



# Sensoriamento Remoto II - GA115

## BLOCO 1

Prof. Dr.Ing. Jorge A.S. Centeno

Departamento de Geomática

UFPR - 2020



## Transformações espectrais

Esta aula está dividida em sete módulos:

- Valores digitais
- Operações aritméticas entre bandas
- Um exemplo real
- multiplicação e divisão
- Contraste e índices
- Índices espetrais
- Índices de vegetação



## Transformações espectrais

Na atualidade é difícil falar de ou usar uma imagem que não seja digital. Vivemos em uma era digital onde tudo é transformado a números, bits. No sensoriamento remoto, as imagens resultam da varredura da superfície terrestre usando sensores orbitais. Nestes sistemas, inalcançáveis no dia a dia, a radiação eletromagnética é medida e transformada em números. Por isso, as imagens ganham valores digitais associados à quantidade de radiação eletromagnética incidente no sensor.

Assim, os dados contidos em uma imagem são representados por valores digitais, números. Números podem ser combinados e facilmente manipulados por computadores. Por isso, o sensoriamento remoto sempre esteve associado ao processamento de imagens com computadores.

224	226	224	217	210	197	189	179	170
221	227	228	226	224	207	200	188	175
209	217	221	221	224	214	207	194	181
198	205	212	217	224	217	211	200	186
189	195	202	210	221	217	213	204	190
182	184	189	197	209	215	214	205	193
175	172	175	185	199	209	211	207	199
168	162	164	176	188	202	207	206	201
166	159	159	170	185	195	204	209	208
163	158	158	169	183	192	202	214	214

Computadores permitem analisar números e calcular novos valores. Por exemplo, dada a região mostrada na imagem ao lado, é possível calcular a média da região (198.14), ou sua variância (19.43). Isto é feito, por exemplo, quando no processo de classificação de imagens é necessário calcular a média e a variância de uma área de treinamento. Ou seja, é relativamente fácil, com um pequeno conhecimento de linguagem de programação (por ex: Python), derivar informações combinando os valores dos pixels.

```
## código omitido, você já sabe... declarações e mais declarações
imagem = [ 224.0 226.0 224.0 217.0 210.0 197.0 189.0 179.0 170.0]
soma_dos_pixels           = sum(imagem)
quantidade                 = len(imagem)
media          = soma_dos_pixels / quantidade
print(media)
```



## Operações aritméticas entre bandas

Os dados contidos em várias imagens, obtidas em faixas espectrais diferentes, podem ser combinados matematicamente para salientar características dos alvos. Tipicamente, estas operações envolvem a manipulação de várias bandas. A maneira mais simples de fazer isto é através de operações aritméticas, como adição e subtração.

Considere a seguinte situação: uma imagem no infravermelho médio (A) de um reservatório é obtida em uma data e um mês depois uma segunda imagem contendo a mesma região (B) é obtida. Como a água absorve muito no infravermelho médio, foi possível separar os pixels cobertos por água daqueles cobertos com solo, obtendo-se assim uma imagem binária para cada data onde **0=solo** e **1=água**. Deseja-se estimar se houve redução ou aumento do espelho de água, o que se traduz em armazenamento deste recurso para a agricultura. Na tabela a seguir são mostrados os recortes de esta imagem.

A	B
1 1 1 1 1 1 1 1 1 1	0 0 0 0 0 0 0 0 0 0
1 1 0 0 0 1 1 1 1	0 0 1 1 1 1 1 0 0
1 1 0 0 0 1 1 1 1 1	0 0 1 1 1 1 0 0 0 0
1 1 0 0 0 0 0 1 1 1	0 0 1 1 1 1 0 0 0 0
1 1 0 0 0 0 0 1 1 1	0 0 0 0 1 0 0 0 0 0
1 1 0 0 0 0 1 1 1 1	0 0 0 0 0 1 0 0 0 0
1 1 1 1 1 0 1 1 1 1	0 0 0 0 0 1 0 0 0 0
1 1 1 1 1 1 0 1 1 1	0 0 0 0 0 0 1 0 0 0

Considerando as imagens binárias, a diferença entre as duas (pixel a pixel) pode ser calculada:

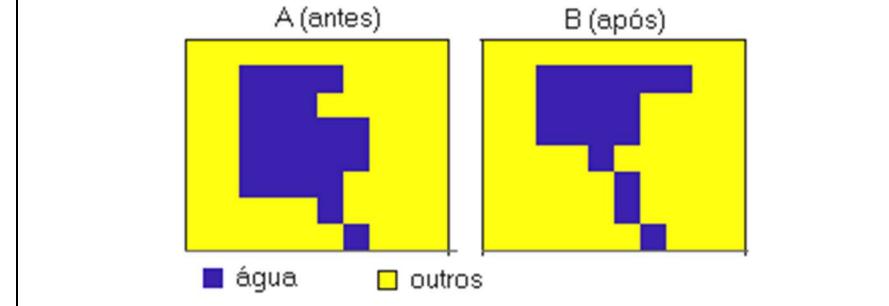
$$C = A - B$$

Do que resultam as seguintes possibilidades:

- **0:** sem mudanças. Ocorre quando  $A=B$ , seja zero nas duas datas ou um nas duas datas.
- **1:** é obtido quando ocorre água na primeira data e "outros" na segunda. Isto significa que houve perda de água.
- **-1:** quando não ocorre água na primeira data e sim na segunda. Isto significa que houve aumento de água.

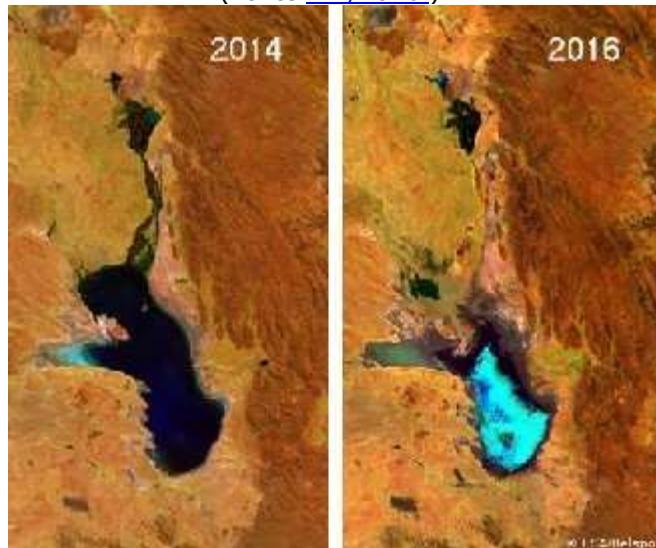
**Problema** tratando-se de uma imagem digital, não é possível representar valores negativos. Alguma sugestão? Primeiro pense, discuta com seu colega.

Uma imagem mostrando água (em azul) de um reservatório em uma data (A) e outra similar derivada de uma imagem captada um mês depois (B).



### **Exemplo**

Redução da superfície do Lago Poopó entre 2014 e 2016  
(Fonte [DW/2016](#) ).



Observe as imagens ao lado. Elas foram obtidas da reportagem da Deutsche Welle (DW), de 10.02.2016. Nesta referência [você](#) pode encontrar a reportagem inteira em inglês.

Em uma parte do texto consta que:

*"O lago Poopó já foi o lar de inúmeras espécies animais, além de fornecer sustento para a população local. Hoje, o lago está praticamente desaparecido - imagens de satélite confirmaram isso recentemente. Tudo o que resta são três áreas pantanosas, nas antigas profundezas do lago. (Tradução livre).*

Sendo estas imagens obtidas pelo sistema Landsat 8, proponha uma maneira de quantificar a redução do espelho de água do lago.

- Qual(is) banda(s) do sistema americano LANDSAT 8, OLI seriam mais adequadas para esta finalidade?
- Como separar apenas os pixels de água?
- Discuta a questão da acurácia a estimativa.



## Multiplicação e divisão é possível, mas para que serviria?

Da mesma forma que se pode calcular a soma ou diferença pixel a pixel entre imagens torna-se possível também efetuar outras operações aritméticas como a multiplicação ou divisão, mas ... para que? O que pode ser obtido de interessante?

**OBS:** Uma das operações mais usadas é a divisão pixel a pixel. Bem, tome cuidado quando programar uma divisão, pois os dados de imagens estão armazenados como **unsigned int** de oito bits (**uint8**) e este formato não permite armazenar frações. Por isso, antes de nada deve transformar os valores a valores reais, tipo **float** ou **double**. Também considere que o produto de duas imagens pode variar de zero a +infinito e ainda pode ocorrer a divisão por zero, pois zero é um valor possível na imagem.**BANDAX=BANDA1/BANDA2**

A divisão de duas bandas de uma imagem pode ser útil para salientar as diferenças entre as bandas. Por exemplo, se se divide a banda do infravermelho próximo pela banda do vermelho pode se obter as seguintes situações:

- vermelho > infravermelho ... 0-1
- vermelho = infravermelho ... 1
- vermelho < infravermelho ... maior que 1

Para poder armazenar estes valores em uma imagem de oito bits seria necessário mudar a escala do resultado, o que

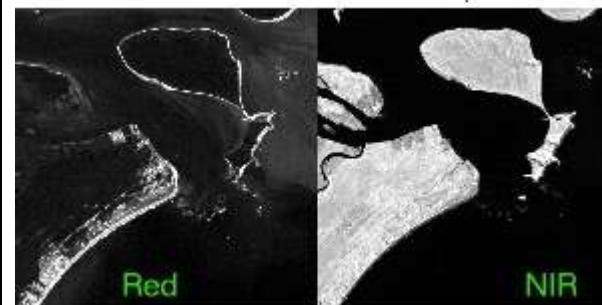
significa somar uma constante e multiplicar o resultado por outra constante, para depois adotar o valor inteiro. O melhor mesmo, seria mudar o formato usado e armazenar o resultado como **double**.

### Exercício

- Carregue a imagem da Ilha do Mel ([mel600.lan](#)). Ao lado você está vendo as duas imagens do vermelho e do infravermelho próximo (NIR). Como espera que seja o resultado de dividir NIR/RED para os pixels de vegetação? e para os de água? e os de areia?

### Tutorial - No Multispec:

- Usando a imagem Landsat da Ilha do Mel/PR ([mel600.lan](#)) você pode aprender como fazer operações aritméticas entre bandas no software Multispec.



Para efetuar a divisão das bandas siga o roteiro do professor.



## Contraste e índices

Para comparar duas imagens, podemos calcular a diferença. Se forem iguais, então o resultado da diferença é zero. O problema com a simples diferença é que pode levar a algumas incoerências na realidade, mas matematicamente corretas. Suponha que tem duas séries de números A e B.

$$A = [1 \ 100 \ 1 \ 2 \ 3 \ 2 \ 2 \ 100 \ 110 \ 100]$$

$$B = [2 \ 105 \ 1 \ 2 \ 3 \ 3 \ 3 \ 105 \ 111 \ 200].$$

Se calculamos a diferença  $C = B - A$ , teremos

$$C = [1 \ 5 \ 0 \ 0 \ 0 \ 1 \ 1 \ 5 \ 1 \ 100].$$

O primeiro e o penúltimo valor sofreram uma alteração de "1". Se calcularmos a percentagem que isto significa para cada um deles, em relação a A:

$$P = (B - A) / A$$

teremos um aumento de 100% para o primeiro elemento e de apenas 1.7% para o penúltimo. Ou seja, a variação de uma unidade é significativa para o primeiro elemento, mas

insignificante para o penúltimo. Ah! Um aumento de 100% é também observado no último elemento.

Claro que esta comparação é relativa. Por que então não usar como referência B? e fazer...

$$C = (B - A) / B?$$

Isto produz resultados diferentes.

Para contornar este problema usa-se o conceito de contraste. O contraste mede a razão entre a diferença e a grandeza das variáveis envolvidas.

$$P = (B - A) / (B + A)$$

Aplicado este conceito às variáveis A e B teremos:

$$P = (B - A) / (B + A) = [0.333 \ 0.024 \ 0 \ 0 \ 0.200 \ 0.200 \ 0.024 \ 0.005 \ 0.333]$$

uma maneira de comparar as bandas de forma relativa. Este conceito é usado para comparar bandas de faixas diferentes do espectro e produzir alguns índices espectrais.



A razão entre bandas, bem como o contraste, servem para evidenciar pequenas variações espectrais da cobertura do terreno que de outra maneira encontram-se mascaradas pela pequena variação dos valores digitais. Assim sendo, aplicando operações aritméticas entre bandas torna-se possível salientar alguns detalhes ou informações na imagem. Isto levou a comunidade científica a propor algumas operações para derivar novas bandas artificiais que contenham alguma informação específica mais visível, os chamados "índices espectrais". Para salientar alguma informação contrastando duas bandas é comum usar operações aritméticas como:

**Divisão:**  $IV = \text{Banda1}/\text{Banda2}$

**Contraste:**  $IV = (\text{Banda1}-\text{Banda2})/(\text{Banda1}+\text{Banda2})$

Veja aqui alguns índices muito usados para salientar:

**Água:** O índice espectral NDWI (Normalized Difference Water Index) se baseia em dois fatos:

- A água absorve muita radiação eletromagnética no infravermelho, IV-próximo (IVP) e médio (IVM).
- A maior reflectância da água se verifica no visível, na região do verde (GREEN) (isto, claro, depende do teor de sedimentos, mas isso é outra aula).

## Índices espectrais

$$DNWI = (\text{GREEN}-\text{IVP})/(\text{GREEN}+\text{IVP})$$

O valor de NDWI pode variar de -1 para 1, sendo zero um limiar adequado para separar água de outros objetos. Observe que, comparando estas duas bandas, o alvo caracterizado por GREEN-IVP positivo a água. Tanto para vegetação, como para solos, GREEN é menor que IVP. Quer ver uma aplicação deste índice? consulte o trabalho de Brenner e Guaselli .

### Outros índices

Uma lista abrangente (em inglês) pode ser encontrada em Index DataBase. Aqui listamos alguns interessantes:

$NDSI = (\text{GREEN}-\text{IVM})/(\text{GREEN} + \text{IVM})$  : índice para identificar neve, Normalized Difference Snow Index (NDSI)

$NDWI = (\text{IVP}-\text{IVM})/(\text{IVP}+\text{IVM})$  : índice de umidade na folha - Normalized Difference Moisture Index (NDMI)

$NBRI = \text{IVM1}-\text{IVM2})/(\text{IVM1}+\text{IVM2})$  : índice de queimadas - Normalized Burned Ratio Index (NBRI), proposto para avaliar a severidade do fogo em áreas florestais. Neste caso, usa-se o contraste entre duas bandas do infravermelho médio. No caso do Landsat OLI, IVM=Banda 5 e IVM2= Banda 7.

Agora, só para desestressar... usando esta imagem aplique um índice para delimitar o corpo de água.

Ah! e se quiser, pode fazer o mesmo para detectar neve.



