fatorial evidencia que de 10 informações obtidas a partir dos cinco canais do satélite GOES (reflectância no canal 1 e temperaturas de brilho nos outros canais, mais as respectivas texturas), apenas quatro delas (as associadas aos canais 1 e 4) já oferecem o mínimo de informação não redundante sobre um dado pixel (Ceballos e Bottino, 1998).

Esquema de classificação utilizado

Neste trabalho foi utilizado o método estatístico e iterativo denominado de “agrupamento dinâmico” (Desbois et al., 1982), Dynamic Clusters em inglês, Nouées Dynamiques em francês e que denominaremos por MAD, por ser relativamente simples e de reduzido tempo computacional. Sumariamente, o MAD consiste em agrupar uma amostra de pixels em torno de um conjunto de situações ou tipos de cenas, usando como critério de semelhança a distância euclidiana. Supondo que os pixels de uma camada de nuvens ou uma superfície apresentem uma certa homogeneidade na assinatura espectral ou de textura, um conjunto destes pixels é representado por um pico de elevada densidade num histograma. Considerando que um único pixel pode ser representado como um ponto num espaço definido por n variáveis espectrais e de textura, podemos medir a distância entre dois pontos em um espaço euclidiano de n dimensões como segue.

Dados dois pontos A e B situados num espaço vetorial E_n de n dimensões, consideremos os vetores $A=(x_1, x_2, \dots, x_n)$ e $B=(y_1, y_2, \dots, y_n)$, onde x e y são as suas coordenadas. Este espaço será euclidiano com métrica unitária se seus eixos são ortogonais, de forma que a distância D entre os pontos A e B é definida por:

$$D_{AB} = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (1)$$

Supondo que a informação de pixels contendo um determinado tipo de cobertura de nuvem ou superfície possui uma certa homogeneidade espectral e ou textural, estes seriam projetados no espaço E_n como uma “nuvem” de pontos relativamente compacta. Portanto, a metodologia de classificação de uma imagem consiste em separar e identificar cada uma destas “nuvens”.

Dada uma população de K pontos aglomerados em M subconjuntos ou classes, onde cada subconjunto é composto por f_m pontos, $m=1, 2, \dots, M$, um método de classificação pela “mínima distância euclidiana” apresenta três características:

1. Um subconjunto m (classe) é identificado ou simbolizado pelas coordenadas de seu centro de massa G (centróide) definido como:

$$G_m(x_1, x_2, \dots, x_n) = \frac{1}{f_m} \left(\sum_{i=1}^{f_m} x_{1im}, \sum_{i=1}^{f_m} x_{2im}, \dots, \sum_{i=1}^{f_m} x_{nim} \right) \quad (2)$$

onde x_{nim} é o valor do i -ésimo ponto (pixel) do subconjunto m na coordenada n .

2. A distância do i -ésimo ponto a uma classe m é avaliada pela distância euclidiana ($D_{im} = |A_i - G_m|$) desse ponto ao centróide da m -ésima classe.

3. Cada ponto pertence à classe que lhe for mais próxima (critério de mínima distância euclidiana “MDE”).

O MAD é uma técnica de classificação parcialmente supervisionada que propõe definir de forma automática as classes de uma população. Este método é iterativo e parte da escolha inicial de M centróides ou "sementes". Os centróides iniciais podem ser escolhidos arbitrariamente ou provir da escolha intencional de M alvos por inspeção visual e cálculo dos seus centros de gravidade. A seguir, uma população de K pontos é classificada em M subconjuntos pelo critério de MDE. Realizada a discriminação, são calculados novos centróides dos M subconjuntos a partir dos valores médios dos f_m pontos agrupados, e estes podem ser utilizados como coordenadas ("sementes") de um novo processo de classificação. A iteração termina segundo algum critério de convergência, definido de acordo com os objetivos finais.

Materiais e métodos

De acordo com Ceballos e Bottino (1998) apenas os dados dos canais 1 e 4 seriam necessários. Foram utilizados recortes de imagens GOES-8 de 553 colunas por 228 linhas, que incluem os estados do Rio de Janeiro, São Paulo, Paraná e Santa Catarina, entre as latitudes de 29S e 20S e as longitudes de 54W e 40W aproximadamente, denominado como setor Sul-Sudeste. Os arquivos tinham resolução total para o canal 4 e eram amostrados na razão 1:4 em linha e coluna no canal 1 de modo a corresponder-se com os arquivos do canal 4. Acompanhando as imagens foram gravados dois arquivos de posicionamento em latitude e longitude. O número de imagens foi de 542 no mês de novembro com uma frequência de até 18 imagens por dia, e 536 no mês de dezembro com até 19 imagens por dia, no período de 0845 às 2145 UTC do ano de 1998.

