

Cap. 5 Classificação Temática

5.1 O Processo de Classificação

5.2 Classificação de Máxima Verosimilhança (supervisionada paramétrica)

5.2.1 Classes multivariadas normais

5.2.2 Limites

5.3 Classificador Distância mínima

5.4 Classificador Paralelepípedo

5.5 Classificador Mahalanobis

5.6 Método não supervisionado

5.6.1 K-Means

5.6.2 ISODATA (Iterative Self-Organizing Data Analysis Techniques)

5.7 Avaliação da precisão da classificação

Cap. 5 Classificação Temática

5.1 O Processo de Classificação

A classificação de imagem envolve a atribuição dos pixéis a uma classe espectral particular usando a informação espectral disponível. Esta operação pode ser vista como uma função de mapeamento do espaço multiespectral para o espaço das classes.

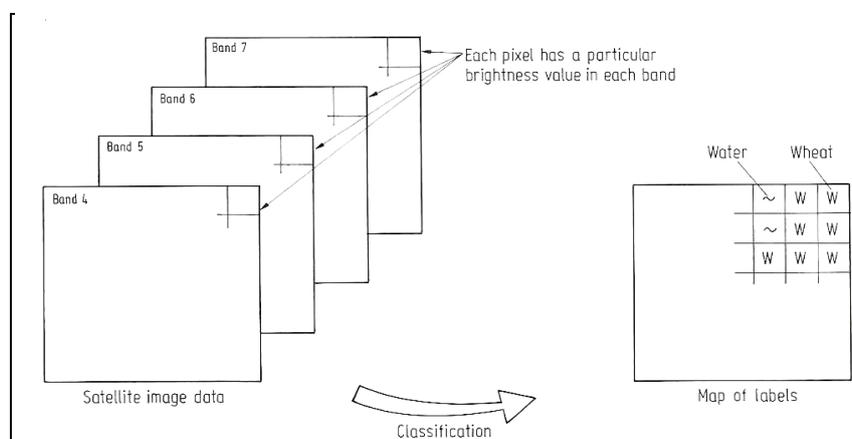


Figura 5.1 – A classificação de imagem como uma transformação entre o espaço multiespectral e o espaço das classes

Podemos dividir os procedimentos de classificação de imagens em duas categorias:

Não supervisionada: Os pixéis numa imagem são atribuídos a classes espectrais sem intervenção do utilizador, sem o conhecimento prévio da existência ou nome das classes.

Supervisionada: Na classificação supervisionada é o utilizador que define as classes espectrais e que seleciona os dados treino.

Paramétrica: É assumido que as classes espectrais podem ser descritas por uma função distribuição de probabilidade no espaço multiespectral.

Passos na classificação supervisionada:

- 1. Escolher a legenda:** Escolher os tipos de cobertura de solo nos quais a imagem será segmentada. Estas são as classes de informação e podem ser: água, região urbana, floresta, pinhal, etc..
- 2. Escolher os pixéis representativos de cada classe legenda.** Estes pixéis são designados por dados treino. Os conjuntos de treino podem ser obtidos por visitas aos locais, mapas, fotografia aérea ou fotointerpretação de uma composição colorida dos dados imagem.
- 3. Usar os dados treino para estimar os parâmetros de um determinado algoritmo de classificação.** Estes parâmetros serão as propriedades do modelo de probabilidades usado ou serão as equações que definem as partições no espaço multiespectral. Os parâmetros para uma dada classe são muitas vezes referidos como assinatura dessa classe.
- 4. Classificar.** Classificar cada pixel da imagem numa das classes definidas previamente (ponto 1) usando o classificador treinado. Todos os pixéis são classificados.
- 5. Produzir a tabela de contingência.** Produzir a tabela de contingência que resume os resultados da classificação.