## Índices de vegetação

O índice espectral mais conhecido e usado é o índice de vegetação. Com este índice pretende-se enfatizar a vegetação na imagem e, se possível, mostrar seu estado, para responder a questões como: Quando de vegetação tem na imagem? Esta vegetação está sadia? Está seca? Sofre ação de pragas? Com base em dois fatos: a) A vegetação sadia apresenta alta absorção no visível, tendo um pico no vermelho (RED) e b) alta reflexão no infravermelho próximo (IVP), veja a Figura ao lado, pode-se concluir que a diferença entre o IVP e o VIS é alta para a vegetação sadia. Quando a vegetação sofre algum estresse, a produção de clorofila diminui, com o que a reflexão no visível aumenta, tornando a diferença menor. Então, pode-se propor um índice para monitorar vegetação como sendo:

$$IV = RED/IVP$$

Aplicando-se o conceito de contraste a estas duas bandas obtém-se **Índice de vegetação por diferença Normalizada** ou *Normalized Difference Vegetation Index - NDVI*, que varia entre -1 to +1. Valores altos do NDVI

correspondem a vegetação sadia e densa enquanto valores pequenos mostram vegetação seca, sob estresse, ou pouco densa.

$$IV = (IVP-RED)/(IVP+RED)$$

Bem, agora, usando a imagem da Ilha do Mel [no Multispec](#), gere imagens destes dois índices de vegetação e responda às seguintes questões:

- É possível diferenciar vegetação de outros alvos?
- Como aparece a vegetação mais densa ou sadia em relação àquela mais seca/rala?
- Por que a água aparece tão escura?

existem outros índices similares, como:

O SAVI, *soil adjusted vegetation index*, que usa uma constante para minimizar o efeito do brilho do solo.

$$SAVI = (IVP-RED)/(IVP+RED + C) (1+C)$$

O EVI, enhanced vegetation index, que inclui as duas faixas de absorção da clorofila na região do visível (RED e BLUE). C1, C2 são coeficientes para cada banda, X um fator de ajuste associado ao fundo and G um ganho ou fator de escala.

$$EVI = G (IVP-RED)/(IVP+C1*RED + C2*BLUE+X)$$

---

### Para saber mais...

Kogan, F.N., 1995: Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data. *Bulletin of the American Meteorology Society*, 76(5):655-668. [DOI: 10.1175/1520-0477\(1995\)076<0655:DOTLIT>2.0.CO;2](https://doi.org/10.1175/1520-0477(1995)076<0655:DOTLIT>2.0.CO;2).

Tarpley, J.D., S.R. Schneider and R.L. Money, 1984: Global vegetation indices from the NOAA-7 meteorological satellite. *Journal of Climate and Applied Meteorology*, 23:491-494. [DOI: 10.1175/1520-0450\(1984\)023<0491:GVIFTN>2.0.CO;2](https://doi.org/10.1175/1520-0450(1984)023<0491:GVIFTN>2.0.CO;2).



# Transformação das Componentes Principais

Esta aula está dividida em seis módulos:

- Revisão de matemática
- Revisão de matemática 2
- Auto- valores e vetores
- Componentes Principais
- Cálculo no Multispec
- Significado das componentes



A figura mostra um recorte da banda do verde de uma imagem Landsat, onde foram selecionadas duas regiões (A em vermelho e B em amarelo). Comparando as tonalidades destas regiões, o que poderia concluir? Bem provavelmente diríamos que a região B é mais escura que a região A. Esta afirmação pode ser corroborada comparando a média dos valores digitais das duas regiões. Na tabela são mostradas as médias e é evidente que a média de B é menor que a de A. Traduzindo isto a níveis de cinza dirímos que B é mais escura que A.

Uma segunda observação seria possível a respeito da variação dos valores em cada região. Mas, como medir a uniformidade? O conceito de uniformidade nos remete ao conceito de dispersão dos valores. Se os valores forem muito parecidos entre si, então dirímos que a região é uniforme. Se os valores são muito dispersos, então a região é menos uniforme. O conceito de dispersão está presente no desvio padrão. O desvio padrão mede a dispersão dos valores em torno da média. A média é calculada como:

Estatísticas das duas áreas		
	Área A	Área B
Média	58.8	33.8
d.p.	11.3	0.8

## Revisão de matemática:

$$\text{média} = \frac{\sum_{i=1}^n x_i}{n}$$

A diferença entre um valor qualquer e a média nos daria o afastamento do valor em relação a esta referência.

$$dif_{média} = \frac{\sum_{i=1}^n (x_i - \text{média})}{n}$$

Porém, se existem diferenças positivas, valores acima da média, e negativas, valores abaixo da média, esta medida pode ser zerada mesmo em situações onde a dispersão é alta, dando assim informação errada. Então, para contornar este problema adota-se o quadrado da diferença. Isto equivale a calcular a distância média em valor absoluto. Bem, como a função quadrado é monotônica crescente, usar a distância ou o quadrado da distância não vai mudar a situação para fins de comparação, então, podemos usar o quadrado, do que se deriva a medida da variância.

$$\text{Variância} = \frac{\sum_{i=1}^n (x_i - \text{média})^2}{n}$$

O desvio padrão não é mais do que a raiz da variância. Descreve o mesmo, mas a diferença é que ele está nas mesmas unidades que a variável.

$$d.p. = \sqrt[2]{\text{Variância}}$$

Analizando as estatísticas dos dois recortes (A e B), é constatado que o desvio padrão de A é maior que o de B, logo pode-se dizer, mesmo sem olhar à imagem, que A tem maior variação de valores, dispersão, do que B, que é mais uniforme.

Para terminar, abra a imagem Landsat da Ilha do Mel/PR ([mel600.lan](#)) e selecione uma área contendo várias classes de cobertura, pode ser grande. Para isto, use a opção de seleção de amostras de treinamento que usamos nas aulas de sensoriamento remoto 1.



### No Multispec

**processor + statistics + OK.** Isto habilita a janela de projeto.

Confirme a ação na janela seguinte. Não se preocupe em dar nome à classe.

Agora, na janela de projeto selecione **Classes**. Isto mostrará que você tem uma classe "Class 1", apenas.

Na mesma janela, clique no campo onde consta **List Classes Stats** para listar as estatísticas desta classe. Para isto, escolha **List Stats...**, a última opção.

Na nova janela, que aparece após **list Stats...**, verifique se a opção **Mean & standard deviation** (Média e desvio padrão) está selecionada. A seguir, confirme com **OK**. O programa perguntará se pode atualizar o projeto. Claro que sim! Se não, como poderíamos calcular as estatísticas?

Agora você pode encontrar as estatísticas da imagem na janela de texto **text Output**.

**Pergunta:** Qual banda é a mais clara? e a mais escura? Qual banda é mais uniforme? e a menos uniforme?





Os conceitos de média e variância podem ser estendidos a mais de uma variável. No caso de uma imagem de satélite, cada pixel contém informações de diferentes regiões do espectro eletromagnético, armazenada como valores digitais. Assim sendo, cada pixel pode ser descrito com um vetor:

$x = [ \text{blue}, \text{green}, \text{red}, \text{IVP}, \text{IVM} ]$ , por exemplo.

A variância descreve a dispersão dos valores em torno da média em cada banda. A **covariância**, por outro lado representa a dependência entre as bandas. Como mostrado na equação:

$$\text{Covariância}(x, y) = \frac{\sum_{i=1}^n (x_i - \text{média}_x)(y_i - \text{média}_y)}{n}$$

Veja que nesta equação temos dois elementos:  $(x - \text{média}_x)$ , ou seja a diferença entre o valor e a média em uma banda e  $(y - \text{média}_y)$ , que é a diferença entre o valor na banda "y" e a média na banda "y". Estes dois elementos são multiplicados.

O que diria se valores acima da média em "y" são sempre encontrados quando ocorrem valores acima da média em "x"? E se ainda valores abaixo da média em "y" são encontrados quando ocorrem valores abaixo da média em "x"? Isso pode ser algo parecido à situação mostrada em (a) na figura ao lado. Neste caso, o resultado da multiplicação será sempre positivo, fazendo com que a covariância seja um valor alto, positivo.

## Estatística multivariada

multiplicação	$(y - \text{média}_y)$ positivo	$(y - \text{média}_y)$ negativo
$(x - \text{média}_x)$ positivo	positivo	negativo
$(x - \text{média}_x)$ negativo	negativo	positivo

Por outro lado, se valores **abaixo** da média em "y" ocorrem quando ocorrem valores **acima** da média em "x"? E valores **acima** da média em "y" são encontrados quando ocorrem valores **abaixo** da média em "x" (caso (b))? Neste caso, o resultado da multiplicação será sempre negativo e a covariância alta, mas negativa. Em ambos casos, pode-se dizer que existe dependência linear entre as variáveis "x" e "y", pois a dispersão tende a se alinhar.

Mas um valor alto de "x" pode estar associado a valores altos ou baixos de "y", sem nenhuma tendência (caso (c))? Neste caso, a somatória incluiria valores positivos e negativos, que iriam se compensar e o resultado seria um valor baixo, próximo de zero para a covariância.

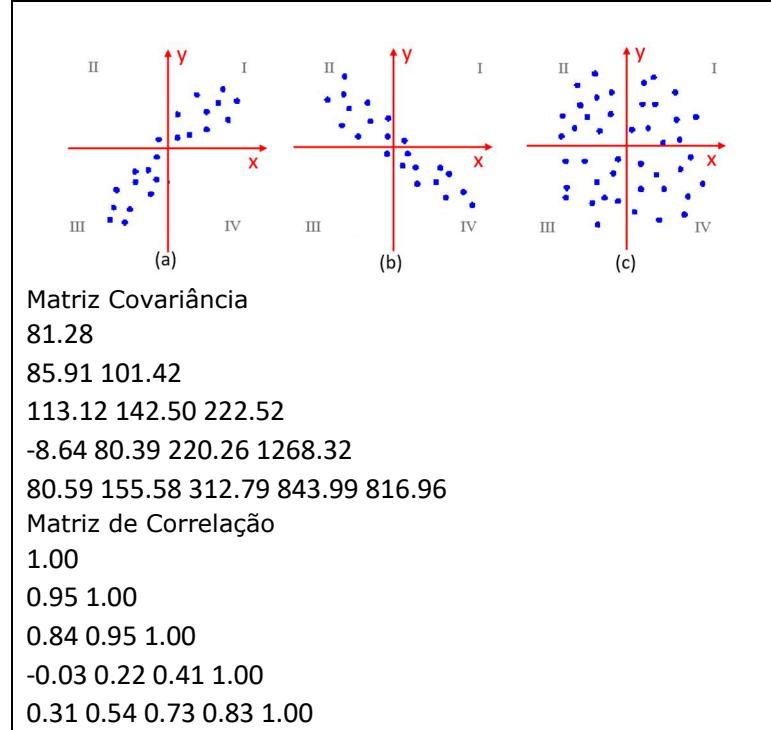
Finalmente, a correlação entre duas bandas "x" e "y" pode ser calculada como:

$$\text{correlação}(x, y) = \frac{\text{covariância}(x, y)}{dp(x) * dp(y)}$$

Esta variável está diretamente associada à covariância. Se a covariância for positiva, então a correlação será também positiva, porque o valor do desvio padrão, raiz da variância, é sempre positivo. A correlação varia entre -1 e +1.



No quadro ao lado são mostradas as matrizes de variância-covariância e correlação das bandas do azul, verde, vermelho, infravermelho próximo e infravermelho médio de uma região no Paraná. Pode dizer quais bandas são mais parecidas? e quais são mais diferentes (não tem correlação?). Pode-se dizer que, se a correlação for alta, as bandas são redundantes, ou seja, a informação de uma está contida na outra? E por que a diagonal da matriz de correlação contém apenas 1.00?





Dada uma matriz quadrada, definida positiva, como a matriz de variância- covariância de uma imagem de satélite, os escalares  $L$  que satisfazem a equação abaixo são chamados de **Autovalores associados à matriz**. Os autovalores de uma matriz são as raízes de seu polinômio característico:

$$\det(A - L * I) = 0$$

O cálculo de  $\det(M - I^*L) = 0$  ... gera um polinômio cujo grau é igual à dimensão da matriz. Em nosso caso, por exemplo, o número de bandas.

### Autovetores

definição: Seja uma matriz  $A$  quadrada, positiva e definida e  $L$  seus autovalores. Se existe um vetor  $x$  não nulo que satisfaz a relação a seguir, este vetor é chamado de autovetor associado ao autovalor  $L$ . Ou seja,  $x$  é chamado de autovetor (vetor característico) da matriz associado ao autovalor  $L$ .

$$A * x = L * x$$

Considerando o exemplo ao lado, uma das raízes do polinômio é  $L=5.6$ . Substituindo este valor na equação dos autovetores temos:

$$\begin{vmatrix} 510.17 & 559.43 & -335.00 \\ 559.43 & 647.26 & 78.40 \\ -335.00 & 78.40 & 9701.23 \end{vmatrix} \begin{vmatrix} |x_1| \\ |x_2| \\ |x_3| \end{vmatrix} = 5.6 \begin{vmatrix} x_1 \\ x_2 \\ x_3 \end{vmatrix}$$

ou três equações:

## Autovalores

- $\begin{vmatrix} (510.17-5.6) & 559.43 & -335.00 \\ 559.43 & (647.26-5.6) & 78.40 \\ -335.00 & 78.40 & (9701.23-5.6) \end{vmatrix} \begin{vmatrix} |x_1| \\ |x_2| \\ |x_3| \end{vmatrix} = 0$

ou

- $\begin{vmatrix} 504.6 & 559.4 & -335.0 \\ 559.4 & 641.66 & 78.4 \\ -0.335 & 78.4 & 9695.6 \end{vmatrix} \begin{vmatrix} |x_1| \\ |x_2| \\ |x_3| \end{vmatrix} = 0$

do que resulta o vetor  $x = \{-0.7515 \ 0.6590 \ -0.0313\}'$ .

De forma análoga dois outros vetores são calculados para os outros autovalores, resultando um novo sistema de 3 autovalores, como mostrado ao lado.

**Tarefa:** Verifique se estes três vetores são ortogonais.

```
Matriz covariância
510.17 559.43 -335.00
559.43 647.26 78.40
-335.00 78.40 9701.23
M- I*L =
| (510.17-L) 559.43 -335.00 |
det| 559.43 (647.26-L) 78.40 |=0
| -335.00 78.40 (9701.23-L) |
Autovalores: L1= 9713.8; L2=1139.2 3 L3=5.62
Os autovetores são as colunas da seguinte matriz:
-0.7515 0.6588 -0.0360
0.6590 0.7521 0.0064
-0.0313 0.0189 0.9993
```



Veja a figura abaixo. Na primeira figura mostra-se um conjunto de pontos altamente correlacionados no sistema ( $B_1, B_2$ ). Eles poderiam ser, por exemplo, as leituras do valor digital em duas bandas de uma imagem de satélite. Por serem altamente correlacionadas, estas bandas serão muito parecidas e o conjunto altamente redundante. Podemos dizer, com baixa margem de erro, que a informação contida em uma imagem pode ser usada para calcular a segunda. Então, para que armazenar duas imagens? Não bastaria uma? Porém, mesmo havendo correlação entre  $B_1$  e  $B_2$ , ao escolhermos apenas uma delas perderíamos parte de informação, pois as imagens não são idênticas.

E se efetuássemos uma rotação, como mostrado na segunda figura, o eixo  $C_1$ , ao passar pela direção de maior espalhamento dos pontos, não resumiria o conteúdo das duas imagens? Este novo sistema ( $C_1, C_2$ ) é ainda ortogonal, é uma rotação do sistema ( $B_1, B_2$ ), mas tem a característica de que nele os dados não são correlacionados. Em se tratando de duas variáveis, a rotação é simples, mas quando se lida com, por exemplo, 5 bandas? como obter a rotação?

#### Transformação das componentes principais:

Do ponto de vista estatístico, o objetivo da transformação das componentes principais consiste em representar um conjunto de dados usando um novo conjunto de variáveis, combinações lineares das originais. Este novo sistema deve

## Transformação IHS

ter como propriedade um baixo grau de correlação entre as novas variáveis.