Cada elemento de imagem foi definido por um vetor orientado num espaço euclidiano tetradimensional composto de 4 coordenadas mensuradas pelas seguintes variáveis: a reflectância do pixel no canal 1 (R1), a textura da reflectância no canal 1 (X1), a temperatura de brilho no canal 4 (T4) e a textura da temperatura de brilho do pixel no canal 4 (X4). Convém observar que a reflectância ($R=F/\mu_0$) foi adotada como variável em vez do fator de reflectância F , a fim de minimizar diferenças regionais devidas a variações espaciais e temporais da iluminação do sol.

A variável de textura para um elemento de imagem em um canal foi definida como a variância local calculada sobre uma grade de 3x3 elementos vizinhos centrada no ponto considerado. Para minimizar os efeitos de valores extremos resultantes de variâncias elevadas, decorrentes de alvos com grande variabilidade espacial, utilizamos como medida de textura o logaritmo na base 10 da variância local. Dado um elemento de imagem $P_{c,l}$ situado na coluna c e linha l , sua textura no n -ésimo canal foi definida como:

$$X_n(P_{c,l}) = \text{Log}_{10}\{\text{Var}[\text{Val}_n(P_{i,j})]\}; \quad i = c-1, c, c+1; \quad j = l-1, l, l+1; \quad (3)$$

onde $\text{Val}_n(P_{i,j})$ é o valor espectral (da reflectância ou temperatura de brilho) no canal n .

As variáveis enumeradas acima podem assumir valores bastantes díspares entre elas. Por outro lado as variáveis se referem a grandezas com características físicas diferentes, o que impede uma comparação direta. Portanto, ao ser calculada a distância euclidiana entre dois pontos é necessário redimensionar as variáveis para que possuam escalas com "pesos" equivalentes. Este procedimento é realizado normalizando as N coordenadas (variáveis) de um ponto ou centróide pela média (μ_n) e desvio padrão (σ_n) de sua população. Dado um ponto ou centróide definido pelo vetor $A=(x_1, x_2, \dots, x_n)$, o vetor normalizado A' é calculado por:

$$A'(x_1, x_2, \dots, x_n) = \left(\frac{x_1 - \mu_1}{\sigma_1}, \frac{x_2 - \mu_2}{\sigma_2}, \dots, \frac{x_n - \mu_n}{\sigma_n} \right). \quad (4)$$

Considerando que a população de pontos de imagem detectados por satélite representa um número muito grande de situações, é computacionalmente lento aplicar o método de classificação a toda ela, portanto utilizamos uma amostra dessa população. Por outro lado, para que o processo de classificação obtenha uma melhor definição dos centros de gravidade dos subgrupos é importante que a amostra utilizada no processo seja razoavelmente grande para que tenha um número representativo de pontos de cada subgrupo. A representatividade foi procurada utilizando amostras das imagens do setor Sul-Sudeste ao longo do mês de novembro de 1998. Foram selecionados 15 imagens em dias alternados em cada horário disponível, obtendo-se uma amostra com população total de aproximadamente $K=250000$ pontos de imagem para cada um destes horários.

O método de agrupamento começa com a seleção de sementes "iniciais" ou centróides "iniciais" obtidos a partir das imagens. Supomos que a escolha de 30 sementes representa um número suficiente de classes para descrever a variedade de cenários das imagens tratadas. Não foi aplicado nenhum esquema de rejeição de classes no processo iterativo para não eliminar eventuais classes significativas mas com população reduzida. Adotamos como critério de seleção os seguintes passos: a) foram selecionadas três imagens do mesmo horário que apresentassem situações

diversas de tempo, b) cada imagem foi inspecionada e selecionados 10 cenários típicos compreendendo cobertura de nuvens e superfície, c) sobre cada cenário foi extraído um alvo de aproximadamente 5 x 5 pixels e calculado o seu centróide. Uma seleção criteriosa de sementes procurando "enquadrar" todos os tipos característicos de cobertura das imagens reduz o número de iterações necessárias para alcançar a convergência.