5. 2 Classificação de Máxima Verosimilhança (supervisionada paramétrica)

Representemos as classes espectrais de uma imagem por:

$$w_i, i=1,\dots,M, \quad M \text{ número de classes}$$

e representemos os pixéis pelo vetor \mathbf{x} :

$$\mathbf{x} = (x_1, x_2, \dots, x_N)$$

Em que x_1, x_2, \dots, x_N é o brilho do pixel \mathbf{x} nas N bandas.

A determinação da classe à qual um pixel na posição \mathbf{x} pertence é uma probabilidade condicional:

$$p(w_i | \mathbf{x}), \quad i=1,..M$$

(probabilidade de ocorrer a classe w_i dada a posição \mathbf{x})

A classificação é feita de modo que:

$$\mathbf{x} \in w_i \quad \text{se} \quad p(w_i | \mathbf{x}) > p(w_j | \mathbf{x}) \quad \text{para todos os } j \neq i$$

Apesar da simplicidade, a probabilidade condicional $p(w_i|\mathbf{x})$ é desconhecida. Vamos supor que temos suficientes dados treino para cada classe. Estes dados treino podem ser usados para estimar uma distribuição de probabilidade para uma classe que descreva a possibilidade de encontrar a classe w_i na posição \mathbf{x} .

Esta distribuição de probabilidade é representada pelo símbolo:

$$p(\mathbf{x} | w_i), \quad i=1,..M \quad \text{haverá tantas } p(\mathbf{x} | w_i) \text{ como classes terreno.}$$

Para um pixel na posição \mathbf{x} no espaço multiespectral pode ser calculada um conjunto de probabilidades que nos dão a proximidade ou grau de vizinhança relativa de um pixel pertencer a cada uma das classes definidas.

A pretendida $p(w_i|\mathbf{x})$ e a existente $p(\mathbf{x}|w_i)$ (estimada com dados terreno) estão relacionadas pelo Teorema de Bayes:

$$p(w_i | \mathbf{x}) = p(\mathbf{x} | w_i) \cdot p(w_i) / p(\mathbf{x})$$

Em que $p(w_i)$ é a probabilidade da classe w_i ocorrer na imagem. Se por exemplo 20% dos pixels de uma imagem pertencem à classe espectral w_i então $p(w_i) = 0.2$. $p(\mathbf{x})$ é a probabilidade de encontrar um pixel de qualquer classe na posição \mathbf{x} . O valor de $p(\mathbf{x})$ é dado por:

$$p(\mathbf{x}) = \sum_{i=1}^M p(\mathbf{x} | w_i) p(w_i)$$

$p(\mathbf{x})$ não é importante na classificação.

A regra de classificação pode ser escrita como:

$$\mathbf{x} \in w_i \quad \text{se} \quad p(\mathbf{x} | w_i) \cdot p(w_i) > p(\mathbf{x} | w_j) \cdot p(w_j) \quad \text{para todos os } j \neq i$$

Esta regra é mais interessante que a anterior uma vez que $p(\mathbf{x}|w_i)$ é conhecido dos dados treino e é aceitável que $p(w_i)$ também seja conhecido, ou pode ser estimado pelo conhecimento que temos da imagem. Por conveniência matemática definimos:

$$g_i(\mathbf{x}) = \ln \{ p(\mathbf{x} | w_i) p(w_i) \} = \ln p(\mathbf{x} | w_i) + \ln p(w_i)$$

Então a regra fica simplificada:

$$\mathbf{x} \in w_i \quad \text{se } g_i(\mathbf{x}) > g_j(\mathbf{x}) \text{ para todos os } j \neq i$$

$g_i(\mathbf{x})$ é referida por função discriminante.

