

PRINCIPIOS E APLICAÇÕES DA DETECÇÃO REMOTA



Capítulo 5 – Classificação Temática

- Correção de imagens
 - Correções Radiométricas, Correções Geométricas, Reamostragem
- Índices (empíricos) de Vegetação
- Classificação de Imagem
 - Unsupervised (K-Means, ISODATA)
 - Supervised
 - Classificação de Máxima Verosimilhança
 - Classificador Distância mínima
 - Classificador Paralelepípedo
 - Classificador Mahalanobis
- Avaliação da precisão da classificação

Correcção das imagens

Os dados recolhidos pelos sensores de detecção remota precisam, antes de ser utilizados, de um conjunto de correcções para eliminar ou atenuar as distorções introduzidas pela aquisição e transmissão.

Esta fase de pré-tratamento pode ser dividido em dois tipos de correcções:

Correcções radiométricas

Correcções geométricas

Radiometric corrections

As correções radiométricas são usadas para calibrar os sensores, corrigir os erros devidos ao seu mau funcionamento e mitigar os efeitos devidos à propagação da radiação na camada atmosférica. Essas podem ser divididas em:

Calibração radiométrica

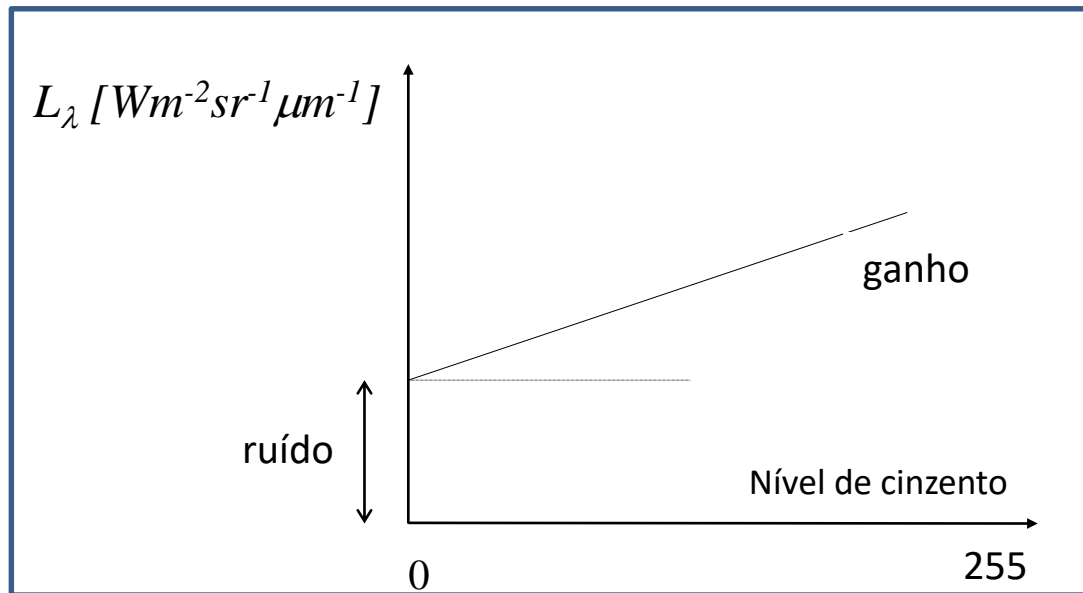
Equalização do sensor

Correcção da linhas e pixéis não gravados

Correcção atmosférica

Radiometric calibration

Serve para transformar o Digital Number (DN) numa quantidade física absoluta que no nosso caso é a radiância.




A função linear utilizada é dada por:

$$L_\lambda = ruído_\lambda + DN_\lambda \times ganho_\lambda \quad [Wm^{-2}sr^{-1}\mu m^{-1}]$$

Lines and pixels not registered

Pode acontecer que durante a scanerização de uma imagem, devido a quedas de tensão ou por perdas de sinal, ocorram erros nas imagens.

Este tipo de erros ocorre geralmente sob a forma de linhas escuras ou uniformemente cinzentas (*Drop Line*) ou de pixéis com valores anómalos.



Atmospheric correction

Os dados de Detecção Remota devem ser corrigidos dos efeitos atmosféricos e solares se o objetivo for a comparação com curvas de reflectância espectral medidas no terreno.

$$L_{\lambda}^s(x, y) = \rho(x, y, \lambda) \frac{\tau_v(\lambda)}{\pi} \{ \tau_s(\lambda) E_{\lambda}^0 \cos(\theta(x, y)) + F(x, y) \cdot E_{\lambda}^d \} + L_{\lambda}^{sp}(x, y)$$

São necessárias correções atmosféricas relativas, se as assinaturas espectrais de uma imagem numa data são para comparar com imagens adquiridas numa outra data, i.e se o objetivo é um estudo multi-temporal.



