



# **Sensoriamento Remoto II - GA115**

## **BLOCO 1**

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

**Departamento de Geomática**

**UFPR - 2020**



# Transformação das Componentes Principais

Esta aula está dividida em sete módulos:

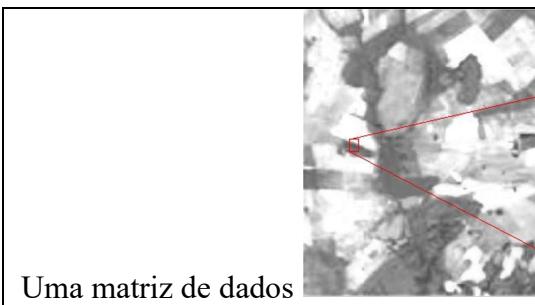
- Valores digitais
- Operações aritméticas entre bandas
- Um exemplo real
- multiplicação e divisão
- Contraste e índices
- Índices espectrais
- Índices de vegetação



## 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.



Uma matriz de dados	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 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
1 1 0 0 0 0 0 1 1 1	0 0 1 1 1 1 0 0 0
1 1 0 0 0 0 0 1 1 1	0 0 0 0 1 0 0 0 0
1 1 0 0 0 0 1 1 1 1	0 0 0 0 0 1 0 0 0
1 1 1 1 1 0 1 1 1 1	0 0 0 0 0 1 0 0 0
1 1 1 1 1 0 1 1 1 1	0 0 0 0 0 1 0 0 0

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

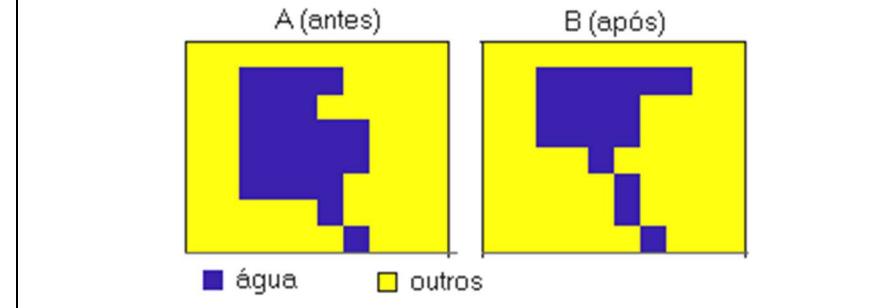
$$C = A - B$$

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.

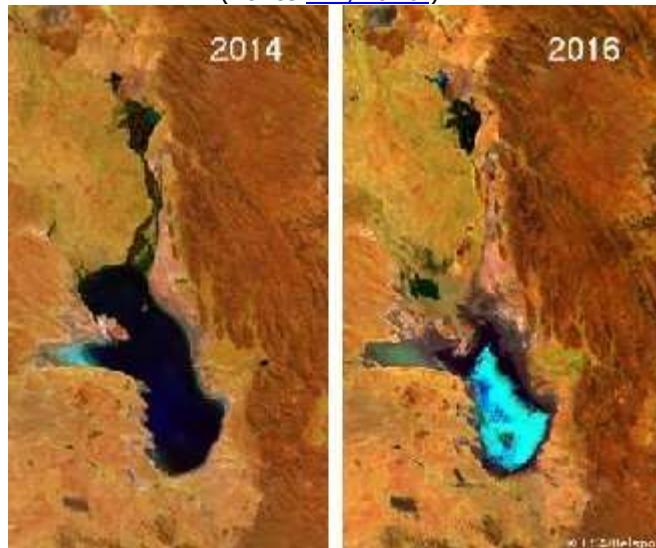
**Problema** tratando-se de uma imagem digital, não é possível representar valores negativos. Alguma sugestão? Primeiro pense, discuta com seu colega.

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

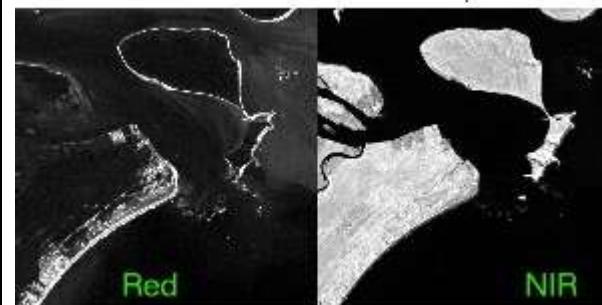
significa somar uma constante e multiplicar o resultado por outra constante, para depois adotar o valor inteiro. O melhor mesmo, seria mudar o formato usado e armazenar o resultado como **double**.