5.2.1. Classes multivariadas normais

Assumimos que a distribuição de probabilidade para cada classe é do tipo multivariada normal. Isto é um pressuposto e não uma propriedade demonstrável das classes espectrais. Vamos assumir que para N bandas:

$$p(\mathbf{x} | w_i) = 2\pi^{-N/2} \left| \sum_i \right|^{-1/2} e^{-\frac{1}{2}(\mathbf{x}-m_i)^t \sum_i^{-1} (\mathbf{x}-m_i)}$$

Em que \mathbf{m} e Σ são o vetor da média e a matriz covariância dos dados da classe w_i . Usando a função discriminante resulta que o termo $-N/2 \ln(2\pi)$ é comum a todos os $g_i(\mathbf{x})$ e por isso não é discriminativo e será ignorado. A função discriminante para classificação de máxima verosimilhança é então dada por:

$$g_i(\mathbf{x}) = \ln p(w_i) - \frac{1}{2} \ln \left| \sum_i \right| - \frac{1}{2} (\mathbf{x} - m_i)^t \sum_i^{-1} (\mathbf{x} - m_i)$$

No caso de não se conhecer o valor de $p(w_i)$ deveremos assumir um valor igual para todas as classes e nesse caso como não será discriminante poderá ser excluído da equação. O mesmo pode ser feito ao valor $\frac{1}{2}$. Neste caso, a função discriminante fica:

$$g_i(\mathbf{x}) = -\ln \left| \sum_i \right| - (\mathbf{x} - m_i)^t \sum_i^{-1} (\mathbf{x} - m_i)$$

5.2.2 Limites

Os pixels em qualquer ponto do espaço multiespectral serão classificados numa das classes espectrais, independentemente de quão pequena seja a probabilidade de pertença a essa classe.

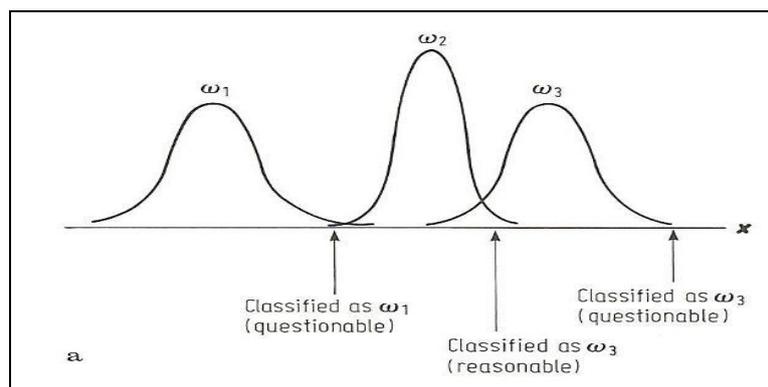


Figura 5.2 – Limites de classificação em função dos histogramas de cada classe.

Isto pode acontecer se as classes são sobrepostas ou sabendo da existência de outras classes não dispomos de dados terreno suficientes para estimar os parâmetros da sua distribuição. Na prática, são aplicados limites (thresholds) à função discriminante e não às distribuições de probabilidade (uma vez que estas não são de facto calculadas). A regra de decisão fica:

$$x \in w_i \quad \text{se } g_i(x) > g_j(x) \text{ e } g_i(x) > T_i \text{ para todos os } j \neq i$$

Em que T_i é o limite considerado com significativo para a classe espectral w_i . Neste caso, uma classificação é aceitável se:

$$\ln p(w_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i) > T_i$$

Ou, equivalentemente:

$$(x - m_i)^t \Sigma_i^{-1} (x - m_i) < -2T_i + 2 \ln p(w_i) - \ln |\Sigma_i|$$

O lado esquerdo da equação tem uma distribuição χ^2 com N graus de liberdade. Se for assumido que x tem uma distribuição normal então N é a dimensão do espaço multispectral. Como resultado, as tabelas do χ^2 podem ser consultadas para determinar o valor do primeiro termo da equação a baixo do qual uma determinada percentagem de pixéis sejam selecionados.