A transformação das componentes principais consiste basicamente numa rotação dos dados no espaço das bandas e os coeficientes da rotação podem ser obtidos com ajuda dos **autovetores**. Ou seja, as componentes do novo sistema resultam da projeção do sistema original na direção dos autovetores da matriz de covariância. Considerando 3 bandas:

$$C = M * B$$

Considerando as 3 bandas do visível da imagem da Ilha do Mel (ao lado), isto equivale a:

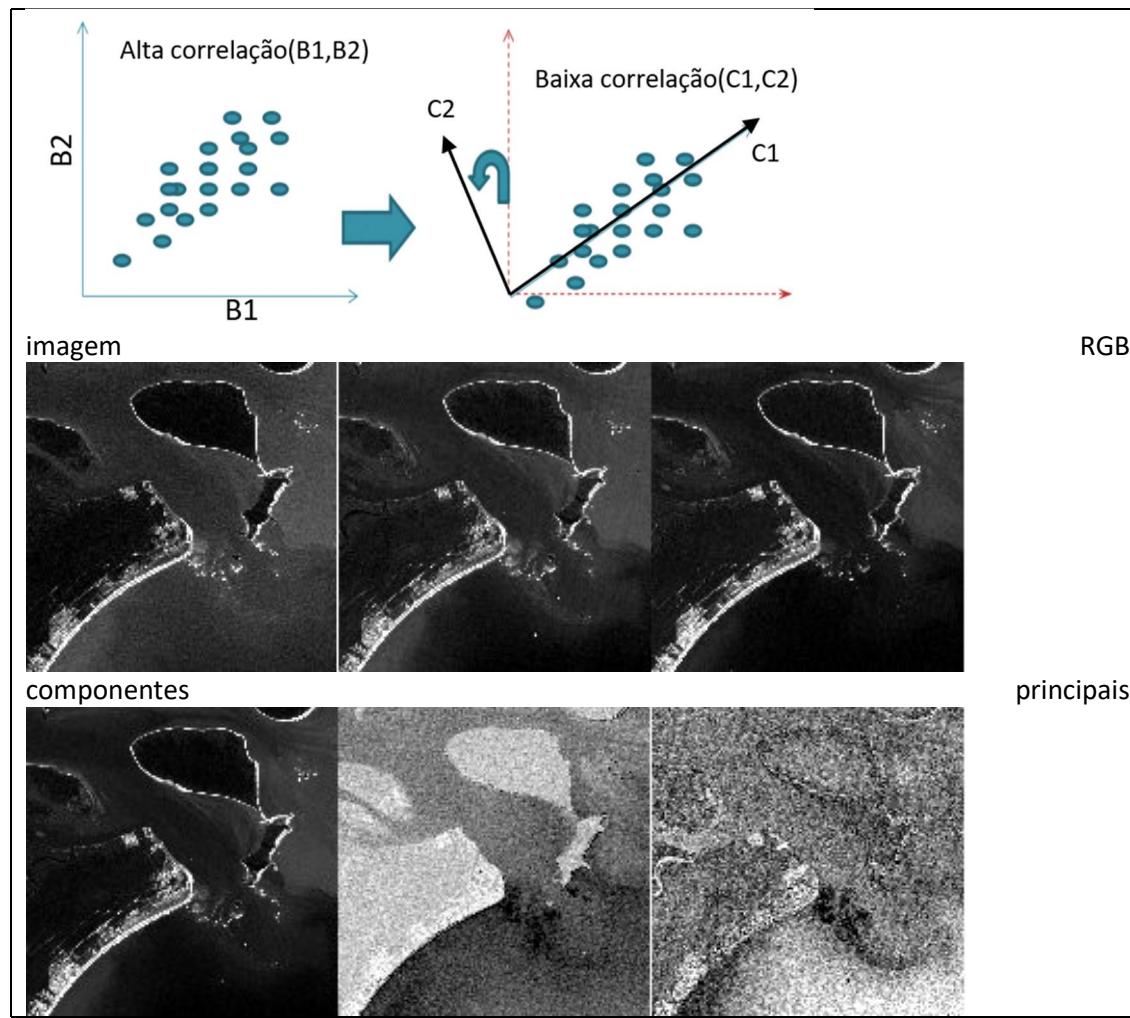
$$\begin{vmatrix} C_1 \\ C_2 \\ C_3 \end{vmatrix} = \begin{vmatrix} v_{11} & v_{12} & v_{13} \\ v_{21} & v_{22} & v_{23} \\ v_{31} & v_{32} & v_{33} \end{vmatrix} \begin{vmatrix} B_1 \\ B_2 \\ B_3 \end{vmatrix}$$

Veja, a seguir, a matriz de correlação da imagem RGB e da imagem das componentes principais. valeu a pena?

Channel	1	2	3	Channel	1	2	3
1	1.00			1	1.00		
2	0.91	1.00		2	0.00	1.00	
3	0.83	0.95	1.00	3	0.00	-0.00	1.00

Agora veja o resultado, na figura ao lado. Percebe que a primeira componente parece uma imagem preto e branco? Ela tem muita informação das três bandas originais. Já a terceira parece ruidosa, pois o conteúdo de informação desta nova componente é baixo. O teor de informação de cada componente é proporcional ao tamanho relativo do autovetor associado.

$$Inf(i) = L_i / (L_1 + L_2 + L_3)$$





Aqui, no futuro, teremos um vídeo mostrando os passos, mas por enquanto, apresentamos o roteiro:

- Carregue a imagem no Multispec.
- Para começar, vamos calcular os autovalores e autovetores para efetuar a transformação. Para isto, use **Processor + Utilities + Principal Component Analysis**.

Isto abrirá uma nova janela de diálogo. Nela selecione **save eigenvalues , Disk File** (para salvar as informações no disco) e **OK**. O Multispec pedirá que escolha o nome do arquivo, vamos chamar ele de "imagePC.pca". Este arquivo não é uma imagem. Ele contém as informações dos autovalores e autovetores. Se você quiser, e for suficientemente curioso, pode dar uma olhada no arquivo com o Bloco de Notas. O arquivo está em ASCII. Um resumo é também apresentado na janela "text Output".

- Agora vamos gerar as componentes com esses dados. Para isto use:
  - **Processor + Reformat + Change Image File Format.**
  - Na janela que será mostrada clique em **Transform data...**
  - Uma nova janela oferece a opção **New Channel from PC Eigenvectors**. Escolha essa opção. Isto mudará a janela. Aqui você pode selecionar as bandas que vai usar. Por enquanto vamos usar todas (All). **OK**.
  - voltará à janela anterior. Confirme de novo com **OK**. E selecione a pasta onde salvará o resultado e o nome da imagem de saída. vamos chamar a imagem de "**imagePC.lan**".

## Prática das CP

- Agora basta abrir esta nova imagem e ver as componentes. Sugerimos usara opção "side by side channels" no display.

### Tarefa

Então. Agora:

- Calcule a matriz variância-covariância e correlação da imagem original.
  - Responda: Existem bandas correlacionadas? quais? como justifica a alta correlação?
  - Responda: Quais bandas são menos correlacionadas? por que isso ocorre?
- Calcule a matriz de correlação da imagem das componentes principais.
  - Compare os valores da correlação com os anteriormente obtidos para a imagem original.
- Veja os autovalores na janela de texto. Veja que nela também se informa qual é a importância de cada componente. Qual a quantidade da variação original explicada por cada componente.

Com quantas componentes principais é possível explicar 95% e 99% da informação original?

Visualize as três primeiras componentes como composição colorida. O que acha?

Component	Eigenvalue	Percent	Cum(%)
1	1586.7070	80.7995	80.7995
2	309.8964	15.7808	96.5803
3	56.0933	2.8564	99.4367
4	4.9300	0.2511	99.6877
5	2.5552	0.1301	99.8179
6	2.0168	0.1027	99.9206
7	1.5601	0.0794	100.000

# Significado das Componentes

Visualize as três primeiras componentes como composição colorida, depois como banda isolada. O que acha? Poderia dizer o que é salientado em cada imagem? Podemos fazer isto visualmente ou analisando os coeficientes das componentes principais, os coeficientes dos autovetores.

Os coeficientes da primeira componente (em vermelho) são quase todos positivos. Apenas as bandas 1 e 6 tem coeficientes negativos, mas estes são muito pequenos em relação aos outros. então, poderiam ser desprezados. Isso vale para a banda 2. Fica então uma soma ponderada das bandas do vermelho e infravermelho. Isto, poderíamos dizer, é uma imagem pancromática cobrindo a faixa do vermelho ao infravermelho médio.

$$CP1 = 0.121 * Red + 0.819 * IVP + 0.494 * IVM1 + 0.259 * IVM2$$

Repetimos isto para os coeficientes da segunda componente (em verde). Aqui apenas a banda 6 (do termal) pode ser desprezada. Chama a atenção que existem dois grupos de coeficientes, um positivo, para o infravermelho próximo (Banda 4) e o resto negativos. Ou seja, esta componente mostra o contraste entre o infravermelho e o visível, e o infravermelho médio. Já vimos algo assim antes ao analisar índices de vegetação. A vegetação é o

único alvo que tem alta refletância no IVP e baixa no visível, por causa da absorção dos pigmentos, e no IVM, pela umidade. Então, esta banda deve refletir o estado da vegetação. Confere na imagem?

Na terceira, novamente a banda 6 tem coeficiente desprezível. Os outros coeficientes mostram o contraste entre o visível+IVP (positivos) e o IVM (negativos). Lembre-se que os solos têm uma curva crescente no visível e IVP, mas são afetados pela umidade no IVM. Então, esta componente nos ajuda discriminar solos. Vale a pena fazer uma observação: A componente nos dá a direção de maior variação, mas não o sentido. então, os sinais dos coeficientes poderiam estar invertidos. Na imagem se nota que os solos, a área urbana e areia aparecem bastante escuros. As regiões onde as ondas se arrebentam aparecem bastante claras;

As imagens das outras componentes, são muito ruidosas. Se consultarmos a quantidade de informação que elas contêm, veremos que contribuem com muito pouco, e por isso apresentam valores de certa forma aleatório. A pior situação é encontrada na última componente.

Comp.	1	2	3	4	5	6	Channels
1	-0.00201	0.05387	0.12115	0.81908	0.49417	-0.01929	0.25876
2	-0.35594	-0.38859	-0.53162	0.41465	-0.30480	-0.08384	-0.40966
3	0.31561	0.40318	0.40883	0.34745	-0.47664	-0.06611	-0.46736
4	-0.73834	-0.14383	0.63701	-0.05042	0.01069	0.09721	-0.12759
5	-0.01079	0.25884	-0.16302	-0.11916	0.56276	0.39845	-0.64548
6	0.46948	-0.76108	0.32124	-0.02411	0.17755	-0.02976	-0.25330
7	0.08953	-0.12893	-0.00288	0.13834	-0.29558	0.90506	0.22298



### Como descrever cor:

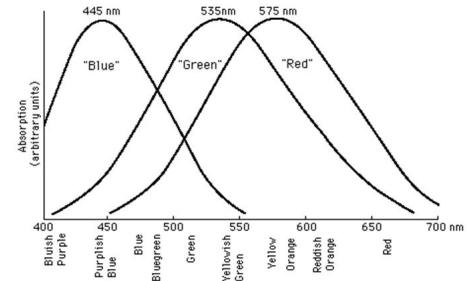
Veja a figura ao lado. A aluna de sensoriamento remoto deseja comprar uma camisa, mas não gostou da cor, então ela especificou a cor conforme aprendeu nas aulas, em RGB, mas a vendedora não entendeu. Descrever cor é uma tarefa difícil. Como você descreveria a camisa? azul? azul claro? celeste? Veja suas roupas, as cores não são cores "puras", então, para descrever as cores de suas roupas você usaria termos como "claro", "desbotado", "brilhante"? ou ainda usando analogias, como "abacate", "verde oliva", "chocolate"? Sim, descrever cor é difícil.

A percepção de **cor** é resultado da sensação que a radiação eletromagnética causa no olho. A luz, após passar pelo cristalino, incide no fundo do olho, onde elementos fotossensíveis, os cones e bastonetes, percebem a intensidade de energia incidente e passam esta sensação através do nervo óptico ao cérebro. Existem aproximadamente 6 milhões em cada olho humano concentrados na região fóvea. Os Cones são as células do olho humano capazes de reconhecer as cores, OU, pode ser dizer que eles se encarregam de diferenciar o comprimento de onda predominante(s) na luz. Diferenciar se é "amarelo",



## Transformação IHS

"azul" etc. Já os bastonetes percebem a luminosidade, ou seja, o total de energia incidente, para avaliar se a cena é clara ou escura. Os animais noturnos não necessitam perceber a cor, então usam mais os bastonetes. Já o ser humano, como outros mamíferos, desenvolve atividades de dia, aproveitando a luz solar, e por isso necessita usar ao máximo os cones. Esta explicação é, claro, simplificada para esta aula. Os interessados devem procurar um bom livro de biologia.



A percepção de **cor** se baseia no princípio do **tristímulus**, ou seja, o uso de três componentes de cor básicas que são combinadas pela soma aditiva de cores. Na figura acima são mostradas as faixas de sensibilidade de cada uma destas componentes. Note que a distribuição das curvas não é uniforme. O azul encontra-se bem separado do verde e vermelho. Claro que estas curvas variam um pouco de ser humano para outro. Mas...

Pergunta O que ocorreria se a curva do verde e do vermelho se aproximassem muito?

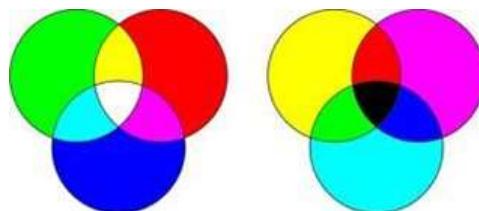


## Sistema R G B:

Na escolinha nos ensinaram que a combinação de todas as cores daria o preto. Porém, alguns de nós fizeram o experimento e não resultou em preto. Alguma explicação? Na verdade, as cores que nos deram não eram as cores básicas puras, então não tinha como dar certo. Uns anos depois nos disseram que *a soma de todas as cores dá o branco*. Mas como? Não era o preto?



Bem, as duas afirmações estão certas, mas se referem a dois fatos diferentes. A combinação de pigmentos segue o princípio da combinação **subtrativa** de cores. Já a **combinação aditiva** é aplicada à combinação de luz colorida.



Cores Aditivas

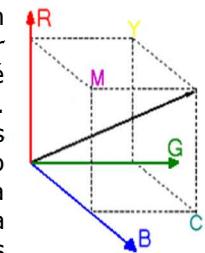
Cores Subtrativas

**combinação subtrativa:** se aplica à combinação de pigmentos. As cores básicas são o ciano, amarelo e o magenta. A soma destas três cores daria o preto. Este sistema é encontrado nos pigmentos usados nas impressoras. Os cartuchos contêm essas cores. Note que, quando criança você não usava ciano nem magenta, por isso não conseguia o preto... :(

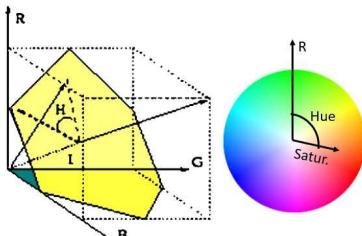


**combinação aditiva:** Isso não vale quando se combina luz, como ocorre no monitor do computador. Neste caso, valem as regras da combinação aditiva, onde a soma de todas as cores produz o branco e as cores básicas são vermelho, verde e azul. Ao longo deste curso usamos apenas este tipo de combinação, pois trabalhamos no monitor do computador.

Assim sendo, as três cores básicas (R G B) definem um espaço tridimensional onde todas as cores que podem ser mostradas na tela estão incluídas. Na figura ao lado é mostrado este espaço, que forma um cubo, o cubo RGB. Na origem (0,0,0) se localiza o preto. No canto mais afastado da origem (255, 255, 255) branco, contendo o máximo de luz de todas as cores básicas. Ao longo da linha que liga estes pontos, todas as cores têm a mesma proporção de R, G e B, logo esta é a linha de cinzas. Nos extremos dos eixos se encontram as cores pura, R,G e B. Nos outros vértices podemos achar amarelo (Y= combinação de E e B), ciano (C=G + B) e magenta (M= R + B).



## Sistema IHS:



Se a luz chega a nossos olhos como luz vermelha, verde e azul, então, dependendo da intensidade de cada uma destas componentes, os cones irão perceber as cores. Se chega apenas luz vermelha e verde perceberemos a cor amarela, conforme visto no **cubo RGB**.

Veja, por exemplo, a figura abaixo onde uns jogadores vestem de vermelho enquanto os reservas usam um colete cinza para se diferenciar dos titulares. O uniforme vermelho tem as cores  $[R=195, G=49, B=50]$  (Você pode ler estes valores usando o paint, por exemplo). Já o colete tem valores em torno de  $[R=108, G=165, B=52]$ . O uniforme tem a componente do vermelho bem alta em relação às outras, logo está claro que é vermelho. O colete tem a componente verde maior, mas o vermelho também é significativo. Por isso, este verde tenderia um pouco ao amarelo.