O processo iterativo de classificação e convergência procura definir o centro de gravidade de cada agrupamento de pontos (subconjuntos) com características semelhantes no espaço tetradimensional. Definidas as M=30 sementes ou centróides iniciais os seguintes passos compõem o processo:

- 1) Uma amostra de K pontos é inicialmente classificada em M conjuntos pelo critério da MDE.
- 2) Realizada a discriminação, os f_m ($m=1, 2, \dots, M$) pontos agrupados em torno de cada um dos M conjuntos definem M novos centróides a partir do cálculo de seus valores médios em cada variável (Eq. 2).
- 3) Calcula-se o deslocamento quadrático médio (DQM) entre os centróides novos e os anteriores a iteração, definido como:

$$DQM = \sum_{m=1}^M (\delta R1^2 + \delta X1^2 + \delta T4^2 + \delta X4^2)_m / M. \quad (5)$$

Se este deslocamento for superior a um limiar pré-definido, retorna-se ao passo 1 utilizando os novos centróides como centróides iniciais.

- 4) Caso este deslocamento seja inferior ao limiar pré-definido, adota-se os novos centróides definidos pela última iteração como centróides finais.

Neste trabalho definimos que a convergência é alcançada (passo 4) quando o deslocamento quadrático médio dos centróides é inferior a $DQM=16 \times 10^{-4}$. Isto implica que o deslocamento quadrático médio de nenhuma variável foi superior a 16×10^{-4} . Portanto, seus deslocamentos típicos são inferiores a 4×10^{-2} , esperando-se que sejam da ordem de 2×10^{-2} para cada variável.

Considerando a natural variação dos parâmetros radiativos ao longo do ciclo diurno, tais como a temperatura da superfície, a reflectância das nuvens com respeito ao seu estágio de desenvolvimento e as características da textura em função do contraste na temperatura e do ângulo de iluminação do sol, é necessário que sejam definidos conjuntos de centróides finais para pelo menos alguns horários distintos ao longo do dia. Foi adotado o seguinte procedimento: a) inicialmente foram selecionadas as sementes iniciais no horário 1445 UTC (aproximadamente 12 h local) e aplicado o método de agrupamento para definir os centróides finais; e b) estes centróides finais foram utilizados como sementes iniciais de classificação para o horário anterior a este, e assim por diante; do mesmo modo foi aplicado aos horários posteriores a 1445 UTC.

A identificação e validação dos grupos obtidos é um problema comum para todas as técnicas de classificação de nuvens por satélite. Comparações com verdade terrestre são difíceis devido ao modo diverso de observar as nuvens: por cima com uma escala grande como o satélite e de baixo por um estreito ângulo de visada como as observações de superfície. Diante destas limitações optamos por uma comparação subjetiva com nefanálise de imagem e uma avaliação "física" das variáveis dos centróides. Este procedimento foi aplicado com o auxílio de um software de visualização e manipulação desenvolvido para este fim.

Resultados

Os resultados do método foram utilizados para classificar o conjunto de imagens do mês de novembro de 1998, e sua nefanálise permitiu a identificação dos 30 grupos encontrados. A Tabela 1 resume estes resultados.

Os 30 grupos foram estratificados em cinco conjuntos de classes: superfície (Sp), campos cumuliformes (Cu), estratiformes (St), cirrififormes (Ci) e situações de multicamadas (Mc) nas quais incluímos a classe referente aos cumulonimbos. A Figura 1 ilustra uma imagem classificada pelos 30 centróides com cores distintas para cada um dos 5 conjuntos de classes. Algumas classes podem apresentar grupos nos quais diferentes tipos de cenas estão presentes (por exemplo, cirros semitransparentes sobre solo, grupo 19; cirros sobre estratos, grupo 26). Observa-se que alguns grupos (centróides) que seriam coincidentes num diagrama de dispersão (R1,T4), diferenciam-se pela textura (por exemplo, as classes cumuliformes 9 e 10 apresentam reflectância e temperatura de brilho semelhantes a classe estratiforme 15, mas a textura X4 é significativamente maior), evidenciando-se que o uso das variáveis texturais permite uma melhor classificação de cenas. É relevante notar que o grupo 29 que inclui os cumulonimbos representa apenas 1,5 % da amostra total; entretanto seu centróide é claramente diferente dos outros vinte e nove.

Se este grupo tivesse sido eliminado por um critério simples como o de baixa frequência, no processo iterativo, então um tipo bem diferenciado de nebulosidade poderia não ter sido identificado. Por outro lado, a inclusão dos pixels correspondentes nos grupos mais próximos teria provocado uma indefinição na posição do centróide deste último.