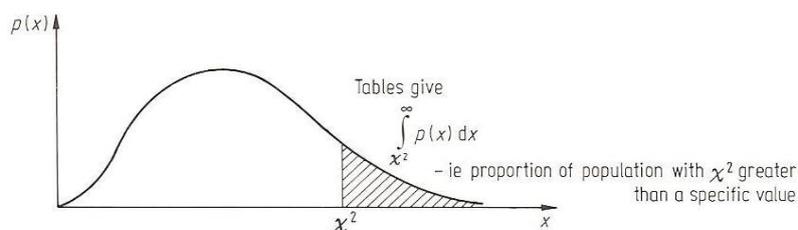


Figura 5.3 – Função χ^2 e a seleção do limite T.

Dado um conjunto de dados treino, representados pelos pontos representados no scattergram da figura 5.4, pretendemos classificar os pixéis indicados com os números 1, 2 e 3. Usando o classificador da máxima verosimilhança o resultado da classificação é: 1 - urbano, 2 - não classificado, 3 - não classificado. Ver figura 5.4.

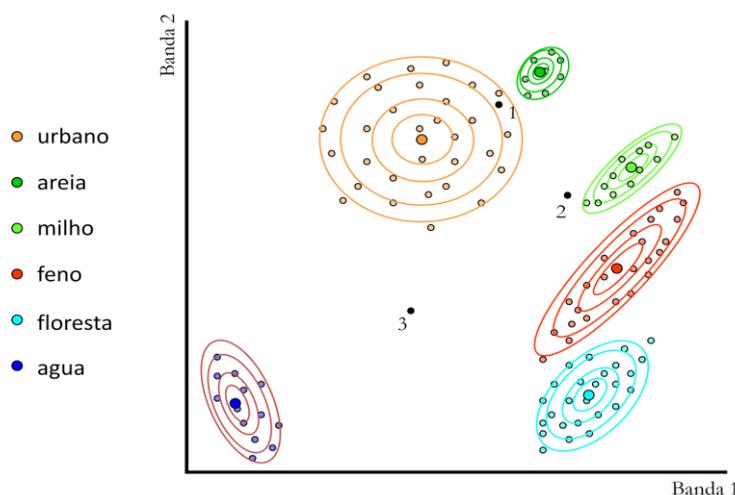


Figura 5.4 – resultado da classificação máxima verosimilhança para os pixéis 1, 2, e 3.

5.3 Classificador Distância Mínima

A qualidade do classificador da máxima verosimilhança depende da exatidão na determinação do vetor da média e da função covariância para cada classe espectral. Esta determinação é dependente do número de dados treino para cada uma dessas classes. Quando não está disponível um número suficiente de dados para treino, é preferível usar um classificador que não requeira uma função covariância mas que dependa apenas da posição média das classes espectrais. A média é sempre mais bem determinada que a covariância.

O classificador da distância mínima satisfaz este requisito. (distancia mínima ao valor da média da classe)

Assumindo m_i ($i=1,..M$) como o valor médio de cada classe, determinado de dados treino, e x a posição do pixel a ser classificado. Calculamos o conjunto de distâncias euclidianas:

$$d(x, m_i)^2 = (x - m_i)^t (x - m_i) \quad i=1, \dots, M$$

Desenvolvendo o produto, obtemos:

$$d(x, m_i)^2 = x \cdot x - 2m_i \cdot x + m_i \cdot m_i$$

A classificação é realizada de acordo com a condição:

$$x \in w_i \text{ se } d(x, m_i)^2 < d(x, m_j)^2 \text{ para todo } j \neq i$$

Com os dados da figura 5.4, o resultado da classificação usando a distancia mínima é :
1- areia; 2 - milho; 3 – água (figura 5.5).