Um time poderia jogar de verde e outro de vermelho, que você distinguiria as equipes na sua TV. mas, no tempo de seus avôs, a televisão era preto/branco. Na impossibilidade de transmitir a cores a única opção era enviar uma imagem preto e branco. Claro que transmitir apenas uma banda R, G ou B, não seria muito bom, pois se usamos apenas o canal azul, as duas

cores se confundem, como visto abaixo, pois em ambos os casos os valores do azul são baixos. Então a opção foi transmitir o total de energia registrado nas três bandas, ou seja, uma imagem pancromática cobrindo R, G e B.

Podemos dizer então que o total de energia incidente é a soma das parcelas R, G e B. Isto é chamado de **Intensidade**. No exemplo dos jogadores, a camiseta teria intensidade  $I=195+49+50=294$ , e o colete  $I=108+165+52=325$ . Conclusão, o colete é mais claro que a camiseta. *Pero no mucho....*

Bem, temos definido a intensidade. Agora veja, na figura ao lado, o mesmo cubo RGB, mas levemente girado. Reconhece a linha de cinzas? O plano perpendicular a esta diagonal principal (Plano amarelo na figura), pode ser descrito usando coordenadas polares (ângulo e raio). A origem do ângulo pode ser arbitrária, digamos na direção da cor vermelha, como mostrado na figura. Note que variando o ângulo a seta aponta para cores diferentes? Valores bem baixos apontam ao vermelho, ângulos próximos a 50 graus apontam para o amarelo, maiores para verde, ciano, azul, magenta e, por último, os ângulos mais altos apontam de novo para regiões de vermelho. A direção, então, da informação a respeito da **cor predominante** na luz, ou seja, o **Hue** ou **matiz**.

Por outro lado, o centro da circunferência mostrada à direita está localizado na linha de cinzas. bem, sendo cinza nenhuma cor predomina neste local, independentemente da **Intensidade**. Podemos então dizer que no centro da circunferência a **Saturação** é baixa, nenhuma cor predomina. Na medida em que o raio cresce e nos afastamos do centro, a cor se torna mais pura, mais saturada. Por isso, este raio é descrito como **Saturation**. Bem, agora temos como descrever as prováveis posições dentro do cubo de cores, mas com termos mais fáceis de entender: Intensidade, Matiz e Saturação (**Intensity, Hue, Saturation - IHS**).



# Transformação RGB-IHS

## IHS:

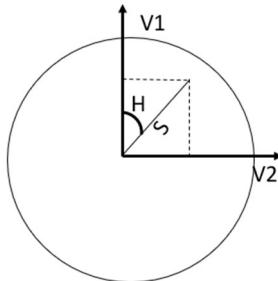
Para obter a representação polar das cores no sistema IHS a partir do RGB é necessário um pouco de matemática. Br a) A intensidade é a soma das componentes R+G+B. Mas, como a soma pode ser muito grande, é normalmente escalada ao intervalo 0-255, ou 0.0-1.0. No Envi, por exemplo, a Intensidade é calculada como:

$$I = a^*(R+G+B),$$

com  $a = \text{raiz quadrada de } 3$ ;

Um plano qualquer, perpendicular à linha de cinzas (cuja direção é  $[1 \ 1 \ 1]$ , pode ser descrito por dois vetores perpendiculares a esta direção. Uma possibilidade é usar o vetor  $\mathbf{V1} = [0 \ 1 \ -1]$ . O produto destes dos vetores  $I$  e  $\mathbf{B1}$  é nulo. Pode comprovar?

O segundo vetor deste plano deve ser também perpendicular a  $I$ . Se ainda condicionamos que ele seja também perpendicular a  $\mathbf{V1}$ , existe apenas uma direção possível, dada por múltiplos do vetor  $\mathbf{V2} = [2 \ -1 \ -1]$ . Novamente, estes vetores podem produzir valores muito



grandes, pelo que também serão normalizados. Assim, obtém-se o seguinte sistema I-V1-V2, que é uma rotação do sistema RGB.

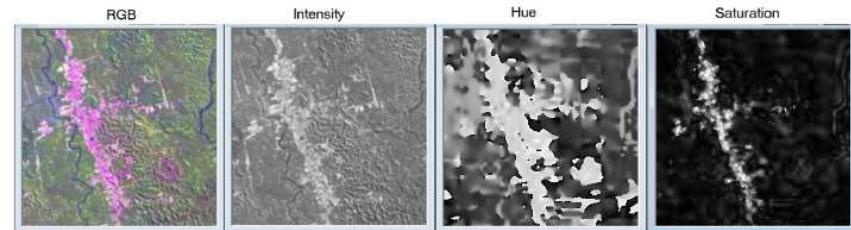
$$\begin{pmatrix} I \\ V_1 \\ V_2 \end{pmatrix} = \begin{pmatrix} \sqrt{3}/3 & \sqrt{3}/3 & \sqrt{3}/3 \\ 0 & 1/\sqrt{2} & -1/\sqrt{2} \\ 2/\sqrt{6} & -1/\sqrt{6} & -1/\sqrt{6} \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix}$$

Agora resta usar  $V1$  e  $V2$  para calcular as coordenadas polares da cor no plano perpendicular a  $I$ . Da figura ao lado, pode-se deduzir que a tangente do ângulo Hue é  $V2/V1$ . Da mesma forma, a Saturação é o tamanho da soma vetorial de  $V1$  e  $V2$ , ou seja:

$$H = \tan^{-1}\left(\frac{V_2}{V_1}\right) \quad S = \sqrt{(V_1)^2 + (V_2)^2}$$

Então, a princípio você poderia programar esta transformação no Python?

Exemplo: Veja, abaixo, as componentes IHS de uma composição colorida Landsat (543 ETM+). As áreas de solo nu, rosa, tem alta Intensidade e são bem saturadas. Por isso a cor aparece tão intensa. A vegetação, por outro lado, tem Intensidade média e baixa saturação. Por isso ela aparece "desbotada" na imagem colorida. As diferenças de "tonalidade" são visíveis na componente Hue. As áreas em rosa são bem claras, enquanto as verde escuras.

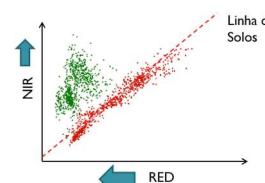




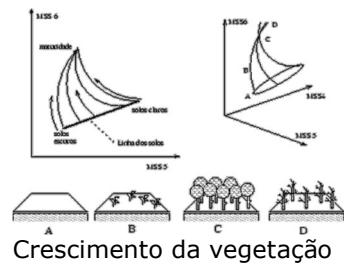
## Transformação Tasseled Cap:

A transformação *tasseled cap* foi originalmente desenvolvida para o estudo de campos de agricultura. Analisando a variação espectral de campos agrícolas em imagens do antigo MSS foram constatadas algumas propriedades que variam em função do crescimento da vegetação.

Considerando a variação espectral nas bandas vermelho e infravermelho próximo IVP notou-se que os campos agrícolas, sem vegetação, tendem a formar uma linha. Solos escuros no vermelho também são escuros no IVP. Solos claros no vermelho são também claros no IVP. Ou seja, nestas bandas R-IVP os pixels de solos são altamente correlacionados, independentemente do tipo ou cor de solo.



Linha de solos nas bandas Red-IVP



Na medida em que a vegetação cresce ela ocupa maior área do pixel. Isto tem duas consequências: o valor medido no vermelho diminui, devido à absorção da clorofila. Por outro lado, a vegetação é conhecida por ter alta reflexão no IVP, o que origina aumento dos valores medidos nesta banda. Assim sendo, da combinação destes dois fatores ocorre um deslocamento "para esquerda" e "para cima" em relação à posição original do solo nu. Quando o pixel está totalmente coberto por vegetação e solo não é mais visível, os valores na imagem dependem apenas da cultura. Neste ponto, o solo não influencia mais e, independentemente da cor do solo, os pixels convergem para um ponto. O caminho entre a linha de solos e o ponto de vegetação plena não é igual, sendo descritas curvas suaves.

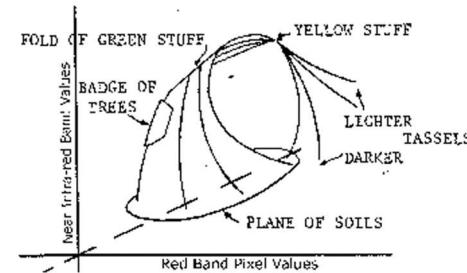
É interessante incluir o verde, pois a vegetação madura ou seca tende a amarelar. Não esquecer que amarelo é a soma de vermelho e verde. Quando se inclui a banda do verde na análise é verificado que a linha de solos não é uma linha neste espaço tridimensional (G-R-IVP), mas forma uma elipse. Assim sendo, pode-se falar de "plano de solos" quando se inclui o verde. Quando a folha se torna amarela, a resposta espectral no vermelho diminui, porque cai a produção de clorofila, e cresce no verde. Isto causa uma leve inclinação na direção do verde para a vegetação madura ou amarela.

Combinando as três bandas e acompanhando o desenvolvimento da vegetação em solos diferentes, é possível ver que se forma um cone inclinado, que tem a aparência de um gorro com borlas, do que deriva o nome inglês *tasseled cap*.

Estes fatos sugeriram a criação de um sistema, apropriado para descrever a evolução da vegetação em campos agrícolas, com os seguintes eixos: Primeiro eixo paralelo à linha de solos nas bandas RED e NIR, chamado de

solos; Segundo eixo paralelo à direção de crescimento da vegetação, chamado de verde Terceiro eixo na direção do amarelamento da folha, chamado de amarelo; Um quarto eixo que não foi passível de interpretação, denominado de outras coisas.

A vegetação, dentro de um pixel, pode ocupar uma pequena área, ou cobrir todo o pixel.



- R.J. Kauth and G.S.Thomas, "The tasseled Cap -- A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT." *Proceedings of the Symposium on Machine Processing of Remotely Sensed Data*, Purdue University of West Lafayette, Indiana, 1976, pp. 4B-41 to 4B-51.



# Fusão de Imagens

Esta aula está dividida em seis módulos:

- Introdução
- Fusão por substituição
- Fusão por substituição IHS
- Fusão por Componentes Principais
- Método de Brovey
- Avaliação da qualidade
- Exercício prático



# Fusão de imagens

necessários  $4 \times N$  detectores para varrer uma linha. Como aumentar a resolução espacial? Existem duas alternativas, diminuir a órbita, difícil, ou aumentar o número de detectores, o que se torna tecnicamente difícil. Mas, e se em lugar de medir a radiação em 4 bandas usássemos os mesmos  $4 \times N$  detectores para varrer uma única linha? Neste caso, os detectores seriam alinhados em uma linha de tamanho  $4N$  e a resolução espacial seria aumentada 4 vezes. O problema é que apenas uma banda espectral seria medida. mas qual? A opção é medir uma banda pancromática, cobrindo a faixa espectral do sensor multiespectral. Assim, como resultado temos uma imagem

Uma das formas de se obter uma imagem de sensoriamento remoto é utilizando um sensor do tipo *pushbroom*, arranjo linear CCD. Neste caso,  $N$ -detectores são usados para varrer uma linha em cada banda. Se considerarmos que os sistemas comerciais modernos medem a radiação refletida nas bandas B,G,R e IVP, seriam

multiespectral, com 4 andas, e uma pancromática, com melhor resolução espacial, cobrindo a mesma faixa espectral.

A questão é "*é possível combinar estas duas imagens, multiespectral e pancromática, para produzir uma imagem colorida de alta resolução espacial?*"? A resposta é sim, usando métodos de **fusão de imagens**

A fusão é aplicada com o objetivo de produzir uma imagem multiespectral de alta resolução espacial a partir de:

- Uma imagem multiespectral de baixa resolução espacial e
- Uma imagem pancromática de alta resolução espacial

Existem várias técnicas de fusão, sendo as mais conhecidas:

- de substituição por
  - **Intensidade-Matiz-Saturação (IHS)** e
  - **Componentes Principais**,
- Método de ponderação, como o **método de Brovey**
- **High-Pass Filter**
- com a transformação de **Wavelets**

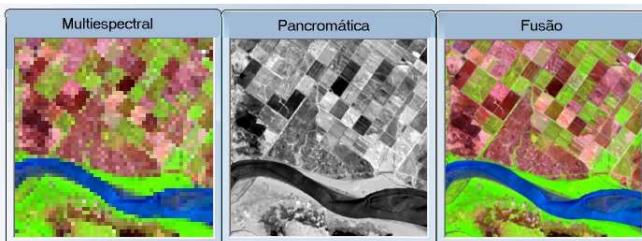
Uma boa referência:

Masood, Saleha & Sharif, Muhammad & Mussarat, Yasmin & Shahid, Muhammad & Rehman, Amjad. (2017). [Image Fusion Methods: A Survey](#). Journal of Engineering Science and Technology Review. 10. 186-195. 10.25103/jestr.106.24.



## Fusão por substituição:

Uma das opções para fazer a fusão é transformar a imagem multiespectral para um espaço de cores alternativo, substituir uma das componentes neste espaço pela imagem pancromática e voltar ao sistema de cores original. As etapas básicas seriam:



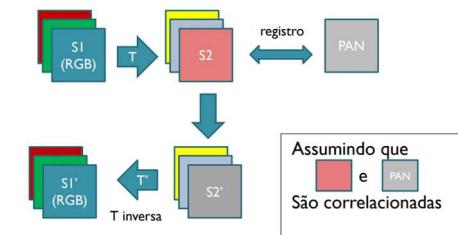
- a) Transformar o conjunto de **n**-bandas originais a um espaço alternativo;
  - b) Selecionar a imagem a ser substituída, que deve ter alta correlação com a banda pancromática;
  - c) Ajustar o histograma da pancromática para se parecer ao da banda a ser substituída;
  - d) Substituir da banda multiespectral escolhida, pela banda pancromática;
  - e) aplicar a transformação inversa.
- Parece simples, mas a questão central aqui é encontrar um *sistema alternativo* onde possamos encontrar uma componente altamente correlacionada com a imagem pancromática. Neste curso serão abordadas duas possibilidades: o **espaço IHS** e **as componentes principais**

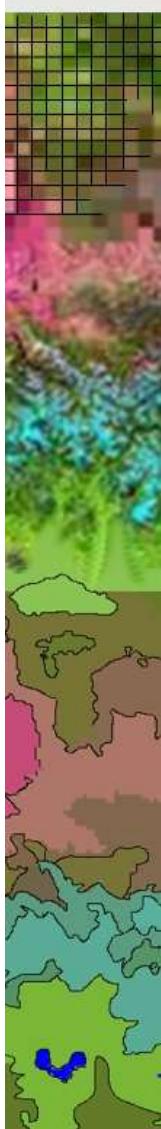
### Pré-processamento

Porém, antes de fazer qualquer fusão, devemos

- Recortar as imagens multiespectral e pancromática cobrindo a mesma área. Recomenda-se recortar com cuidado a pancromática, pois ela será a base espacial para o resultado, e recortar a imagem multiespectral cobrindo uma área um pouco maior que aquela coberta pela pancromática, para evitar que faltem pixels.
- Efetuar o registro imagem x imagem, usando a imagem pancromática como base. Neste processo, será produzida uma imagem multiespectral com resolução espacial igual à da pancromática, por reamostragem. Pode usar a reamostragem bilinear. O resultado é uma imagem com mais pixels, mas não de melhor resolução espacial. Ela aparecerá "borrada" na sua tela em função da reamostragem.

OK, então a partir deste ponto falaremos de "imagem multiespectral" e "pancromática" assumindo que já passou por estas etapas.

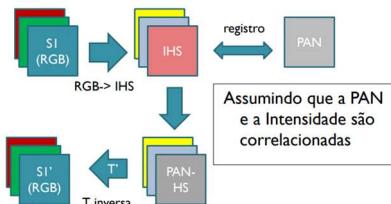




## Fusão por substituição IHS:

Se você se lembra da aula da [transformação IHS](#) deve-se lembrar que a **Intensidade (I)** é o resultado da soma das três bandas originais  $RGB.I = \text{cte} * (R+G+B)$ . Sendo ela a soma das intensidades das bandas originais, ela é muito parecida com uma imagem pancromática cobrindo a mesma faixa espectral das bandas RGB. Logo, a Intensidade será muito parecida com a banda pancromática, ou seja, as áreas claras na imagem Intensidade aparecem claras na imagem pancromática, e áreas escuras em uma delas aparecem também escuras na outra. A diferença é que a pancromática terá melhor resolução espacial.