Os resultados expostos podem ter diversas aplicações, por exemplo: o mascaramento de nuvens para fins de estimativa de temperatura superficial, ou área coberta por campos de cirros. No contexto de um modelo de radiação solar por satélite, a estimativa da cobertura envolve os parâmetros associados ao céu sem nuvens R_{\min} e a uma cobertura total R_{\max} . O primeiro foi avaliado para cada horário através da seleção dos valores mínimos de reflectância ao longo de um conjunto de imagens nos meses de novembro e dezembro de 1998. Os histogramas de reflectância revelam que um valor médio de 0,06 para o solo e de 0,03 para o mar pode ser adotados de forma geral para todos os horários (Fig. 2).

A reflectância associada a transição cumuliforme-estratiforme foi avaliada para cada horário por histogramas de frequência acumulada de pixels classificados pelos conjuntos Cu e St. A Tabela 2 apresenta a reflectância associada a alguns limites de frequência acumulada, verifica-se que em média 90% dos cumuliformes possuem uma reflectância inferior a 0,29 e que em 90% dos estratiformes esta é superior a 0,33. Estes resultados sugerem que um valor médio $R_{\max} = 0,3$ pode ser adotado para todos os horários.

Conclusões

O método de classificação MAD permitiu definir um conjunto de 30 centróides para cada horário diurno referentes as imagens do setor Sul-Sudeste de novembro de 1998. A identificação das centróides resultou na definição de cinco conjuntos de classes representando: superfície, campos cumuliformes, estratiformes, cirriformes e situações de multicamadas.

Foram avaliados valores típicos de reflectância para as situações de céu descoberto e para transição de uma cobertura cumuliforme-estratiforme. No primeiro caso foi encontrado um valor de reflectância médio de 0,06 e 0,03 para o solo e mar respectivamente. Histogramas de reflectância avaliados para os conjuntos de classes Cu e St, indicaram que o valor de reflectância médio 0,3 pode ser adotado para todos os horários.

Referências


- Baum B. A., V. Tovinkere e R. M. Welch, 1997. Automated cloud classification of global AVHRR data using a fuzzy logic approach. *Journal of Appl. Meteorology*, **36**, 1519-1540.
- Ceballos J.C. e M.J. Bottino, 1998. Classificação automática de cenas: Uma análise da informação mínima contida em imagens GOES-8 multiespectrais. Anais do X Congresso Brasileiro de Meteorologia, Brasília (compact disk art. MS98032).
- Ceballos J.C. e M.J. Bottino, 2000. Modelo CPTEC GL para estimativa de radiação solar por satélite: versões GL1.0 e GL1.1. Anais do XI Congresso Brasileiro de Meteorologia, Rio de Janeiro.
- Desbois M., G. Sèze e G. Szejwach, 1982. Automatic classification of clouds on Meteosat imagery: Application to high-level clouds. *Journal of Applied Meteorology*, **21**, 401-412.
- Ellrod G. P., 1995. Advances in the detection and analysis of fog at night using GOES multispectral infrared imagery. *Weather and Forecasting*, **10**, No. 3, 606-619.
- França J. R. A., J. M. Brustet, J. Fontan, 1995. Multispectral remote sensing of biomass burning in West Africa. *Journal of Atmospheric Chemistry*, **22**, 81-110.
- Rossow W. B., F. Mosher, E. Kinsella, A. Arking, M. Desbois, E. Harrison, P. Minnis, E. Ruprecht, G. Sèze, C. Simmer e E. Smith, 1987. ISCCP cloud algorithm intercomparison. *Journal of Climate and Applied Meteorology*, **24**, 877-903.
- Tokuno M. e K. Tsuchiya, 1993. Classification of cloud types based on data of multiple satellite sensors. *Adv. Space Res.*, **14**, No. 3, 199-206.

Tab. 1. Resultados do método de classificação para as imagens GOES 8 do horário 1445 UTC de novembro de 1998 no setor Sul-Sudeste. Dados das 30 classes, a frequência de pixels, os valores espectrais e texturais médios (coordenadas das centróides), a estimativa da altura das nuvens e as características verificadas.