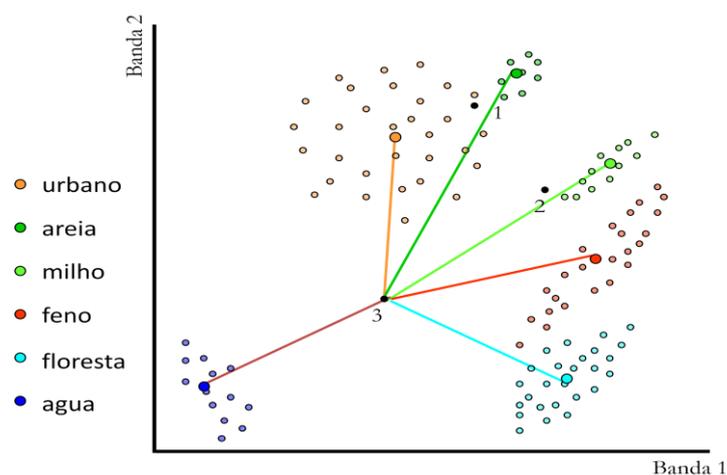


Figura 5.5 – Resultado da classificação distância mínima para os pixéis 1, 2, e 3.

5.4 Classificador Paralelepípedo

O classificador do paralelepípedo é treinado por análise dos histogramas das componentes espectrais com base nos dados treino. O histograma das componentes bidimensionais de dados treino corresponde a uma única classe espectral. Os limites inferiores e superiores são identificados como os vértices e um paralelepípedo (figura 5.6).

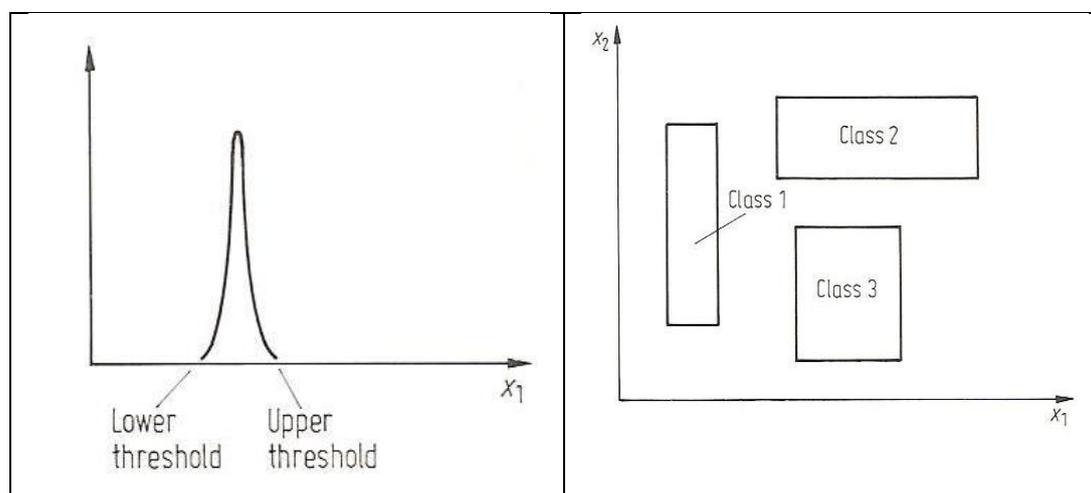


Figura 5.6 – Classificador do paralelepípedo.

Com os dados da figura 5.4, o resultado da classificação usando o classificador do paralelepípedo é: 1 - urbano, 2 - feno, 3 - não classificado (figura 5.7). A desvantagem deste classificador é que nem sempre é possível classificar um pixel de maneira unívoca, veja-se a sobreposição entre as classes milho, feno e floresta.