Então, pode-se proceder a:



- Transformar o conjunto RGB original a sistema IHS;
- Verificar se a imagem pancromática tem alta correlação com a imagem Intensidade. Caso isto ocorra, então elas são equivalentes.
- Ajustar o histograma da pancromática para se parecer ao da banda a ser subsidia. Não se esqueça de que

as duas imagens, pancromática e Intensidade, podem estar em escalas diferentes. Por exemplo, a Intensidade pode variar de 0.0-1.0, enquanto a pancromática de 0-255. Então, para ter sucesso na substituição vale a pena ajustar o histograma da pancromática para o histograma da Intensidade. Usando o histograma da Intensidade como base, pode-se aplicar uma transformação linear de contraste à imagem pancromática:

$$\text{NovaPan} = a * \text{PAN} + b$$

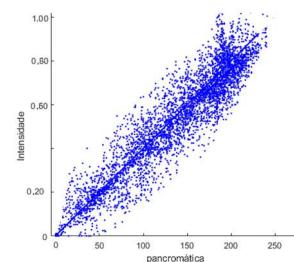
os parâmetros "a" e "b" devem ser estimados analisando os valores mínimos e máximos dos histogramas ou fazendo a regressão linear entre as duas bandas. A primeira opção é mais simples e funciona.

- Substituir a banda Intensidade pela banda pancromática e aplicar a transformação inversa.

### Olhe:

Existe correlação entre Intensidade e pancromática, porém os dados se encontram em escalas diferentes. Devemos calcular

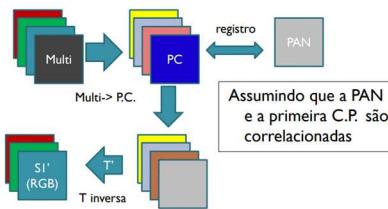
$$\text{Pan\_nova} = a * \text{Pancromática} + b$$





## Fusão por Componentes Principais:

A transformação das [Componentes Principais](#) consiste na rotação do sistema composto pelas bandas espectrais em um novo sistema, onde as novas "bandas" são combinação linear das bandas originais. Como vimos no [capítulo 3](#), é importante analisar os valores dos coeficientes das componentes principais para lhes dar uma interpretação. Na análise que fizemos, concluímos que a primeira componente era a soma ponderada de todas as bandas, pois todos os coeficientes são positivos. Bem, a "soma", mesmo que ponderada, remete a uma imagem pancromática. Então podemos dizer que a primeira componente principal se parece com uma imagem pancromática, mas... Cuidado! A transformação das componentes principais nos dá a direção da maior variação, mas não o sentido. Pode ser que o vetor direcional que foi calculado como autovalor esteja apontando "para baixo" e não "para cima", veja a figura ao lado.



Os passos são similares aos da fusão IHS, pois o método também é de substituição, porém este método tem a vantagem de poder

processar mais de três bandas espectrais. O método IHS somente pode fazer a fusão com exatamente três bandas.

- Transformar o conjunto de  $n$ -bandas originais para  $n$ -Componentes Principais.
- Verificar se a imagem pancromática tem correlação com a primeira componente. Verificar se a ordem das componentes não foi alterada e se é necessário escolher outra componente. Para tomar a decisão, analise o tamanho relativo dos autovetores.
- Ajustar o histograma da pancromática para se parecer ao da primeira componente, a ser substituída. Não se esqueça de que as duas imagens podem estar em escalas diferentes. O ajuste da Pancromática é feito usando o histograma da primeira componente e usando uma transformação linear de contraste:

$$\text{NovaCP1} = a * \text{CP1} + b$$

Os parâmetros "a" e "b" devem ser estimados analisando os valores mínimos e máximos dos histogramas ou fazendo a regressão linear entre as duas bandas. A primeira opção é mais simples e funciona.

- Substituir a banda primeira componente principal pela banda pancromática;
- aplicar a transformação inversa.



O método de Brovey se baseia na combinação matemática das imagens multiespectrais (alta resolução espectral) e a pancromática (alta resolução espacial). Primeiro, cada imagem multiespectral é normalizada com base na intensidade total contida em todas as bandas originais. Isto equivale à soma dos valores digitais do pixel em todas as bandas.

Da normalização resultam basicamente quatro dados: a Intensidade e três componentes de cor "normalizadas"

$$\text{Banda\_normalizada}(i) = \text{Banda}(i)/I$$

$$b=B/I$$

- $r=R/I$
- $g=G/I$

$$b_a = \frac{\text{Banda}_a}{\sum_{i=1}^n \text{Banda}_i} * \text{PAN}$$

Método de fusão por combinação aritmética de bandas  
CP1\_nova=a \*CP1 + b

## Método de Brovey:

Na segunda etapa se descarta a imagem Intensidade e se substitui a mesma pela pancromática. A seguir se recalcula as bandas originais, mas desta vez usando a pancromática em lugar da Intensidade:

- $R'=r*\text{PAN}$
- $G'=g*\text{PAN}$
- $B'=b*\text{PAN}$

isto equivale a:

- $R'=R*\text{PAN}/I$
- $G'=G*\text{PAN}/I$
- $B'=B*\text{PAN}/I$

Esta abordagem é bem mais simples e pode ser programada pelo aluno, não acha?

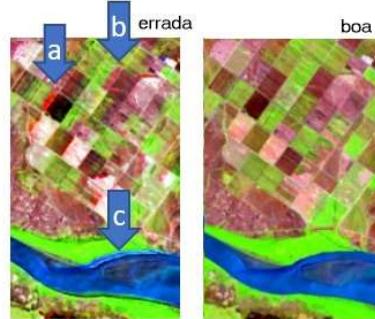


Se um dia for comprar o resultado de uma fusão de imagens, então você gostaria de saber se o produto é bom e se sua qualidade é satisfatória. Da mesma forma, se quiser comparar vários métodos de fusão e escolher o mais adequado, como poderia proceder? Bem, uma primeira análise visual pode lhe ajudar, mas não seria bom poder medir o sucesso com parâmetros numéricos?

Primeiro, verifique se existe coerência espacial entre as duas fontes, multiespectral e pancromática. Se o registro imagemximagem não foi bem executado, as imagens não se superpõem exatamente, como é mostrado na figura ao lado. Veja os seguintes erros:

- a) o campo escuro criou uma área vermelha devido ao deslocamento
- b) o campo com solo parece maior
- c) as margens do rio ocorrem duas vezes.

Por isto, é importante verificar a qualidade do registro com pontos de verificação bem distribuídos em toda a imagem e garantir erros inferiores a um pixel.



## Avaliação do produto:

### Como medir se houve perda de informação?

Bem, um bom começo para a análise e a comparação das médias das bandas antes e após a fusão. Se as médias estão parecidas, então pode-se dizer que a cor média da imagem não foi alterada significativamente, o que é um bom começo.

### Desvio padrão

É esperado que o desvio padrão da imagem híbrida seja parecido, um pouco maior, que o da imagem original. Claro, isto porque a imagem pancromática tem mais textura e o desvio padrão descreve a dispersão dos dados em torno da média. Assim sendo, uma imagem com alta resolução espacial terá maior textura e, por conseguinte, maior desvio padrão. Porém, a diferença não deve ser exagerada. A pior situação é quando o desvio padrão da imagem final é menor que o da original. Nesta situação, pode-se concluir que o contraste diminuiu e, por conseguinte, a textura não foi realçada e houve perda de informações.

### Correlação

É esperado que a imagem após a fusão, híbrida, tenha mais textura, mas ela deve ser parecida, em geral, com a imagem original. Isto quer dizer que áreas escuras na imagem original devem permanecer escuras na imagem final. Caso contrário, ocorrerá alteração das cores na composição colorida. Então, vale a pena conferir se estas duas imagens, antes e após a fusão, são correlacionadas.

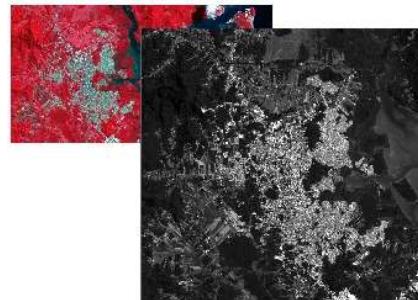
**Pergunta:** E se... a correlação for negativa, porém alta?



Como sabemos que não temos acesso ao laboratório de fotogrametria para fazer o exercício inteiro, aqui estamos disponibilizando as imagens já registradas. Assim, é possível fazer a fusão usando o Multispec.

#### Material

Imagen Landsat OLI com [Pancromática e três bandas](#)



Primeiro vamos fazer umas fusões usando o conjunto de dados contendo a [Pancromática e três bandas](#). As bandas espectrais são do sensor OLI a bordo do Landsat 8. Elas cobrem uma região em torno de Joinville, incluindo a Ilha de São Francisco. No arquivo compactado tem uma imagem com quatro bandas, na seguinte ordem: Verde, Vermelho, Infravermelho Próximo e Pancromática. As imagens multiespectrais já foram reamostradas para 15m, a resolução da Pancromática. Normalmente, você faria isso no Envi, no Laboratório. **Brovey** Usando o Multispec, visualize as imagens. A seguir, execute a fusão pelo método de Brovey. Para isto, você vai

## Aula prática

necessitar se lembrar de como se fazem operações aritméticas entre bandas.

- $R' = R * PAN / (R + G + B)$
- $G' = G * PAN / (R + G + B)$
- $B' = B * PAN / (R + G + B)$

#### Componentes Principais

Bem, foi bom para se aquecer. agora vamos a algo mais complexo, porém que você já sabe: a fusão por componentes principais. Usando o Multispec, calcule as [Componentes Principais](#), mas não de todas as bandas, apenas das três primeiras bandas (verde, vermelho & IVP). Deve ter, como resultado, uma imagem com as componentes principais com três bandas. Substitua a primeira componente pela imagem pancromática. Aplique a transformação inversa.



Área aproximada coberta pela imagem. Fonte Google Maps.



## Análise multitemporal



O que mudou nesta área, com base nas duas imagens obtidas em datas diferentes? Quais alterações podem ser consideradas naturais?

Existem alterações devido a:

- Diferenças de umidade do solo? • Ciclo fenológico ? • Ciclo de marés?

Um dos usos mais relevantes do sensoriamento remoto é o monitoramento de alterações da cobertura da terra em escalas regionais ou globais. Hoje, com a riqueza do acervo de imagens, principalmente as imagens Landsat, que se remetem aos anos 70, é possível visualizar grandes áreas "desde o espaço" e sua evolução ao longo do tempo. As imagens de sensoriamento remoto orbital fornecem dados relativamente confiáveis e com suficiente resolução para o monitoramento de grandes áreas. O problema, aqui é **detectar e quantificar** as alterações em uma série de imagens orbitais da mesma área obtidas em datas diferentes.

Dentro desta problemática, Jensen (1996) levanta questões iniciais como:

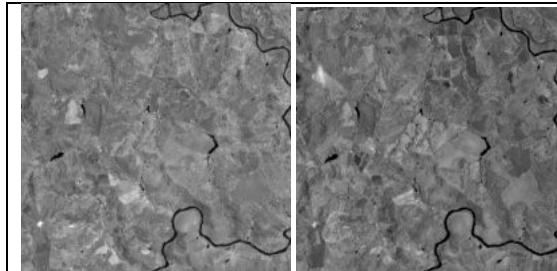
- Definir a área de estudo e determinar a frequência da mudança (sazonal? anual?);

**Uma boa referência:** Jensen, J.R. (1996) Introductory Digital Image Processing: A Remote Sensing Perspective. 2nd Edition, Prentice Hall, Inc., Upper Saddle River, NJ.

- Verificar se a alteração é visível na imagem? Em qual (is) banda(s)? Parece óbvio, mas muitas vezes estamos procurando mapear alterações que não aparecem nas imagens. Por exemplo, se uma rua se encontra totalmente coberta por vegetação, então será difícil mapear o tipo de objeto localizado na rua.
- Identificar as classes de interesse (mudanças). Como é visível na figura ao lado, diferentes tipos de alterações podem ocorrer em uma região, algumas são naturais e não necessariamente de interesse.

Uma vez estabelecida a finalidade, cabe escolher as ferramentas adequadas, como o método e principalmente a fonte de dados: o Sistema sensor, considerando suas diferentes resoluções (espacial, temporal, radiométrica, espectral).

E não deve se esquecer que a aparência dos objetos nas imagens pode ser afetada pelo Meio ambiente. Por isso, deve-se considerar os efeitos que podem ter nas imagens fatores como: Condições atmosféricas, umidade do solo, ciclo fenológico ou ciclo de marés.



## Pré-Processamento

Estas duas imagens cobrem a mesma área em datas diferentes, no vermelho. Os valores mínimos e máximos são

- imagem 1:[ 5211 - 26631]
- imagem 2:[5157 - 31299 ]

Poderia calcular os parâmetros de uma transformação linear de contraste para ajustar as imagens de forma que a faixa de variação dos valores digitais seja a mesma?

$$\text{imagem 2\_ajustada} = a * (\text{imagem 2}) + b$$

A comparação de duas imagens de datas diferentes, e eventualmente de sensores diferentes, requer que as imagens sejam dispostas em um referencial geométrico e radiométrico compatível. Para isto, são necessárias etapas de pré-processamento como:

- **A Correção Geométrica** das imagens garante que elas possam ser superpostas e que um pixel na posição (linha/coluna) de uma delas tenha a mesma posição nas outras datas. Isto permite fazer comparação direta aplicando álgebra de imagens ou operações lógicas. O processo de correção imagem imagem foi discutido no módulo de fusão de imagens.
- **A Correção Radiométrica (ou normalização):** tem por finalidade garantir que as diferenças entre imagens representem diferenças na cobertura do solo e não diferenças ambientais como condições atmosféricas ou umidade do solo, ou diferenças no sensor.

Existem vários métodos de normalização radiométrica, como:

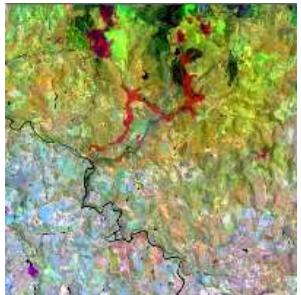
### **Correção rígida com base na modelagem do meio ambiente:**

Este processo é mais detalhado e consiste em modelar as variações que a radiação eletromagnética sofreu durante o processo de tomada da imagem. Para isto, é necessário aplicar um método de correção do efeito atmosférico e depois transformar os dados digitais a valores de radiância, base nas informações do cabeçalho da imagem que incluem a data Juliana (dia do ano), posição do sensor, posição do sol, etc. Programas comerciais, como o ENVI, possuem módulos próprios para esta finalidade.

### **Ajustes imagem x imagem (empírico):**

Os métodos empíricos ajustam a faixa de variação de uma imagem à faixa de variação de uma imagem de referência. Por exemplo, tomando a primeira data como referência, o contraste da segunda imagem é ajustado para que suas áreas escuras tenham valores próximos daqueles observados na imagem de referência e o mesmo ocorra com as áreas claras.

## Tarefa: Análise visual



Composição colorida da região do córrego do Feijão, MG, bandas do infravermelho próximo.  
Como explica a área vermelha no centro da imagem?  
O que são as áreas com cor verde saturada?  
Como explica que a parte norte da imagem seja mais "verde"?  
A que correspondem tonalidades "cinza"?  
Como será a saturação da cor das áreas com alterações?

Usando o Multispec e O conjunto de imagens fornecidos pelo professor:

- Determine os valores mínimo e máximo em cada banda;
- Determine os coeficientes da transformação linear de contraste para ajustar a segunda imagem à primeira
- Aplique esta correção à segunda imagem.

