



## *Sensoriamento Remoto: Classificação de imagens - parte 2*

Jorge Centeno - UFPR



# Classificação

---

- ▶ Atribuir a cada pixel um rótulo que o identifique como membro de uma das classes, em função de seus valores do contador digital.
- ▶ Para isto, temos uma descrição de cada classe a partir de amostras (exemplos).
- ▶ O objetivo é classificar cada pixel como pertencendo à classe “mais parecida”.

## Perguntas

- ▶ ***Com quem se parece mais cada pixel, considerando as classes disponíveis?***
  - ▶ ***Como medir o grau de similaridade entre o pixel e as classes?***
-



# Métodos

---

O problema pode ser resolvido com base nas estatísticas das classes, estimadas a partir das amostras.

Exemplos de métodos são:

- ▶ Hipercubos
  - ▶ Distância Mínima (Euclidiana)
  - ▶ Máxima Verossimilhança Gaussiana
-



# Método dos Hipercubos

---

Com base nas amostras de uma determinada classe é possível estimar a faixa de variação dos valores típicos desta classe em cada banda.

É então assumido que um pixel pertencente a esta classe deveria ter valores entre estes valores extremos.

Se o pixel ficar fora destes intervalos, é razoável assumir que ele não pertence à classe.

---

# Exemplo de estatísticas


Classe = “vegetação” ; Número de pixels = 850

| Bandas       | 1    | 2    | 3    | 4    | 5     | 6    | 7    |
|--------------|------|------|------|------|-------|------|------|
| Media        | 17.3 | 12.8 | 15.9 | 10.0 | 137.8 | 59.1 | 25.2 |
| Desv. Padrão | 0.7  | 0.7  | 1.6  | 0.8  | 8.7   | 3.5  | 1.4  |
| Mínimo       | 15.0 | 11.0 | 11.0 | 8.0  | 114.0 | 49.0 | 21.0 |
| Máximo       | 20.0 | 16.0 | 20.0 | 12.0 | 168.0 | 69.0 | 29.0 |

Considerando as bandas 3,4, determine o interval de variação dos pixels nesta classe.

Banda 3: 11-20

Banda 4: 8-12



# Classificação



Se a classe varia entre

|        |      |      |
|--------|------|------|
| Bandas | 3    | 4    |
| Mínimo | 11.0 | 8.0  |
| Máximo | 20.0 | 12.0 |


como classificaria os pixels com valores

- a)  $B3, B4 = (12, 10)$
- b)  $B3, B4 = (9, 9)$  ?

A similaridade, neste caso, é medida em função da posição do pixel em relação aos limites fixados pelo usuário




# Hipercubos



No caso 3D a área delimitada pelos mínimos e máximos forma um paralelepípedo. Em dimensões superiores formam-se hiperparalelepípedos, denominados Hipercubos.

Método dos Hipercubos,


# Hipercubos - desvantagens



Pode ocorrer superposição de regiões de diferentes classes, o que causaria uma situação de dúvida.

Existem valores de pixel possíveis fora de estas regiões. Ou seja, o método não considera todas as possibilidades.

# Hipercubos - desvantagens



Uma vez definidas as regiões, alguns pixels a serem classificados podem

- a) Cair fora das regiões
- b) Cair na área de superposição

Em estes casos, uma solução deve ser dada.

Ex: deixar se classificação;

Ex: escolher uma das classes aleatoriamente.

# Método da distância Euclidiana

---



► 
$$D(A, B) = \sqrt{(x_A - x_B)^2 + (y_A - y_B)^2}$$

---

# Método da distância Euclidiana

- ▶ Lembrando:
- ▶ No espaço bidimensional Euclidiano, a distância entre dois pontos é medida como:
- ▶  $D(A, B) = \sqrt{(x_A - x_B)^2 + (y_A - y_B)^2}$



No espaço tridimensional:


$$D(A, B) = \sqrt{(x_A - x_B)^2 + (y_A - y_B)^2 + (z_A - z_B)^2}$$

Ou generalizando...

$$D^2(A, B) = \sum_{i=1}^n (x_{Ai} - x_{Bi})^2$$

# Distância Mínima Euclidiana

- ▶ Podemos resolver o problema, adotando como valor representativo das classes seus vetores de médias.
- ▶ Para classificar podemos “medir” o grau de semelhança entre um pixel qualquer e cada uma das classes calculando a distância Euclidiana entre o vetor do pixel e a média de cada classe.