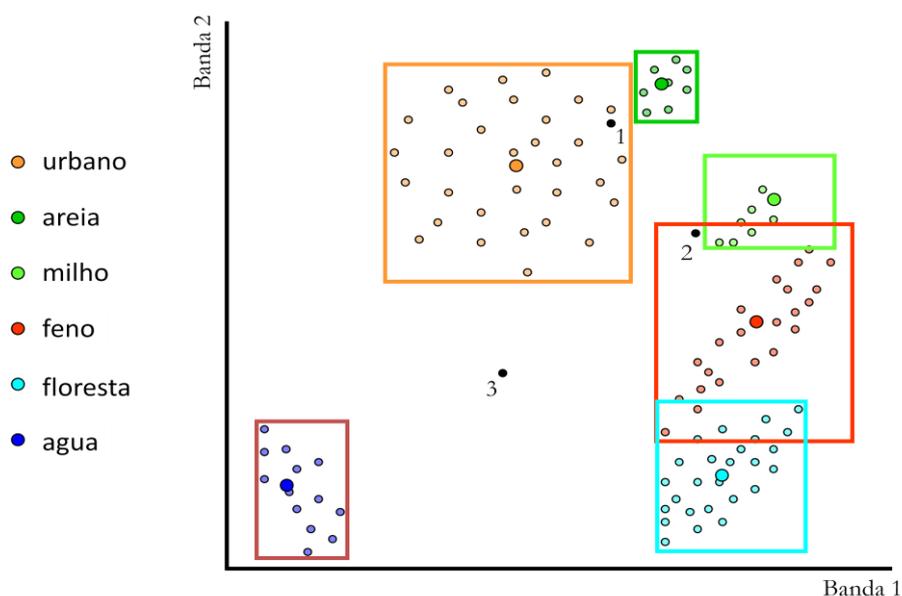


Figura 5.7 – Resultado da classificação paralelepípedo para os pixéis 1, 2, e 3.

5.5 Classificador Mahalanobis

Consideremos a função discriminante para o classificador da máxima verosimilhança. Se invertermos o sinal desta função podemos considerar como uma distância no espaço multivariado (2º termo) à qual foi somada uma constante (1º termo). Neste caso a função é definida como:

$$d(x, m_i)^2 = \ln |\Sigma_i| + (x - m_i)^t \Sigma_i^{-1} (x - m_i)$$

O classificador de máxima verosimilhança pode ser visto como um classificador de distância mínima, em que a distância é sensível à direção e modificada de acordo com a classe.

Consideremos agora o caso em que todas as covariâncias são iguais $\Sigma_i = \Sigma$ para todo o i . O termo $\ln |\Sigma_i|$ deixa de ser discriminante e podemos eliminá-lo. A função discriminante fica definida como:

$$g_i(x) = d(x, m_i)^2 = (x - m_i)^t \Sigma^{-1} (x - m_i)$$

Este é o classificador distância Mahalanobis. Assumindo um constrangimento adicional em que $\Sigma = \sigma I$ o classificador Mahalanobis reduz-se a um classificador de distância mínima. A vantagem do classificador de Mahalanobis sobre a máxima verosimilhança é que é mais rápido e mantém algum grau na sensibilidade à direcção através da função covariância Σ que pode ser uma covariância média de todas as classes ou um modelo.

5.6 Método não supervisionado

Para os métodos não supervisionados não é necessário ter um conhecimento prévio do terreno, nem ter dados treino. Este método baseia-se em algoritmos que analisam todos os pixéis e formam conjuntos de pixéis (os chamados *cluster*) apenas atendendo ao seu valor. Em geral o utilizador pode escolher alguns parâmetros como o número máximo de clusters ou o número mínimo de pixéis que é preciso para formar um *cluster*.

5.6.1 K-Means

Método que particiona n observações em k clusters de acordo com a menor distancia da observação ao cluster com média mais próxima. O algoritmo é iterativo em que em cada iteração a média de cada cluster é recalculada e os pixéis realocados relativamente à nova média. Todos os pixéis são classificados na classe mais próxima a menos que um limite seja especificado. O processo é continuado até que o numero máximo de iterações seja atingido

5.6.2 ISODATA (Iterative Self-Organizing Data Analysis Techniques)

Idêntico ao anterior mas em que o número de clusters é automaticamente ajustado durante o processo iterativo por junção e/ou divisão de clusters com valores muito elevados do desvio padrão

5.7 Avaliação da precisão da classificação

A avaliação da qualidade da classificação baseia-se na tabela de contingências que compara uma amostra dos pixéis classificados com a verdade terreno que poderá ser obtida de trabalho de campo ou de uma fonte atualizada (fotografia aérea, mapa).