Classes e conjuntos	Freq. por classe	Reflectância		Temp. de Brilho		Altura do topo (km) (Nota 1)	Característica (Nota 2)	
		Canal 1 R1 (n=1)	X1 (n=2)	Canal 4 T4 (n=3)	X4 (n=4)			
1	Sp	19335	0,03	-1,10	292	-1,88	-	Superfície (água)
2		14706	0,04	-0,93	295	-1,09	-	Superfície (água ...)
3		18343	0,06	-0,62	299	-0,23	-	Superfície (solo)
4		14721	0,08	0,37	295	0,04	-	Superfície (solo ...)
5		10978	0,06	0,18	294	-0,99	-	Superfície (solo ...)
6	Cu	14171	0,10	1,15	294	-0,24	1,6	Cu
7		8095	0,22	1,44	287	-0,10	2,0	Cu
8		13505	0,15	1,69	289	0,48	2,3	Cu
9		6502	0,28	1,72	275	1,19	3,5	Cu
10		7985	0,32	1,71	280	0,51	2,1	Cu
11	St	3199	0,46	1,89	267	1,37	4,3	St + Ci
12		5173	0,36	1,52	277	-0,19	2,7	St
13		3123	0,45	1,50	278	-0,85	2,6	St
14		5044	0,48	0,84	265	-0,41	4,6	St + Ci
15		3290	0,29	1,24	280	-1,10	2,3	St
16		2830	0,46	0,95	278	-1,52	2,7	St
17		4730	0,48	1,32	265	0,44	4,6	St
18		2552	0,52	0,18	250	-0,86	6,9	St + Ci
19	Ci	11459	0,07	-0,30	290	0,65	-	Ci + Sup.
20		16800	0,10	1,10	293	0,54	-	Ci + Cu + Sup.
21		11517	0,10	0,51	278	1,25	-	Ci + Sup.
22		1991	0,20	1,70	265	2,06	-	Ci + Cu + Sup.
23		9014	0,12	1,71	288	1,15	-	Ci + Cu + Sup.
24		8202	0,18	1,07	262	1,59	5,1	Ci
25		7035	0,24	0,70	253	0,81	6,4	Ci
26	Mc	4869	0,40	0,96	251	1,17	6,7	St + Ci
27		4116	0,55	0,69	250	0,28	6,9	St + Ci
28		4130	0,48	0,35	245	0,83	7,7	St + Ci
29		3288	0,50	-0,10	237	-0,02	8,9	Cb + Ci
30		4838	0,36	0,54	247	0,14	7,5	St + Ci
Total	245541							

Nota 1. As alturas do topo das nuvens foram avaliadas utilizando o gradiente vertical de uma atmosfera padrão $\alpha = -6,5$ K/km. Para as classes Cumuliformes (Cu) a temperatura do topo T_c foi corrigida pela nebulosidade assumindo que $T_c = [T_i - (1-C)T_s] / C$, onde T_i e T_s são a temperatura observada pelo satélite e da superfície respectivamente. Nesta equação na verdade não é a temperatura, mas a radiância que é ponderada com a nebulosidade. Entretanto, como a diferenças das temperaturas consideradas são pequenas em relação a ordem de grandeza, é aceitável uma aproximação linear.


Nota 2. Caracterização das classes por nefanálise e considerações físicas dos resultados, onde foram diferenciadas superfícies descobertas (Sp), nuvens cumuliformes (Cu), nuvens estratiformes (St), nuvens cirriformes (Ci) e classes identificadas como situações de multicamadas (Mc). O símbolo de adição foi utilizado para referi-se a sobreposição de classes.



a) Canal 1 (R1)



b) Canal 4 (T4)




1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Superfície					Cumuliforme					Estratiforme					Cirriforme					Multicamada									


c) Classificação

Fig. 1. Imagem do setor Sul-Sudeste, 1445 UTC em 9 de novembro de 1998. A imagem classificada por 30 centróides (c) foi colorida em 6 cores distintas para cada conjunto de tipos de classes. O método de classificação baseia-se nas informações da imagem "visível" (a) e da imagem "infravermelho" (b).


a) 1010Z




b) 1410Z




c) 1745Z




d) 2010Z




e) 1010Z



f) 1410Z



g) 1745Z



h) 2010Z




Fig. 2. Histogramas da reflectância (sem nuvens) das imagens de nov-dez de 1998 do setor Sul-Sudeste para superfícies de solo (a) a (d) e para superfícies de água de (e) a (f).

Tab. 2. Reflectâncias para alguns limites de frequência acumulada para os conjuntos Cu e St no mês de novembro de 1998.

Hora UTC	10:10	11:45	14:45	17:45	20:10	Reflect. média
Limites de Freq. Acumulada	Nuvens Cumuliformes					
90%	0,32	0,29	0,29	0,28	0,29	0,29
95%	0,35	0,33	0,33	0,32	0,34	0,33
	Nuvens Estratiformes					
5%	0,30	0,30	0,33	0,31	0,27	0,30
10%	0,33	0,32	0,36	0,33	0,30	0,33