$$d^2(x, V) = \sum_{i=1}^2 [(média(V)_i - X_i)^2]$$

$$d^2(x, S) = \sum_{i=1}^2 [(média(S)_i - X_i)^2]$$

Se  $d^2(x, V) > d^2(x, S)$ ,  
X é mais próximo de Solos (S) ... Ou  
seja, se parece mais com solos.  
Seria logico, classificar o pixel como  
“solos”

# Distância Mínima Euclidiana

---

- ▶ O conceito de distância Euclidiana pode ser estendido a “n” bandas

$$d^2(x, A) = \sum_{i=1}^n [(média(A)_i - X_i)^2]$$

Considerando “Nc” classes, deve-se calcular a distância Euclidiana entre o pixel e todas as classes e encontrar a classe associada à menor distância;

X pertence à classe “A” se:  
Se  $d^2(x, A) < d^2(x, B)$ ,

Onde “B” denota todas as outras classes.


---

# Distância Mínima

## ► Pros

- Todos os valores possíveis dentro do espaço n-dimensional são classificados
- Não ocorre superposição de classes
- 

Uma classe sempre será mais próxima de cada pixel, mesmo que a distância seja grande. | Procura-se a “menor” distância. O “mais parecido”





# Avaliação do produto


---

- ▶ Determinação da qualidade temática do produto
-

# Avaliação da qualidade

---

Como posso afirmar que esta  
imagem temática está correta?  
Posso provar que a informação é  
verdadeira?




# Verificação da qualidade

---

Após a classificação se dispõe de um mapa temático, todos os pixels são rotulados como membros de uma classe, mas o processo pode ter erros.

Como saber quantos pixels (%) estão corretamente classificados?

Se ocorrem erros, em qual classe estes erros são mais frequentes?




# Avaliação


---

- Uma opção é comparar o resultado com um mapa com a verdadeira classificação, isto permitiria calcular a taxa de pixels errados.

PRODUTO



correto



Mas,... Se já temos o mapa correto, para que classificar?


---

# Avaliação por amostragem

---

Como não se dispõe de uma verdade completa, pode-se visitar em campo áreas selecionadas para verificar se o classificador funcionou corretamente. Isto é, usando amostras de “verificação”

PRODUTO





Estas amostras são diferentes das amostras de treinamento usadas para calcular as estatísticas usadas no modelo de classificação

---

# Avaliação por amostragem

As amostras devem ser criteriosamente selecionadas na imagem.


- ▶ Elas devem estar bem distribuídas na imagem;
- ▶ Devem ser representativas e em número suficiente;
- ▶ A quantidade de pixels por classe deve ser parecida.



# Avaliação por amostragem

Comparando a observação de campo (verdadeira) e a classificação obtida nestas regiões selecionadas se pode calcular:

- ▶ quantos pixels realmente são de uma classe e foram classificados dentro dessa classe (OK)?
- ▶ quantos pixels realmente são de uma classe e foram classificados dentro de OUTRA classe (x)?



# Exemplo de comparação


- ▶ Sabe-se que uma região de 8x8 pixels é coberta plenamente de vegetação, mas no resultado da classificação aparecem 4 pixels de solo e dois de área urbana. Qual a taxa de sucesso deste classificador nesta área?

|           | total     | vegetação | solo | urbana | água |
|-----------|-----------|-----------|------|--------|------|
| vegetação | <b>64</b> | 62        | 4    | 2      | 0    |

- ▶ Corretos = 62
- ▶ Taxa =  $62/64 = 96,9\%$
- ▶ Isto significa que o classificador teve uma taxa de sucesso de 96,9% para esta classe
- ▶ Acurácia do ponto de vista do PRODUTOR



verdade



classificado

# Verdade vs classificação

- ▶ Esta análise pode ser repetida para cada classe considerando todas as possíveis confusões do classificador

|         |           | classificação |           |           |           |           |
|---------|-----------|---------------|-----------|-----------|-----------|-----------|
| verdade |           | <i>total</i>  | vegetação | solo      | urbana    | água      |
|         | vegetação | 64            | <b>62</b> | 4         | 2         | 0         |
|         | solo      | 70            | 3         | <b>60</b> | 7         | 0         |
|         | urbana    | 71            | 10        | 20        | <b>40</b> | 1         |
|         | água      | 65            | 1         | 1         | 2         | <b>60</b> |


Esta comparação pode ser organizada sob forma de uma tabela, também chamada de matriz de confusão.

Os acertos estão na diagonal principal. A confusão do classificador aparece fora da diagonal.

# A matriz de confusão


É uma forma de representar as coincidências e contradições entre a verdade de campo e o resultado da classificação.