Há dois possíveis tipos de erro:

Omissão : Pixéis que não foram atribuídas a uma determinada classe. Por exemplo um pixel que pertencem à classe “água” e não foi atribuído à classe água.

Comissão: quando um pixel associado à classe C_k na realidade pertence à outra classe. Por exemplo um pixel classificado como “água” na realidade pertence a uma das outras três classes (solo nu, floresta ou solo cultivado).

A quantificação dos erros de omissão e de comissão é efetuada usando uma tabela de contingências (tabela 5.1). Ao longo da diagonal do quadro de contingências está o número de pixels corretamente classificados para cada uma das quatro classes (padrões) deste exemplo. A linha j -ésima fornece o número dos pixels que na imagem classificada são associados à classe j -ésima. A coluna i -ésima fornece o número de todos os pixels que no mapa de referência são associados à classe i -ésima.

Tabela 5.1 – Tabela de contingências

	Água	Solo nu	Solo cultivado	Floresta	(produtor)
Água	187	40	7	0	79.9%
Solo nu	11	246	12	9	88.5%
Solo cultivado	0	21	239	39	79.9%
Floresta	0	0	140	49	74.1%
(utilizador)	94.4%	80.1%	60.1%	50.5%	70.6%

E_{ii} é o número de pixels que foram corretamente classificados. E_{ij} é o número de pixels que é conhecido pertencer à classe i -ésima mas que foram classificados pelo computador como pertencer à classe j -ésima.

A percentagem de pixels corretamente classificados é dada por:

$$\sum_{i=1}^N E_{ii} / \sum_{i=1}^N \sum_{j=1}^N E_{ij}$$

No exemplo do quadro de contingências (tabela 5.1), a percentagem de pixels corretamente classificados é 70.6%.

$N = 4$; Suma $E_{ii} = 187+246+239+49= 672$;

Suma $E_{ij} = 40+7+11+12+9+21+39+140+672=951$

5.7.1 Precisão do Utilizador

A percentagem de pixels corretamente classificados é dada por:

$$E_{ii} / \sum_{j=1}^N E_{ij}$$

Água : 79.9%; Solo Nu : 88.5%; Solo Cultivado : 79.9%, Floresta: 74.1%

A precisão do utilizador ser 79.9% para a água diz ao utilizador que apenas 79.9% dos pixéis da imagem classificados como água são na realidade associados a pontos sobre a superfície terrestre realmente cobertos de água. Para o utilizador é importante o que está classificado corretamente!

5.7.2 Precisão do Produtor

No que diz respeito o utilizador é definida a precisão do produtor como:

$$E_{ii} / \sum_{i=1}^N E_{ij}$$

Água : 94.4%; Solo Nu : 80.1%; Solo Cultivado : 60.1%; Floresta: 50.5%

A precisão do produtor ser 50.5% para a floresta diz ao produtor que apenas 50.5% dos pixéis da imagem que sabemos são floresta são classificados como floresta. Para o produtor é importante o que está no terreno e foi corretamente classificado!

Bibliografia:

Fundamentals of Remote Sensing, Canada Centre for Remote Sensing.
http://www.ccrs.nrcan.gc.ca/resource/tutor/fundam/index_e.php

R.A. Schowengerdt, "Remote Sensing. Models and Methods for Image Processing", Academic Press ed.

Remote Sensing Digital Image Analysis, An Introduction. Hohn A. Richards.
Springer-Verlag.

Principles and Applications of Imaging Radar. Manual of Remote Sensing, Third Edition, Vol. 2. Edited by Floyd M. Henderson and Anthony J. Lewis.

Remote Sensing of the Earth Sciences. Manual of Remote Sensing, Third Edition, Vol. 3. Edited by Andrew N. Rencz.