Leia os valores digitais do mesmo pixel nas imagens. São parecidos?

A forma mais simples de fazer uma análise temporal é visualizando as imagens na tela do computador e observando as alterações de tonalidade. Para isto, duas imagens, da mesma região espectral, ou duas composições coloridas com as mesmas bandas podem ser colocadas lado a lado na tela do computador. Visualmente pode-se buscar diferenças pela variação dos tons de cinza ou cor. Isto pode ser difícil quando se trata de grandes imagens ou de muitas datas.

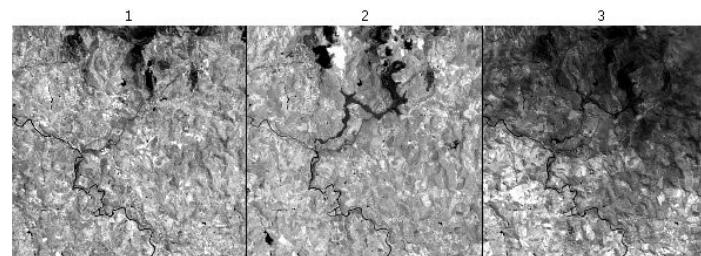
### Exemplo

Nesta [imagem](#) você encontra as imagens da banda do infravermelho do sensor OLI do Landsat 8 correspondentes à região de Brumadinho, MG. As datas são:

- banda 1:2018/09/24
- banda 2:2019/01/30
- banda 3:2019/05/06

Você pode ler esta imagem com o Multispec. Primeiro, visualize as três imagens lado a lado, com a opção "side by side channels" do comando de "display". Você deveria ter [algo como isto](#) na sua tela.

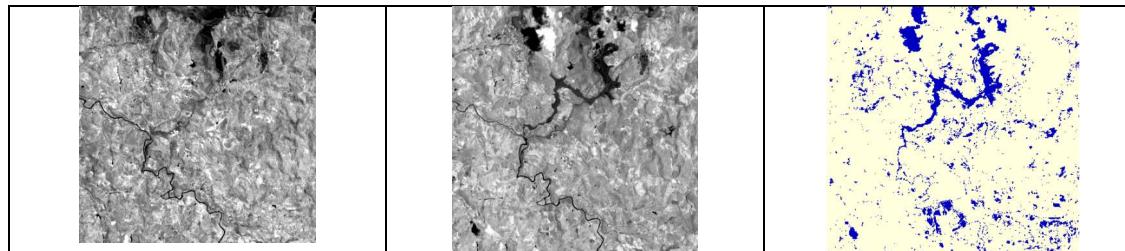
Agora também pode visualizar estas três bandas como uma composição colorida, como é mostrado na primeira figura.



Pode encontrar os efeitos da quebra da barragem?



## Análise multitemporal: Álgebra de Imagens



Imagens: antes, depois e Binária

Uma técnica de detecção de alterações é "calcular" as diferenças espectrais pixel a pixel de duas imagens de satélite adquiridas em datas diferentes. Para isto, pode-se recorrer às [operações aritméticas](#) entre bandas ou imagens. Para que o resultado do cálculo da diferença seja coerente, é necessário que as imagens tenham passado por um correto ajuste geométrico.

$$\text{DiF} = \text{após} - \text{antes}$$

A diferença entre os valores de um pixel em duas datas pode ser positiva, negativa ou nula. Raramente é nula, pois sempre existem diferenças em função das condições ambientais. Porém, *pequenas* diferenças podem ser negligenciadas. O problema é definir o que seria uma *pequena* diferença e quando ela é *grande o suficiente* para caracterizar uma alteração significativa da cobertura do planeta. Isto implica na escolha de um limite, que deve ser fundamentado com base na resolução radiométrica das imagens.

- Se  $\text{DiF} > \text{limiar}$  é alteração, Resultado=1;
- caso contrário: não houve alteração, Resultado=0;

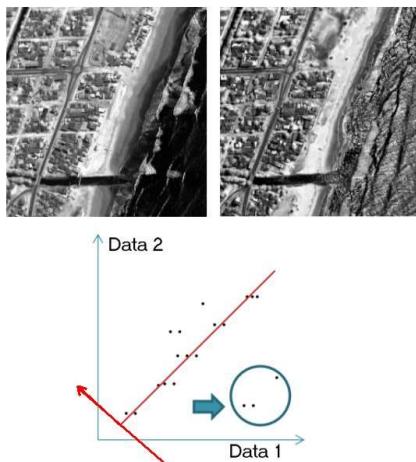
Selecionando apenas os pixels acima deste limiar, uma imagem binária é obtida: 0="inalterado"; 1="mudança". Mas lembre-se que, quanto maior o limiar, maior a chance de pixels alterados serem classificados como não alterados (erros de omissão). Pelo contrário, se o limiar for muito baixo, muitos pixels que não são alteração serão incluídos: erros de comissão.

Considere também que diferenças negativas também são alterações e podem ser descartadas quando se calcula álgebra de imagens com variáveis `UINT8`, inteiros de 8 bits. Então, vale a pena adicionar uma constante quando se deseja preservar estas alterações, por exemplo:

$$\text{DiF} = \text{após} - \text{antes} + 128$$

Como visto, o problema reside na escolha do limiar.

**exercício:** Com [as duas imagens do Corrigo do Feijão](#), calcule a diferença entre as imagens (após-antes) com 8 bits e como número real (`double`). Visualize o histograma da diferença. Estabeleça o melhor limiar de corte para separar as alterações. Verifique se a divisão de bandas serve para esta finalidade.



## Análise temporal: Análise de Componentes Principais

Com base na teoria da [transformação das componentes principais](#), sabemos que esta transformação serve para "resumir" as informações mais relevantes em um conjunto de dados. Então, ela pode ser também usada para salientar diferenças significativas e detectar padrões de alterações em uma série temporal.

Considere, inicialmente, uma série de 9 imagens de uma mesma região obtida ao longo do tempo, digamos uma por dia. Se juntamos todas estas imagens em um único conjunto  $X=\{x_1, x_2, x_3, \dots, x_9\}$ , cada pixel será descrito por um vetor  $9 \times 1$  e se a imagem tem tamanho  $n \times m$  então teremos  $n \times m$  vetores.

A seguir pode ser calculada a matriz variância-covariância deste conjunto, a que será de tamanho  $9 \times 9$  (número de bandas=9). Para esta matriz podem ser calculados os autovalores e respectivos autovetores e assim obter os vetores direcionais que apontam as principais direções da distribuição dos pontos.

Se a região não sofreu ação antrópica e, consideremos hipoteticamente, as condições ambientais não mudaram significativamente, então, as imagens serão muito parecidas ( $x_1=x_2=x_3=\dots=x_9$ ). Nessas condições, apenas a primeira componente principal teria valores significativos e a informação contida nas outras oito seria insignificante. Porém, se ocorreu alguma alteração, então a segunda e terceira componente principal irão mostrar onde.

Outra maneira de identificar as diferenças entre imagens multiespectrais, incluindo mais de uma banda por data, consiste em juntar todas as imagens em um único arquivo e calcular as Componente Principais. A seguir, deve visualizar cada componente principal e tentar dar uma interpretação. Para isto, vale a pena analisar os valores dos coeficientes de cada componente principal.

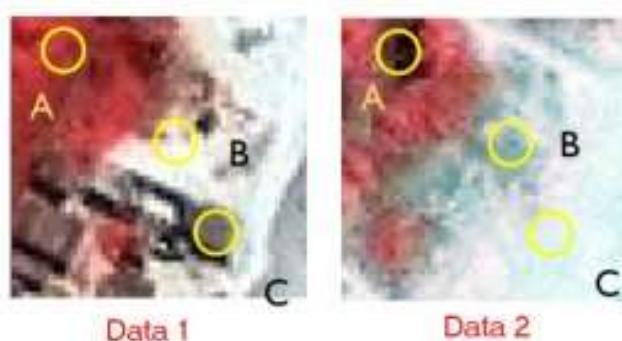
A terceira opção é calcular as componentes principais de cada data e depois comparar as respectivas componentes. Para isto, pode usar o método de [álgebra de imagens](#) e detectar as diferenças a partir da diferença entre as componentes obtidas em datas diferentes.

**Exercício:** Bem, agora é sua vez de mostrar sua capacidade. Temos uma [Aula prática](#), na qual pode aplicar estes conceitos.



## Classificação

Da mesma forma que no processamento por componentes principais, as imagens podem ser combinadas para formar um conjunto maior de imagens que pode ser submetido ao processo de classificação digital. Neste caso, seria necessário fornecer amostras de "classes de alteração" para treinar o algoritmo. Este método é válido, mas pouco eficiente em termos de processamento.



Uma opção melhor seria compor uma imagem com as bandas resultantes do cômputo da diferença nas distintas regiões espectrais. Assim, em lugar de uma imagem contendo a informação de uma banda espectral teríamos uma imagem contendo a variação nessa banda espectral. Este conjunto pode então ser classificado, usando métodos como o da distância Euclidiana ou outro método de classificação. No caso da Máxima Verossimilhança, deve-se tomar cuidado, pois ele supõe que as classes têm distribuição Normal (Gaussiana).

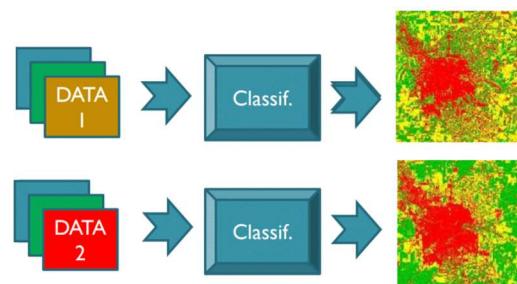




## Análise Pós-classificação

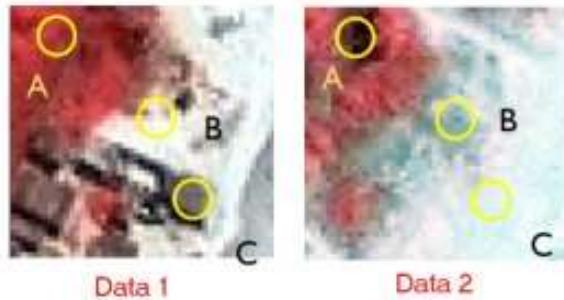
A classificação também pode ser realizada em duas etapas, classificando os dados de cada data de forma independente, mas dentro do mesmo conjunto de classes. Na etapa "pós-classificação", os mapas temáticos são comparados. Isto pode ser feito usando um Sistema de informações Geográficas (SIG), ou com operações lógicas entre bandas.

O resultado esperado é uma tabela que reflete a quantidade de pixels com e sem alterações e cada tipo de alteração, como é mostrado a seguir.



Esta tabela, uma confrontação entre os resultados da classificação das duas datas, permite quantificar e caracterizar as alterações. Na diagonal principal desta matriz consta o total de pixels que não sofreram alteração.

		Após			
		água	vegetação	solo	areia
Antes	água	1000	30	0	60
	vegetação	0	2000	100	0
	solo	10	0	2500	0
	areia	0	0	0	500



## Vetor de mudança espectral

Embora o primeiro passo na análise de alterações da superfície da terra seja a detecção dos locais onde elas ocorrem, é muitas vezes também desejado saber a natureza da alteração. Por exemplo, se houve alteração nas áreas de vegetação, a vegetação aumentou ou diminuiu? Como mudou a resposta espectral do pixel ao longo do período pesquisado? Tais questões demandam duas informações básicas:

- Como mudaram os valores digitais em cada banda?
- Qual é a intensidade desta mudança?

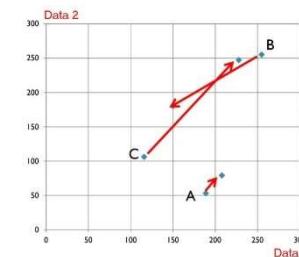
Estas questões podem ser respondidas analisando e comparando os valores de todas as bandas de cada imagem nas diferentes datas. Da álgebra de imagens sabemos que é possível calcular a diferença entre as bandas da mesma região espectral nas duas datas analisadas, antes e depois.

$$\text{DiF}_i = \text{Banda}_i(\text{após}) - \text{banda}_i(\text{antes})$$

Fazendo isto para cada banda, no caso de uma imagem com três bandas, por exemplo, teremos três diferenças. Estes valores podem ser então armazenados como um vetor, um vetor de diferenças.

$$V = [\text{DiF}_1, \text{DiF}_2, \text{DiF}_3]$$

Existe então um vetor de mudança (diferenças) para cada pixel, derivado da variação das coordenadas do pixel no espaço multiespectral. Este vetor é usado para avaliar o grau e a natureza da alteração. O procedimento mais comum consiste em calcular a direção deste vetor (cossenos diretores) e a intensidade, ou tamanho do vetor. O tamanho reflete a intensidade de mudança, independentemente da direção na que ela ocorre. Já o ângulo ou direção do vetor nos dá informações de como esta alteração ocorre.



Considere a imagem ao lado. Nela temos marcadas três regiões. Para fins de simplificar e facilitar o entendimento, vamos considerar apenas duas bandas espetrais da imagem: uma no vermelho e outra no infravermelho próximo. Os valores digitais destas regiões nas duas bandas espetrais foram medidos na imagem "data 1" e "data 2". Eles são listados a seguir. Calcule o valor da diferença entre as bandas da mesma faixa espectral. Isto equivale a calcular as componentes do vetor de mudanças (diferenças).

Determine a direção e a intensidade de cada caso. Em uma folha, desenhe estes vetores.

- Qual região sofreu maior alteração?
- As alterações se deram na mesma direção e sentido

Com base nos vetores pode dizer:

	data1		data2					
área	banda1	banda2	banda1	banda2	Dif(1)	Dif(2)	cosseno	Intensidade
A	189	53	208	79				
B	255	255	150	180				
C	116	196	228	247				

Finalmente, considere que

- Pixels sem alteração permanecem na mesma posição, ou seja, tem os mesmos valores nas diferentes datas.
- Pixels com alterações terão seus valores mudados, ou seja, sua posição no espaço multiespectral será alterada.
- A intensidade da mudança é determinada pela magnitude do vetor de mudança.
- A direção do vetor pode ajudar a determinar o tipo de alteração "de-para".



# Trabalho Prático

## Parte 1

Elabore uma proposta de trabalho no qual você aplique métodos de detecção de alterações com imagens de sensoriamento remoto. Para isto, procure nos arquivos históricos de jornais eventos caracterizados pela mudança de cobertura da terra de grande extensão. Pode ser, por exemplo, alteração do espelho de água de reservatórios ou lagos em função da seca, derramamento de lodo pela quebra de barragens, desmatamento, desmoronamentos, erosão costeira, crescimento urbano, etc, etc. Verifique também se existem dados para desenvolver o trabalho. Um bom ponto de partida é o acervo Landsat do USGS, disponível [no Earth Explorer](#)

Apresente a proposta ao professor, contendo:

- Título
- Descrição do problema, com referências (pode ser páginas de jornal) que comprovem o fato.
- Dados que serão usados
- Descrição do método que pretende usar

## Parte 2

Entrega de relatório contendo

- Título

- Introdução: contendo a caracterização do problema e a viabilidade da solução.
- Materiais: Descreva as imagens que usou, suas fontes de dados. Mostre as imagens de entrada.
- Métodos: Descreva os passos necessários para resolver o problema. Justifique por que escolheu o método e mostre como definiu os parâmetros dos métodos usados. Toda decisão deve ser descrita e justificada.
- Resultados: Contendo um mapa de alterações, bem como estatísticas e tabelas quantificando as alterações.
- Conclusões: Discuta a natureza e intensidade das alterações e como o método proposto foi capaz de resolver o problema. Se notou que houve falhas, que não podem ser resolvidas com este método, comente este fato.