- ▶ São confrontadas duas situações: as linhas correspondem à classe correta e as colunas à classe estimada no processo de classificação.
- ▶ Cada célula armazena o valor de pixels que deveriam ser classificados como a classe especificada na linha e que foram classificados segundo a classe especificada na coluna.
- ▶ Numa situação ideal a matriz será diagonal.



Na verdade é ...

Foi classificado como...



|                                                                                       | A  | B  | C  | D  |
|---------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|
| A  | OK                                                                                     | x                                                                                      | x                                                                                      | x                                                                                      |
| B  | x                                                                                      | OK                                                                                     | x                                                                                      | x                                                                                      |
| C  | x                                                                                      | x                                                                                      | OK                                                                                     | x                                                                                      |
| D  | x                                                                                      | x                                                                                      | x                                                                                      | OK                                                                                     |

# Acurácia Global

## ► Taxa média de Acertos

|           | <i>total</i> | vegetação | solo      | urbana    | água      |
|-----------|--------------|-----------|-----------|-----------|-----------|
| vegetação | 64           | <b>62</b> | 4         | 2         | 0         |
| solo      | 70           | 3         | <b>60</b> | 7         | 0         |
| urbana    | 71           | 10        | 20        | <b>40</b> | 1         |
| água      | 65           | 1         | 1         | 2         | <b>60</b> |

A taxa de pixels corretamente classificados considerando todas as classes fornece uma informação a respeito do desempenho global do classificador

A acurácia global

$$AG = \frac{\textit{soma da diagonal}}{\textit{soma de todos os pixels de verificacao}}$$

# Acurácia GLOBAL

|           | <i>total</i> | vegetação | solo      | urbana    | água      |  |
|-----------|--------------|-----------|-----------|-----------|-----------|--|
| vegetação | 64           | <b>62</b> | 4         | 2         | 0         |  |
| solo      | 70           | 3         | <b>60</b> | 7         | 0         |  |
| urbana    | 71           | 10        | 20        | <b>40</b> | 1         |  |
| água      | 65           | 1         | 1         | 2         | <b>60</b> |  |
| total     | 270          |           |           |           |           |  |

Neste exemplo:

- ▶ Total de amostras:  $T = 64 + 70 + 71 + 65 = 270$
- ▶ Total de amostras corretamente classificadas :  $C = 62 + 60 + 40 + 60 = 222$
- ▶ Acurácia GLOBAL =  $222/270 = 82,2\%$

# Como avaliar?

| Acurácia Global (%) | Resultado         | Significado Prático                                                                                   |
|---------------------|-------------------|-------------------------------------------------------------------------------------------------------|
| > 90%               | Excelente         | Classificação extremadamente robusta.<br>Pouca margem de erro.                                        |
| 80% - 90%           | Bom/aceitável     | Padrão de corte institucional.<br>O patamar mínimo aceito pelo USGS (Anderson et al., 1976) é de 85%. |
| 70% - 80%           | Regular / Modesto | Resultado com problemas sérios.                                                                       |
| < 70%               | Insuficiente      | Resultado não confiável inaceitável.                                                                  |

Anderson, J. R., Hardy, E. E., Roach, J. T., & Witmer, R. E. (1976). *A Land Use and Land Cover Classification System for Use with Remote Sensor Data* (Geological Survey Professional Paper 964). U.S. Government Printing Office.

# Acurácia do ponto de vista do Produtor


Descreve o desempenho do classificador na identificação dos elementos pertencentes a cada classe.

|           | <i>total</i> | vegetação | solo      | urbana    | água      | AP          |
|-----------|--------------|-----------|-----------|-----------|-----------|-------------|
| vegetação | 64           | <b>62</b> | 4         | 2         | 0         | <b>96,9</b> |
| solo      | 70           | 3         | <b>60</b> | 7         | 0         | <b>85,7</b> |
| urbana    | 71           | 10        | 20        | <b>40</b> | 1         | <b>56,3</b> |
| água      | 65           | 1         | 1         | 2         | <b>60</b> | <b>92,4</b> |

A acurácia do produtor permite avaliar a capacidade do classificador de identificar corretamente os elementos de cada classe de referência, indicando a proporção desses elementos que foi corretamente classificada.

Valores baixos de AP indicam maior ocorrência de erros de omissão e permitem identificar as classes cuja identificação apresenta maiores dificuldades.

# Caso extremo



*Com este mapa, se você for em campo e encontrar um pixel de vegetação, com certeza esse pixel está bem classificado em meu mapa.*

*Ou seja, do ponto de vista do produtor terei 100% de acurácia.*

# Do Ponto de Vista do Usuário

O usuário do mapa temático gostaria de saber a confiabilidade de cada classe.

“qual a certeza de um pixel atribuído a uma determinada classe ser mesmo de essa classe?”