### 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:

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

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, IVM1=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 diríamos 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 diríamos 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:



## 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:

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

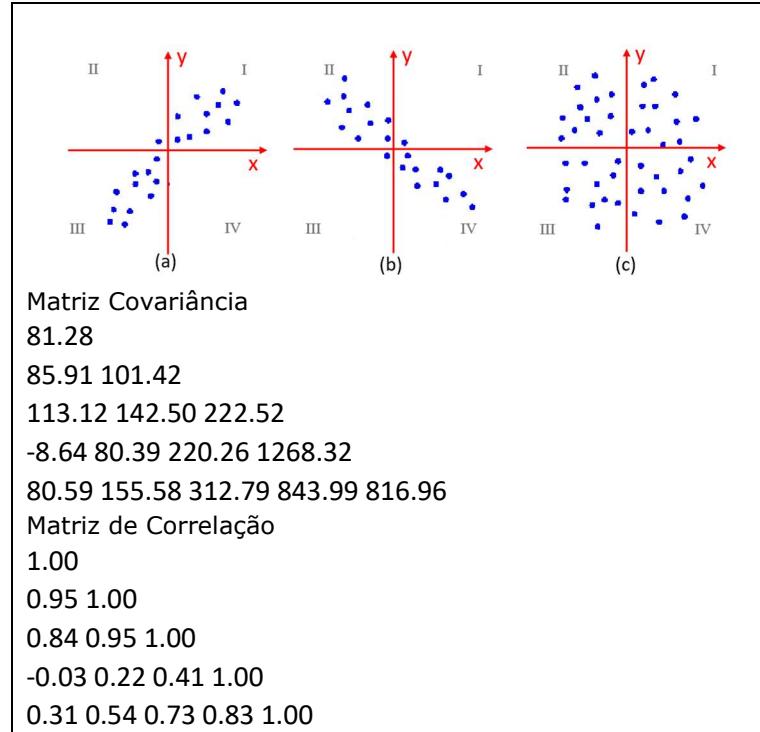
Finalmente, a correlação entre duas bandas "x" e "y" pode ser calculada como:

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

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:

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

ou três equações:

## Autovalores

$$\begin{array}{l} \bullet \begin{vmatrix} (510.17-5.6) & 559.43 & -335.00 & | & |x_1| \\ 559.43 & (647.26-5.6) & 78.40 & | * |x_2| = 0 \\ -335.00 & 78.40 & (9701.23-5.6) & | & |x_3| \end{vmatrix} \\ \bullet \begin{vmatrix} 504.6 & 559.4 & -335.0 & | & |x_1| \\ 559.4 & 641.66 & 78.4 & | * |x_2| = 0 \\ -0.335 & 78.4 & 9695.6 & | & |x_3| \end{vmatrix} \end{array}$$

ou

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

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

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:

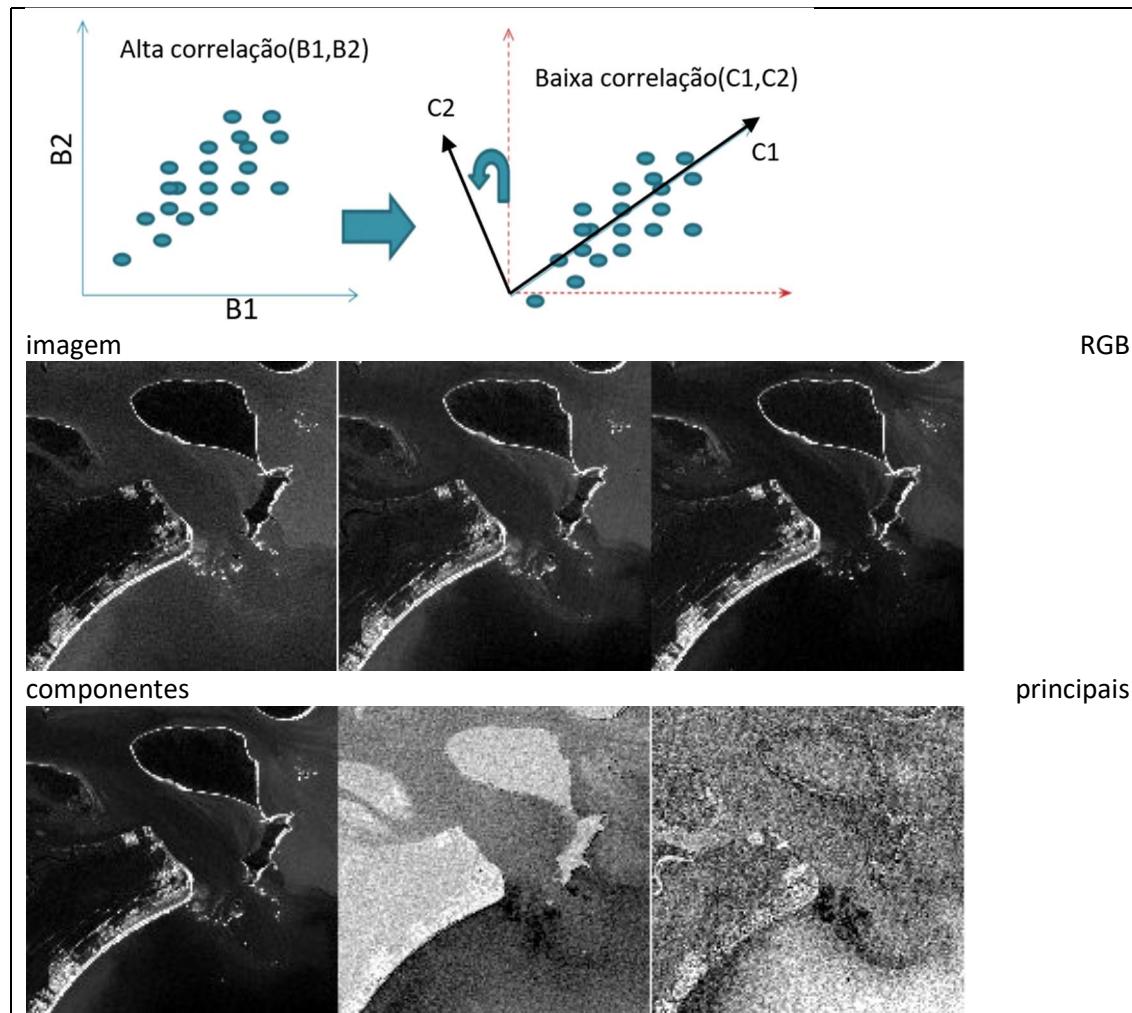
$$\begin{vmatrix} C_1 \\ C_2 \\ C_3 \end{vmatrix} = \begin{vmatrix} v_{11} & v_{12} & v_{13} \\ v_{21} & v_{22} & v_{23} \\ v_{31} & v_{32} & v_{33} \end{vmatrix} \begin{vmatrix} B_1 \\ B_2 \\ B_3 \end{vmatrix}$$

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

Comp.	1	2	3	4	5	6	7
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

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.

Channels	1	2	3	4	5	6	7
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:

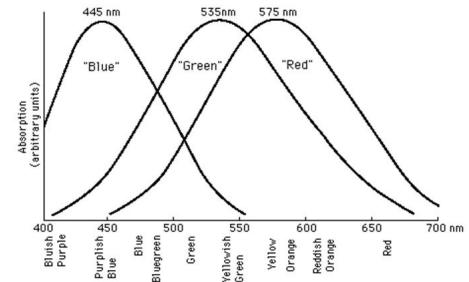
Veja a figura ao lado. A aluna de sensoriamento remoto deseja comprar uma camisa, mas não gostou da cor, então ela especificou a cor conforme aprendeu nas aulas, em RGB, mas a vendedora não entendeu. Descrever cor é uma tarefa difícil. Como você descreveria a camisa? azul? azul claro? celeste? Veja suas 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?