Algumas recomendações e lembretes

- Pré-processamento: Correção geométrica e Correção radiométrica (ou normalização)

### Método

- Seleção de método de detecção apropriado
- Classificar imagens se for necessário
- Aplicar algoritmo de detecção de alterações
- Destacar as classes selecionadas usando a matriz de detecção de mudança
- Gerar mapas e produtos
- Calcular estatísticas

### Produto

- Controle e garantia da qualidade
- Avaliar a precisão estatística de Classificações individuais
- Produtos de detecção de mudanças



## Segmentação







## Segmentação

A segmentação pode ser uma etapa inicial na análise de imagens. Ela consiste em subdividir uma imagem em regiões uniformes (em um determinado sentido) que se espera sejam os objetos presentes na cena, ou pelo menos partes deles. Em teoria, esta divisão deveria parar quando os limites dos objetos de interesse tiverem sido isolados. Uma vez separadas estas regiões, elas podem ser analisadas não somente em termos de sua cor, mas também considerando parâmetros espaciais, como sua forma, tamanho, orientação, etc. O que facilita muito a discriminação de objetos. Como a finalidade da segmentação pode variar, o nível até onde a subdivisão deve ser realizada depende do problema a ser resolvido.

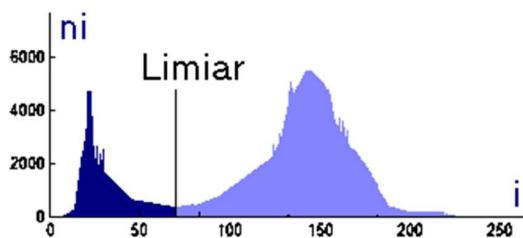
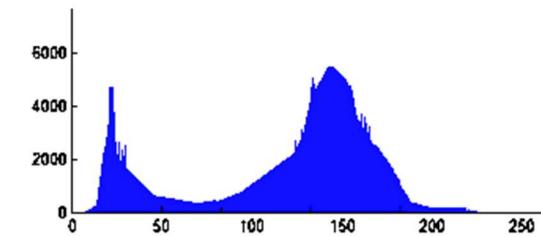
A segmentação separa as regiões com base em critérios de similaridade entre pixels de um mesmo objeto ou de diferenças mensuráveis pixels localizados nas bordas dos objetos. Ela agrupa pixels com características similares em termos tonais ou de textura, formando regiões homogêneas. O elemento da imagem, então, deixa de ser o pixel e passa a ser a região, um conjunto de pixels contíguos que apresentam alto grau de similaridade.

Algumas aplicações podem ser:

- delimitar construções em uma imagem de sensoriamento remoto, ou LiDAR;
- delimitar e contar árvores em uma imagem aérea;
- separar objetos em nuvens de pontos ou imagens de profundidade;
- desenvolver métodos para automatizar processos de leitura visual;
- reconhecimento de padrões em geral.

Alguns exemplos são apresentados na figura ao lado. Pode ativar o quadro com a tecla "start".

Não existe uma solução geral para segmentação, pois suas aplicações são múltiplas. Assim sendo, ela deve ser adaptada a cada situação, ajustando parâmetros e limiares. A segmentação baseia-se nas características de descontinuidade e similaridade dos valores digitais (cores) de uma imagem. O método que avalia a descontinuidade baseia-se na detecção de locais onde ocorre mudança abrupta dos valores digitais e os métodos por similaridade consistem da agregação de pixels próximos e similares.



## Segmentação Global

A segmentação global consiste em analisar a imagem inteira, todos os pixels, e procurar grupos de pixels similares que podem ser parte do mesmo objeto. Neste caso, não são levadas em consideração relações espaciais de vizinhança ou proximidade. Os métodos de segmentação global analisam a variação dos valores digitais presentes na imagem e tentam identificar grupos, conjuntos de pixels com valores parecidos, partindo da hipótese de que os objetos na imagem aparecem de forma uniforme em termos de cor. São exemplos os métodos de **Limiarização (Thresholding)** e **Agrupamento (Clustering)**.

### Thresholding (limiarização)

A limiarização consiste em determinar um limiar, um valor limite, que separe pixels escuros de pixels claros. Parte-se da hipótese de que existem dois grupos de pixels na imagem claros e escuros (FUNDO e OBJETO) e que é possível separar estes grupos analisando o histograma da imagem. É assumido que o histograma é bimodal.

# Método de Otsu

Otsu considera que o histograma, por ser uma representação da frequência de ocorrência dos valores digitais na imagem, pode ser visto como a distribuição da probabilidade de os valores digitais ocorrer na imagem. Ou seja, se o valor da frequência ( $ni$ ) de um determinado valor digital ( $i$ ) for baixo, a probabilidade deste ( $p(i)$ ) é baixa. Então, o histograma da imagem pode ser tratado como uma *Função Densidade de Probabilidade Discreta*:

- $p(i) = ni/N$ , com  $i = 0, 1, 2, \dots, 255$  (\*pode ser outro valor máximo)
- $N$  = número total de pixels na imagem

Então, se um determinado limiar  $T$  for escolhido, ele divide os pixels em dois grupos: Grupo1 (entre  $[0, T-1]$ ) e Grupo2 (entre  $[T, 255]$ ). Na figura são mostrados casos de divisão dos valores do histograma com um limiar  $T$ . O primeiro grupo, escuro, é formado pelos pixels com valor abaixo do limiar. Como os grupos não são completamente uniformes, a dispersão de cada grupo em torno de sua média pode ser descrita pela sua variância ( $S$ ).

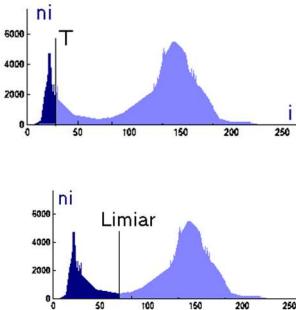
É considerado que o Limiar ideal  $T$  é aquele que minimiza a variância ( $S$ ) dentro das classes. Na figura (a) A variância do primeiro grupo é baixa, mas a do segundo grupo é muito alta. O inverso ocorre na figura (b). A combinação da variância dos dois grupos pode ser estimada fazendo a soma ponderada das variâncias "dentro" de cada classe.

$$\text{var(dentro)} = p_1 * \text{var(Grupo1)} + p_2 * \text{var(Grupo2)}$$

A média também seria uma soma ponderada

$$\text{média} = p_1 * m_1 + p_2 * m_2$$

Os pesos  $p$  são as probabilidades da ocorrência de cada grupo. Na figura (a), a probabilidade do primeiro grupo ( $p_1$ ) é menor, pois ela é igual à soma de todas as barras do histograma abaixo do limiar. Por outro lado, a probabilidade da segunda classe (acima do limiar) será dada pela soma das probabilidades dos valores entre ( $T$  e 255).



A ideia do método é obter grupos o mais uniformes possíveis como no caso da figura (c), ou seja, minimizar a soma das variâncias dentro de cada grupo. Minimizar a variância dentro das classes equivale a **Maximizar a variância "entre" classes**:

- $\text{var(entre)} = \text{var(total)} - \text{var(dentro)}$
- $\text{var(entre)} = \text{var(total)} - p_1 * \text{var(Grupo1)} + p_2 * \text{var(Grupo2)}$
- $\text{var(entre)} = p_1 * (m_1 - \bar{m})^2 + p_2 * (m_2 - \bar{m})^2$
- $\text{var(entre)} = p_1 * p_2 * (m_1 - m_2)^2$

Operacionalmente, calcula-se todos os valores possíveis de  $T$  (1-254) e escolhe-se aquele que maximizar a variância "entre" classes. Para cada valor " $i$ " calcula-se a média de cada grupo, a probabilidade de cada grupo e o peso de cada grupo, para assim poder determinar a variância entre as classes. Após calcular todas as possíveis variâncias, escolhe-se o limiar que está associado ao maior valor de  $\text{var(entre)}$ .

**Consulte:** Otsu N., "A Threshold Selection Method from Gray-level Histograms", *IEEE Transactions on Systems, Man and Cybernetics*, v. SMC 9, no 1, pp.62-66, 1979.



Quando se deseja encontrar grupos uniformes de pixels em imagens multiespectrais, pode-se usar técnicas de agrupamento multiespectral, como o método **K-médias**. **K-médias**

A princípio não se conhece quais ou quantos grupos existem. Então, deve-se especificar o número de grupos que se deseja obter. Cada grupo pode ser descrito por seu vetor de médias. Estas médias são a princípio desconhecidas e devem ser achadas. As médias devem ser tais que:

- Pixels de um mesmo grupo sejam similares entre si;
- Pixels de grupos diferentes sejam diferentes;

Veja a série de figuras à direita. Neste exemplo, duas bandas espectrais são consideradas. Os valores digitais nas duas bandas foram plotados em azul ( $x=\text{banda 1}$ ,  $y=\text{banda 2}$ ).

O primeiro passo é determinar quantos grupos existem. Vamos considerar, no exemplo,  $K=3$  grupos.

O processo é o seguinte:

1. como não conhecemos as médias destes grupos, então o sistema escolhe centros de forma aleatória. Uma boa escolha é ao longo da diagonal principal porque em sensoriamento remoto as bandas podem ser correlacionadas.
2. Agora, com essas médias, pode-se classificar a imagem e avaliar o resultado obtido. Porém, é necessário um método de classificação, baseado em uma medida de

## Agrupamento

similaridade entre cada pixel e os centros dos grupos. Como medida de similaridade pode ser usada a **distância Euclidiana**.

3. Uma vez classificados todos os pixels, pode-se calcular o verdadeiro valor das médias dos grupos (visto que o processo se iniciou com valores arbitrários). Então, vamos recalcular os centros com base nos indivíduos classificados.
4. Comparar estes novos centros com os centros anteriores. Se houver diferença entre o centro inicial e o calculado, quer dizer que o anterior não era uma boa aproximação, então vale a pena adotar os novos centros como verdadeiros;
5. Como temos novos centros, devemos repetir a classificação, voltando ao passo 2.
6. caso os centros sejam iguais aos anteriores, ou muito parecidos, então assume-se que a solução ótima foi atingida e o processo é detido.
7. Com os centros determinados neste processo iterativo pode-se classificar a imagem e obter um mapa temático.
8. Após a segmentação, deve-se analisar os grupos formados, tentando dar uma explicação.

### Exercício:

Vamos agora à aula prática. Aqui usaremos o Multispec, pois ele contém o algoritmo de agrupamento (CLustering) ISODATA. O algoritmo ISODATA tem alguns refinamentos adicionais em relação ao K-médias. Ele funde dois grupos quando o número de pixels de um grupo é extremamente pequeno e se dois centros de grupos se encontram muito próximos. Também, quando a variância de um grupo é muito grande, ISODATA divide o grupo em dois para aumentar a uniformidade dos grupos. Por isto, no algoritmo ISODATA o número de clusters pode variar durante o processo iterativo, o que não ocorre no K-médias. OK? Vamos ao exercício.



Uma das maneiras de extrair informação de uma imagem é analisando agrupamentos de pixels com características similares e não somente o pixel isolado. O primeiro passo nesta análise é a delimitação de regiões de interesse na imagem, o que pode ser atingido aplicando métodos de segmentação.

Os métodos de segmentação local são geralmente baseados em análise de descontinuidade ou similaridade de valores digitais.

- Descontinuidade: a abordagem é dividir a imagem baseando-se em mudanças bruscas dos valores digitais.
- Similaridade: pixels adjacentes com propriedades similares são agrupados para formar regiões uniformes.
- Exemplo: crescimento de regiões e divisão e fusão de regiões.

Sendo  $R$  a imagem completa, a segmentação e o processo de dividir  $R$  em  $n$  regiões  $R_1, R_2, \dots, R_n$ , tal que:

## Segmentação local

1. A segmentação deve ser completa: toda a imagem deve ser dividida e todos os pixels pertencem a uma região.
2. As regiões devem ser conexas, ou seja, não podem ter partes espacialmente separadas. Caso isto ocorra, então se trata de duas regiões diferentes.
3. As regiões devem ser disjuntas. Ou seja, não pode ocorrer superposição de regiões. Um pixel pertence a apenas uma região, não pode pertencer a duas ou mais.
4. Todos os pixels de uma mesma região têm as mesmas características. Por exemplo, todos os pixels de uma região têm a mesma cor (ou parecida). Caso um pixel não compartilhe esta propriedade com o restante, ele pertence a outra região.
5. Duas regiões diferentes e adjacentes devem ter a propriedade em questão (por exemplo a cor) diferente. Se não, são uma única região.

Os métodos de segmentação local analisam a vizinhança em torno de um pixel para procurar criar regiões uniformes juntando este pixel com pixels com cores iguais (parecidas) e diferenciando o pixel de vizinhos com cores diferentes. Isto pode ser feito de duas formas: procurando agrupar pixels similares (crescimento de regiões) ou detectando as bordas



## Crescimento de regiões

O crescimento de regiões é um método de dividir a imagem em segmentos uniformes que consiste em agrupar pixels ou sub-regiões em regiões cada vez maiores juntando pixels que tenham valores (cores) próximos. Como não se conhece onde estão as regiões, escolhe-se um pixel aleatório para servir como "semente", por exemplo o número "9" na imagem abaixo. Este pixel, inicialmente, é a região.

O seguinte passo é buscar, na sua vizinhança imediata, pixels que parecidos com ele. Caso seja achado um pixel parecido, ele deve ser incluído na região, fazendo com que a região cresça. A vizinhança do pixel na linha 3 e coluna 3 é mostrada como uma área cinza. A questão é definir um critério de "similaridade" que permita decidir se o pixel é "parecido" ou não. A opção mais simples é usar a distância entre os valores digitais. Em se tratando de mais de uma banda, a distância Euclidiana é uma opção válida.

$$D(a,b) = | \text{valor\_digital}(a) - \text{valor\_digital}(b) |$$

Vamos considerar que se a distância entre o valor do pixel e o valor da semente for menor ou igual a 20, então o pixel pertence à região. No exemplo, existem um pixel, localizado abaixo da semente, que satisfaz este critério, pois tem valor 10. Ele é então anexado à região.

Após este passo, a região cresceu e sua vizinhança imediata foi modificada, como é mostrado na segunda figura. Cabe então repetir a análise e buscar candidatos nesta nova vizinhança. No exemplo, três pixels com valores 13, 11 e 12 podem ser anexados. O processo é repetido até que não seja mais possível anexar novos pixels, o que ocorre quando os limites do objeto são encontrados, em teoria. Na prática isto nem sempre ocorre.

O critério para formar a região pode variar, pode ser "cor", "textura" ou outro. Uma crítica ao método é que o resultado pode ser afetado pela escolha das sementes. Uma semente na borda de um objeto, onde o valor digital pode ser resultante da mistura do objeto e o fundo, por exemplo, pode gerar uma região muito diferente de uma semente localizada no centro do objeto. Outra questão crítica é a escolha da medida de similaridade e o limiar que é usado para aceitar ou rejeitar a anexação de um pixel ou região.



99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87
99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87

99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87
99	87	78	83	98	83	87
99	87	78	83	98	83	87
67	99	9	89	71	89	99
69	87	10	83	77	83	87
92	13	11	12	98	92	13
89	87	13	83	78	83	87
09	77	78	73	98	73	77
99	87	10	83	77	83	87



## Split & Merge (Dividir e depois juntar)

Este método busca as fronteiras dos objetos por divisões sucessivas e consiste de duas partes.

### Divisão

Na primeira etapa se verifica se cada região é **uniforme** ([item 4 das leis da segmentação](#)). Caso isto seja verdade, então o processo é detido. Caso contrário (existam regiões não uniformes), elas devem ser divididas. A divisão é dita sistemática, pois ela é sempre igual: divide a região em quatro retângulos iguais. A divisão sucessiva em quatro partes gera uma árvore quaternária (Quadtree), que permite descrever a topologia, a relação espacial entre regiões. Por isso, as regiões são sempre retangulares neste método.

A princípio, é considerado que a imagem toda é uma região. De preferência a imagem original deve ter tamanho (linhas e colunas)  $2^n$ , para facilitar a divisão em quatro partes.