*Todos os pixels verdes no mapa são mesmo vegetação?*



Se eu for em campo  
neste local,  
encontrarei mesmo  
vegetação? Ou o  
mapa tem erros?

# Ponto de vista do usuário

Considerando as amostras do exemplo, um total de 76 pixels foram classificados como vegetação, mas apenas 62 são de fato vegetação.

- ▶ Então  $62/70=88\%$  dos pixels classificados como vegetação são realmente vegetação.
- ▶ Isso aponta a acurácia do ponto de vista do usuário.

|           | vegetação        | solo      | urbana    | água      |
|-----------|------------------|-----------|-----------|-----------|
| vegetação | <b>62</b>        | 4         | 2         | 0         |
| solo      | 3                | <b>60</b> | 7         | 0         |
| urbana    | 10               | 20        | <b>40</b> | 1         |
| água      | 1                | 1         | 2         | <b>60</b> |
| total     | 76               | 85        | 51        | 61        |
| <b>AU</b> | <b>62/70=88%</b> |           |           |           |

# Ponto de vista do usuário

- ▶ traduz a “confiabilidade” (acurácia) das previsões do modelo para cada classe.
- ▶ mede o impacto dos “falsos positivos”, (classificações de pixels de outras classes dentro da classe analisada) no resultado final.

Para isto, compara-se a quantidade de pixels corretos em relação a todos os pixels representados como pertencentes à classe, analisando as colunas.

|           | vegetação    | solo         | urbana       | água         |
|-----------|--------------|--------------|--------------|--------------|
| vegetação | <b>62</b>    | 4            | 2            | 0            |
| solo      | 3            | <b>60</b>    | 7            | 0            |
| urbana    | 10           | 20           | <b>40</b>    | 1            |
| água      | 1            | 1            | 2            | <b>60</b>    |
| total     | 76           | 85           | 51           | 61           |
| <b>AU</b> | <b>62/70</b> | <b>60/85</b> | <b>40/51</b> | <b>60/61</b> |

# Índice Kappa

- ▶ A acurácia global é calculada dividindo o total de acertos pelo número de amostras usadas. Porém, ela não considera a aleatoriedade.
- ▶ Considere um resultado completamente aleatório. Obviamente, algumas classificações serão, aleatoriamente, corretas. Logo, o valor da acurácia global não será nulo.
- ▶ Então, o índice Kappa confronta estas duas situações: a diferença entre o seu resultado e um resultado completamente aleatório.


$$Kappa = \frac{Acertos(Reais) - Acertos(aleatórios prováveis)}{Total\ de\ amostras - Acertos\ (Aleatórios\ Prováveis)}$$

Ou

$$Kappa = \frac{Acurácia\ Global - Taxa\ de\ acertos\ aleatórios}{100\% - Taxa\ de\ acertos\ aleatórios}$$

# Kappa

► 
$$Kappa = \frac{Acurácia\ Global - Taxa\ de\ acertos\ aleatórios}{100\% - Taxa\ de\ acertos\ aleatórios}$$



acurácia global = 100. perfeito. Kappa=1:

Caso geral, Acurácia global entre um resultado aleatório e 100%, Kappa entre zero e um

Pior resultado: Acurácia global menor que uma situação aleatório: Kappa < 0

# Tabela de Interpretação do Índice Kappa (Landis & Koch)

| Kappa       | Concordância                   | Significado Prático                                                              |
|-------------|--------------------------------|----------------------------------------------------------------------------------|
| $<0,0$      | Sem concordância (Inaceitável) | O modelo consegue ser pior do que o puro acaso.                                  |
| 0,0-0,2     | Insignificante                 | Praticamente o mesmo desempenho de um resultado aleatório.                       |
| 0,21 - 0,40 | Discreta                       | O resultado é melhor que o resultado aleatório, porém ainda com baixa qualidade. |
| 0,41 - 0,60 | Moderada                       | Resultado aceitável para estudos preliminares ou exploratórios. Ainda ruim.      |
| 0,61 - 0,80 | Substancial                    | Bom resultado! É a faixa padrão considerada confiável para a maioria dos casos.  |
| 0,81 - 1,00 | Quase Perfeita                 | Excelente! Alta confiabilidade e precisão extrema do classificador.              |

# Exercício

---

- ▶ Colete amostras de várias classes e classifique a imagem usando o método da distância mínima Euclidiana.



Ex:  
Água  
Mata Atlântica  
Áreas urbanas  
Areia  
Restinga  
Solo úmido  
Solo seco.... Etc etc

- ▶ Analise a acurácia de sua classificação
-