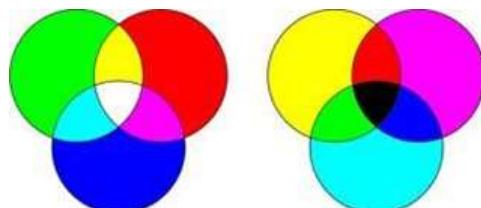


## Sistema R G B:

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

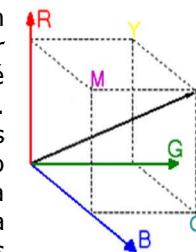
Cores Subtrativas

**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... :(

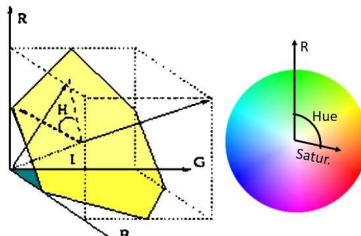


**combinação aditiva:** Isso não vale quando se combina luz, como ocorre no monitor do computador. Neste caso, valem as regras da combinação aditiva, onde a soma de todas as cores produz o branco e as cores básicas são vermelho, verde e azul. Ao longo deste curso usamos apenas este tipo de combinação,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

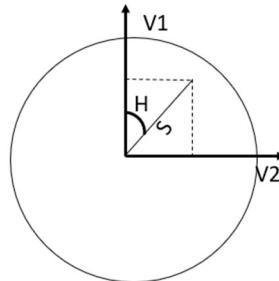
Para obter a representação polar das cores no sistema IHS a partir do RGB é necessário um pouco de matemática. Br a) A intensidade é a soma das componentes R+G+B. Mas, como a soma pode ser muito grande, é normalmente escalada ao intervalo 0-255, ou 0.0-1.0. No Envi, por exemplo, a Intensidade é calculada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

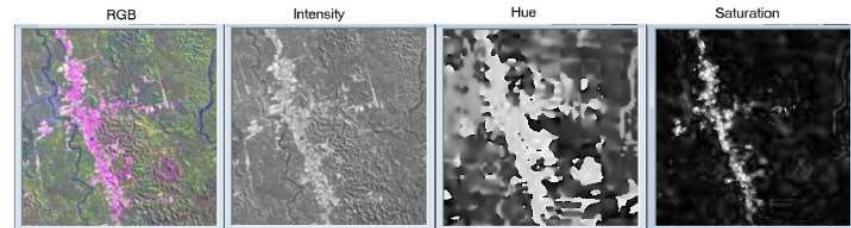
$$\begin{pmatrix} I \\ V_1 \\ V_2 \end{pmatrix} = \begin{pmatrix} \sqrt{3}/3 & \sqrt{3}/3 & \sqrt{3}/3 \\ 0 & 1/\sqrt{2} & -1/\sqrt{2} \\ 2/\sqrt{6} & -1/\sqrt{6} & -1/\sqrt{6} \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix}$$

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.

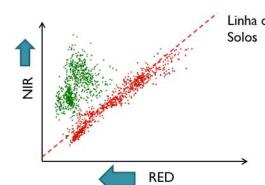




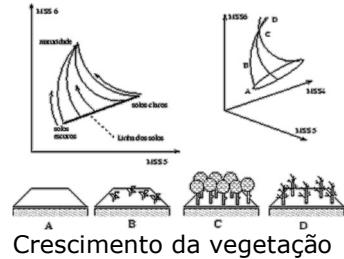
## Transformação Tasseled Cap:

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



Crescimento da vegetação

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.

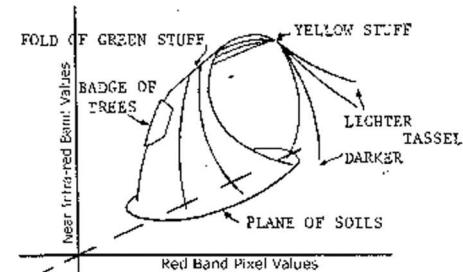
É interessante incluir o verde, pois a vegetação madura ou seca tende a amarelar. Não esquecer que amarelo é a soma de vermelho e verde. Quando se inclui a banda do verde na análise é verificado que a linha de solos não é uma linha neste espaço tridimensional (G-R-IVP), mas forma uma elipse. Assim sendo, 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.