O resultado depende muito do **critério de uniformidade**. Pode-se usar, por exemplo, a variância da região, ou a diferença entre seus valores máximos e mínimos.

$$\text{Uniformidade}(a,b) = | \text{maximo}(Regiao\_A) - \text{minimo}(Regiao\_A) |$$

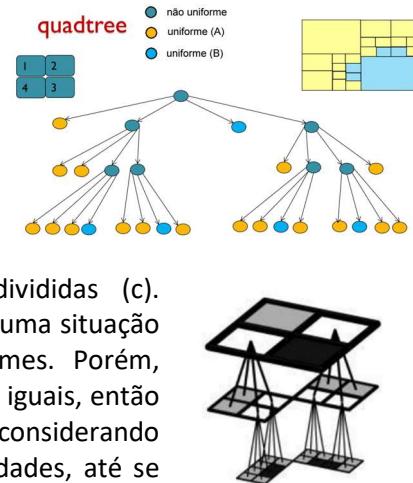
### Fusão

Na segunda parte, uma vez obtidas regiões uniformes, o seguinte passo é verificar a [condição 5](#) das leis da segmentação. Para isto, as médias das regiões adjacentes são comparadas. Caso a distância entre as médias seja inferior a um limiar pré-determinado, elas são consideradas como iguais e são fundidas.

$$D(a,b) = | \text{media}(Regiao\_A) - \text{media}(Regiao\_b) |$$

**exemplo:** Considerando região uniforme aquela no qual a diferença entre o valor máximo e mínimo não supere 20.

A imagem original (a) é dividida em 4 partes (b). É verificado se estas regiões são uniformes, como algumas não são, elas são subdivididas (c). Repetindo o processo se chega a (d) uma situação onde todas as regiões são uniformes. Porém, algumas regiões vizinhas têm valores iguais, então procede-se a juntar estas regiões (d), considerando a diferença entre médias de 10 unidades, até se chegar ao resultado final (f).



<http://graphics.cs.niu.edu/projects/rgview/index.html>

a- A imagem é uniforme?

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

b- As 4 regiões são uniformes?

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

c

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

d- Todas são uniformes

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

e- Juntar similares/adjacentes

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93

f

1	2	3	4	3	6	2	2
1	1	1	1	1	2	1	1
1	1	1	1	1	1	1	2
1	2	8	2	3	91	90	1
1	2	2	1	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	91	91	82	92	93
1	2	2	1	91	82	92	93



# Segmentação FNEA Fractal Net Evolution Approach

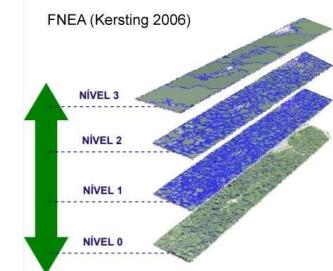
Este método é um método de crescimento de regiões, mas ele leva em consideração não somente a cor dos pixels e segmentos, mas também parâmetros de forma, o que permite controlar e guiar o crescimento em função dos objetos que se deseja procurar nas imagens. Para isto, uma medida de uniformidade é derivada da informação de cor (espectral) e da informação de forma (espacial) dos segmentos.

A princípio, todos os pixels são considerados regiões uniformes (bottom-up). Em uma primeira fase, pixels parecidos e adjacentes são agrupados formando pequenos agrupamentos.

Na sequência, as regiões são progressivamente combinadas, formando regiões cada vez maiores. As regiões a serem fundidas são selecionadas considerando a melhor fusão possível. Toda fusão de regiões gera uma região menos uniforme, então a fusão com menor perda de uniformidade é selecionada. Para isto, a heterogeneidade ( $H$ ) de cada possível fusão (ex: região "a" e "b") é quantificada como:

$$H(a,b) = (p) * H_{espectral}(a,b) + (1-p) H_{espacial}(a,b)$$

O peso " $p$ " tem por finalidade ponderar se se deseja dar maior ou menor ênfase à geometria. Isto depende da aplicação. Por exemplo, quando se deseja segmentar construções (objetos produzidos pelo homem), a forma pode ganhar maior atenção.



**A heterogeneidade espectral:** pode ser descrita pela variância ou desvio padrão dos pixels (do segmento) em cada banda. Como existem várias bandas, é adotado o somatório dos desvios padrão ( $s$ ) em cada banda ( $c$ ). Às vezes, um fator de ponderação ( $w$ ) é usado quando se deseja dar ênfase a uma banda particular. No caso geral, o peso é desconsiderado.

$$H_{espectral} = d.p.(Banda\_1) + d.p.(Banda\_2) + \dots d.p.(Banda\_n)$$

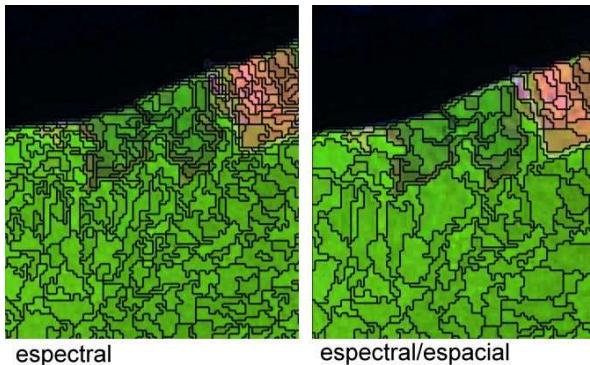
**A uniformidade espacial** descreve a forma do segmento. Para isto, dois aspectos são considerados: a **Compacidade** e a **Suavidade (dos contornos)**. Cada um destes fatores é descrito por um parâmetro e os dois valores são combinados, novamente, usando um fator de ponderação para controlar o processo no sentido de definir objetos com bordas (contornos) suaves ou não:

$$H_{espacial} = (q) * H_{compacidade} + (1-q) H_{suavidade}$$

Estes dois fatores são descritos no próximo módulo .



Na figura ao lado são apresentados dois resultados de segmentação. No primeiro caso apenas a cor foi levada em consideração. Por este motivo, o algoritmo formou regiões com alto grau de uniformidade interna, sem se importar com a forma dos segmentos.



segundo exemplo, é apresentado o produto de uma segmentação considerando também o aspecto espacial. Nota-se que o resultado apresenta agrupações mais "compactas", com contornos mais suaves. Algumas regiões podem não ser tão uniformes, como no resultado anterior. Note, também, que muitas regiões passaram a ter uma forma um tanto "quadrada" em função do peso dados ao critério espacial.

Qual destas duas abordagens você escolheria para:

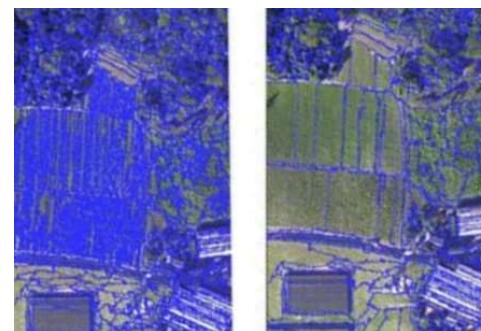
No

## Exemplo

- a) segmentar feições artificiais, como campos agrícolas?
- a) segmentar feições naturais, como a mata galeria em torno dos rios?

Se mudarmos o fator de escala, muitas regiões serão novamente fundidas, gerando uma quantidade menor de regiões, porém, menos uniformes em termos espectrais. Isto é controlado pelo critério de heterogeneidade, que é escolhido pelo usuário.

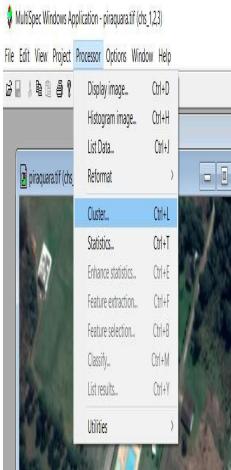
As seguintes duas segmentações são um claro exemplo de como a correta escolha do parâmetro espacial permite delimitar bem as parcelas de uma lavoura e os prédios, que tem forma regular.



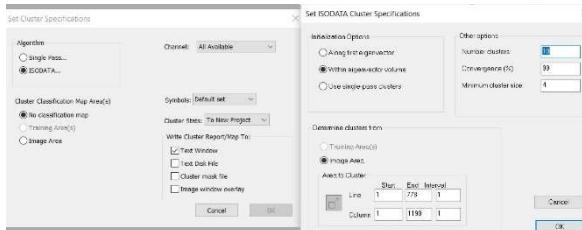
**Fonte:** [Kersting, 2006](#). Mapeamento de obstáculos sob a faixa de domínio de linhas de transmissão usando uma abordagem orientada a objeto, tecnologia lidar e câmera digital de pequeno formato. Dissertação de Mestrado UFPR.



Para este exercício utilizaremos o software “Multispec”. É uma imagem colorida RGB de uma região próxima a Curitiba.



- 1. Abra a imagem Piraquara.tif
- 2. No menu do multispec selecione Processor/Cluster. Cluster quer dizer agrupamento.
- 3. Isto abre uma nova janela, oferecendo opções para fazer o agrupamento “set cluster specifications”. Nesta janela ative a opção ISODATA, o que abre uma segunda opção com os parâmetros de algoritmo.



Algumas opções:

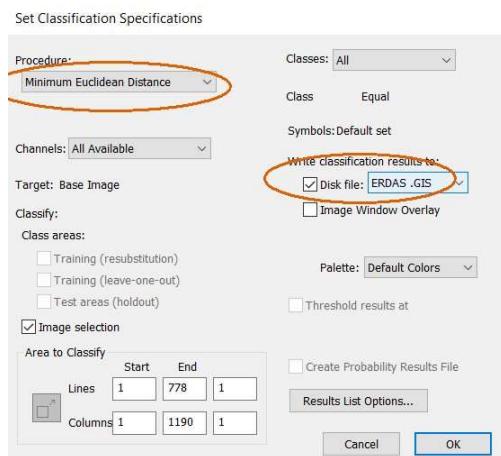
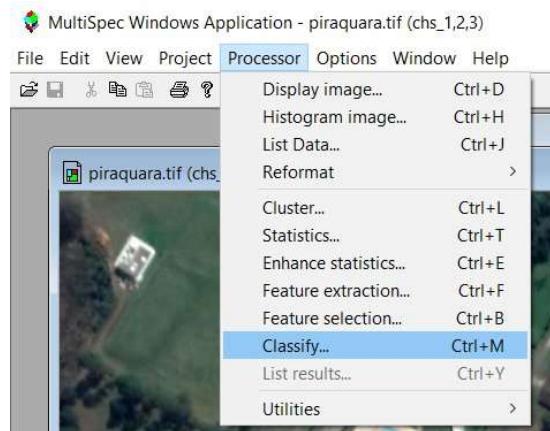
- **Initialization Options:** se refere a como devem ser arbitrados os centros iniciais. Uma boa opção é ao longo de

## Exercício de Agrupamento

primeiro autovetor (2ª linha), mas parece uma boa ideia variar e verificar o resultado.

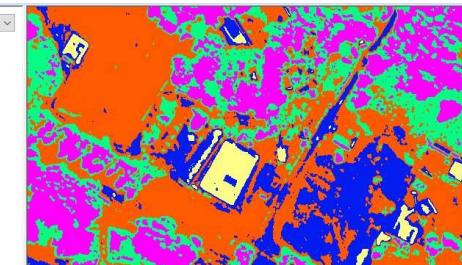
- **Other Options:** Aqui você pode escolher:
- **Número de grupos (Clusters).** Isto deve ser determinado em função da imagem. Bem, na imagem temos, pastagem, vegetação densa, área construída, piscina, solo... podemos arbitrar 5 classes?
- **Convergence:** 99%. Isto significa que o algoritmo pode parar quando chegar próximo da solução óptima. 100% seria ideal, mas devido a erros numéricos ou pequenas variações, o processo pode ser muito demorado.
- **Minimum cluster size:** é o menor tamanho de um grupo que será aceito.
- OK. Então vamos teclar OK! Após processar, o programa mostra a [tela de um projeto](#), similar àquele que usamos quando fizemos a classificação supervisionada de imagens. Note que as classes não têm nome específico, apenas “Cluster #”. Isto porque o programa não sabe que classes achou, apenas sabe que os grupos formados são uniformes. Neste ponto você pode salvar o projeto dando a ele um nome. Por enquanto não é necessário.

Então, vamos classificar a imagem com estes centros, estes clusters. Clique na imagem e depois ative no menu do Multispec o comando “processor/classify”

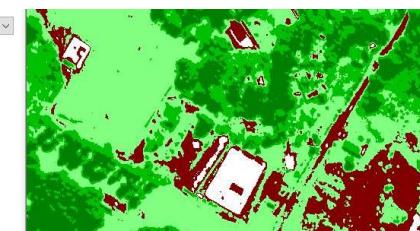


Não esqueça selecionar o método da distância Euclidiana como opção de classificação e de pedir que o resultado seja armazenado no disco. Após classificar a imagem, abra o

resultado, a imagem temática. No caso geral esta imagem pode ter o nome “piraquara\_cl.gis”, mas se você deu outro nome, procure seu resultado na pasta. Por se tratar de uma imagem temática, habilite o tipo “thematic” no diálogo de abertura de imagens. O resultado é mostrado como uma imagem temática, junto com sua tabela decora e classes. Não esqueça que você pode editar as cores das classes clicando duas vezes nos quadradinhos coloridos. Os nomes também podem ser editados. Mas nesta fase, não é tão importante. O mais importante é primeiro achar o número de clusters ótimo.



Bem, o resultado obtido não está ruim, solo, vegetação densa e pastagem foram delimitados. Mas a piscina e as áreas pavimentadas foram confundidas. Pode melhorar este resultado usando mais clusters? No resultado, vários clusters podem ser mostrados com a mesma cor.



OK. Então, vamos lá!



## Classificação por forma



O problema proposto é o seguinte: na imagem em níveis de cinza mostrada ao lado (original), existem várias regiões com a mesma forma, mas tonalidades diferentes. A tarefa é separar estas regiões em dois grupos. Obviamente, o uso de apenas o valor digital não parece promissor e a resposta está em parametrizar a forma. Afortunadamente, cada região é uniforme em termos de cor e não existem regiões com a mesma tonalidade. Então, você deve elaborar um programa em Freemat ou Python para resolver o problema.

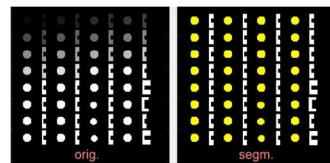
Ao lado é mostrada a fórmula do coeficiente de compacidade. É necessário calcular o perímetro e a área de cada segmento.

### Passos

Ler a imagem padrao256.tif. Seu tamanho é 256x256. Quantos objetos/figuras são visíveis na imagem?

Calcular área de cada região. Para isto devemos varrer toda a imagem e contar quantos pixels tem de cada cor. Mas antes, vamos alocar um vetor para armazenar estas áreas.

```
A=zeros(256);
for i=2: nlinhas-1 %varrer todas as linhas
```

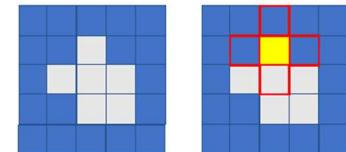


## Classificação por forma

```
for j=2:mcolunas-1 %varrer todas as colunas
    if M(i,j)>0 % se o pixel nao for do fundo
        x=M(i,j); % guarda seu valor
        A(x)=A(x)+1; % soma uma unidade à area
        desta tonalidade
    end
end
end
```

OK. agora temos a área de cada segmento. Mas e o perímetro?

Considere a figura ao lado. ela mostra uma região cinza e um fundo azul. Para contar o perímetro devemos contar quantos lados livres existem entre os pixels cinza e o fundo. Ou seja, devemos contar quantos lados livres cada pixel tem. Por exemplo, para saber quantos lados livres o pixel em amarelo tem devemos verificar seus vizinhos acima, abaixo, à direita e à esquerda. Se um deles é fundo, então encontramos um lado livre. No caso particular deste pixel teremos 3 lados livres. Se fizer isto para todos os pixels terá achado o número de cantos livres, ou seja, o perímetro.



- Como você agruparia estes elementos em duas classes?
- Depois, calculamos o coeficiente de compacidade cc.
- A seguir, devemos fixar um limiar que separe os dois grupos. Limiar:
- Finalmente, podemos mudar o valor de cada pixel segundo seu "cc".