Atmospheric correction

Os métodos de correção atmosférica das imagens dividem-se em dois grupos baseado no facto de haver ou não dados sobre as condições atmosféricas no momento da aquisição da imagem.

Como já vimos no capítulo anterior, não havendo observações meteorológicas, é calculada a reflectância espectral da superfície terrestre ao nível do topo da atmosfera:

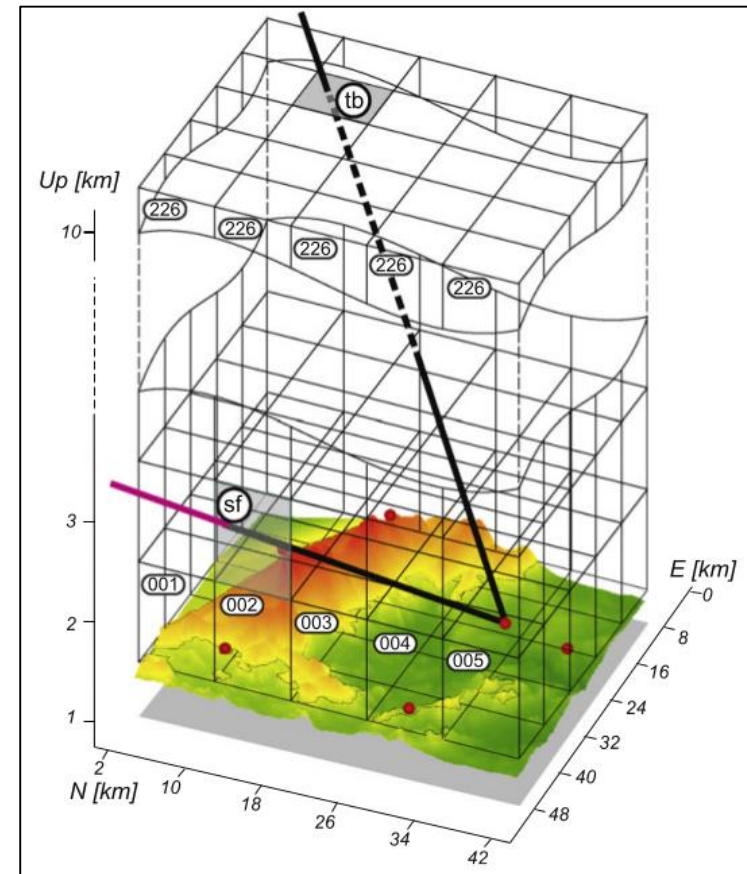
$$\rho_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot d^2}{E_{SUN_{\lambda}} \cos \theta_s}$$

Refletância Topo
da atmosfera

Atmospheric correction

Os métodos mais exatos são os baseados em modelos que abrangem a coluna inteira da atmosfera e que precisam de dados sobre as condições atmosféricas à superfície para serem calibrados (temperatura do ar, humidade, visibilidade, etc.).


Estes modelos, os mais conhecidos *Lowtran* e *Modtran* (MODerate resolution atmospheric TRANsmission) fornecem valores precisos da transmitância e da radiação atmosférica para calcular L_{sp} ed E_d .



$$L_{\lambda}^s(x, y) = \rho(x, y, \lambda) \frac{\tau_v(\lambda)}{\pi} \left\{ \tau_s(\lambda) E_{\lambda}^0 \cos(\theta(x, y)) + F(x, y) \cdot E_{\lambda}^d \right\} + L_{\lambda}^{sp}(x, y)$$




MODTRAN® is an atmospheric radiative transfer model developed by Spectral Sciences Inc. and the US Air Force Research Laboratory. It has been extensively validated and serves as a standard atmospheric band model for the remote sensing community.

[About Modtran®](#)[Features and Benefits](#)[FAQs](#)[User Resources](#)[Order MODTRAN5 Now](#)


Increased Spectral Resolution

MODTRAN®5 introduces a state-of-the-art band model formalism, developed to support increased spectral resolution.

[Read More](#)

Atmospheric Correction Data Generation

MODTRAN®5 includes a new option to generate atmospheric correction data.

[Read More](#)

Auxiliary Species Options

MODTRAN®5 now allows users to add molecular species not included in the terrestrial atmosphere default list.

[Read More](#)



Atmospheric correction– Dark pixel

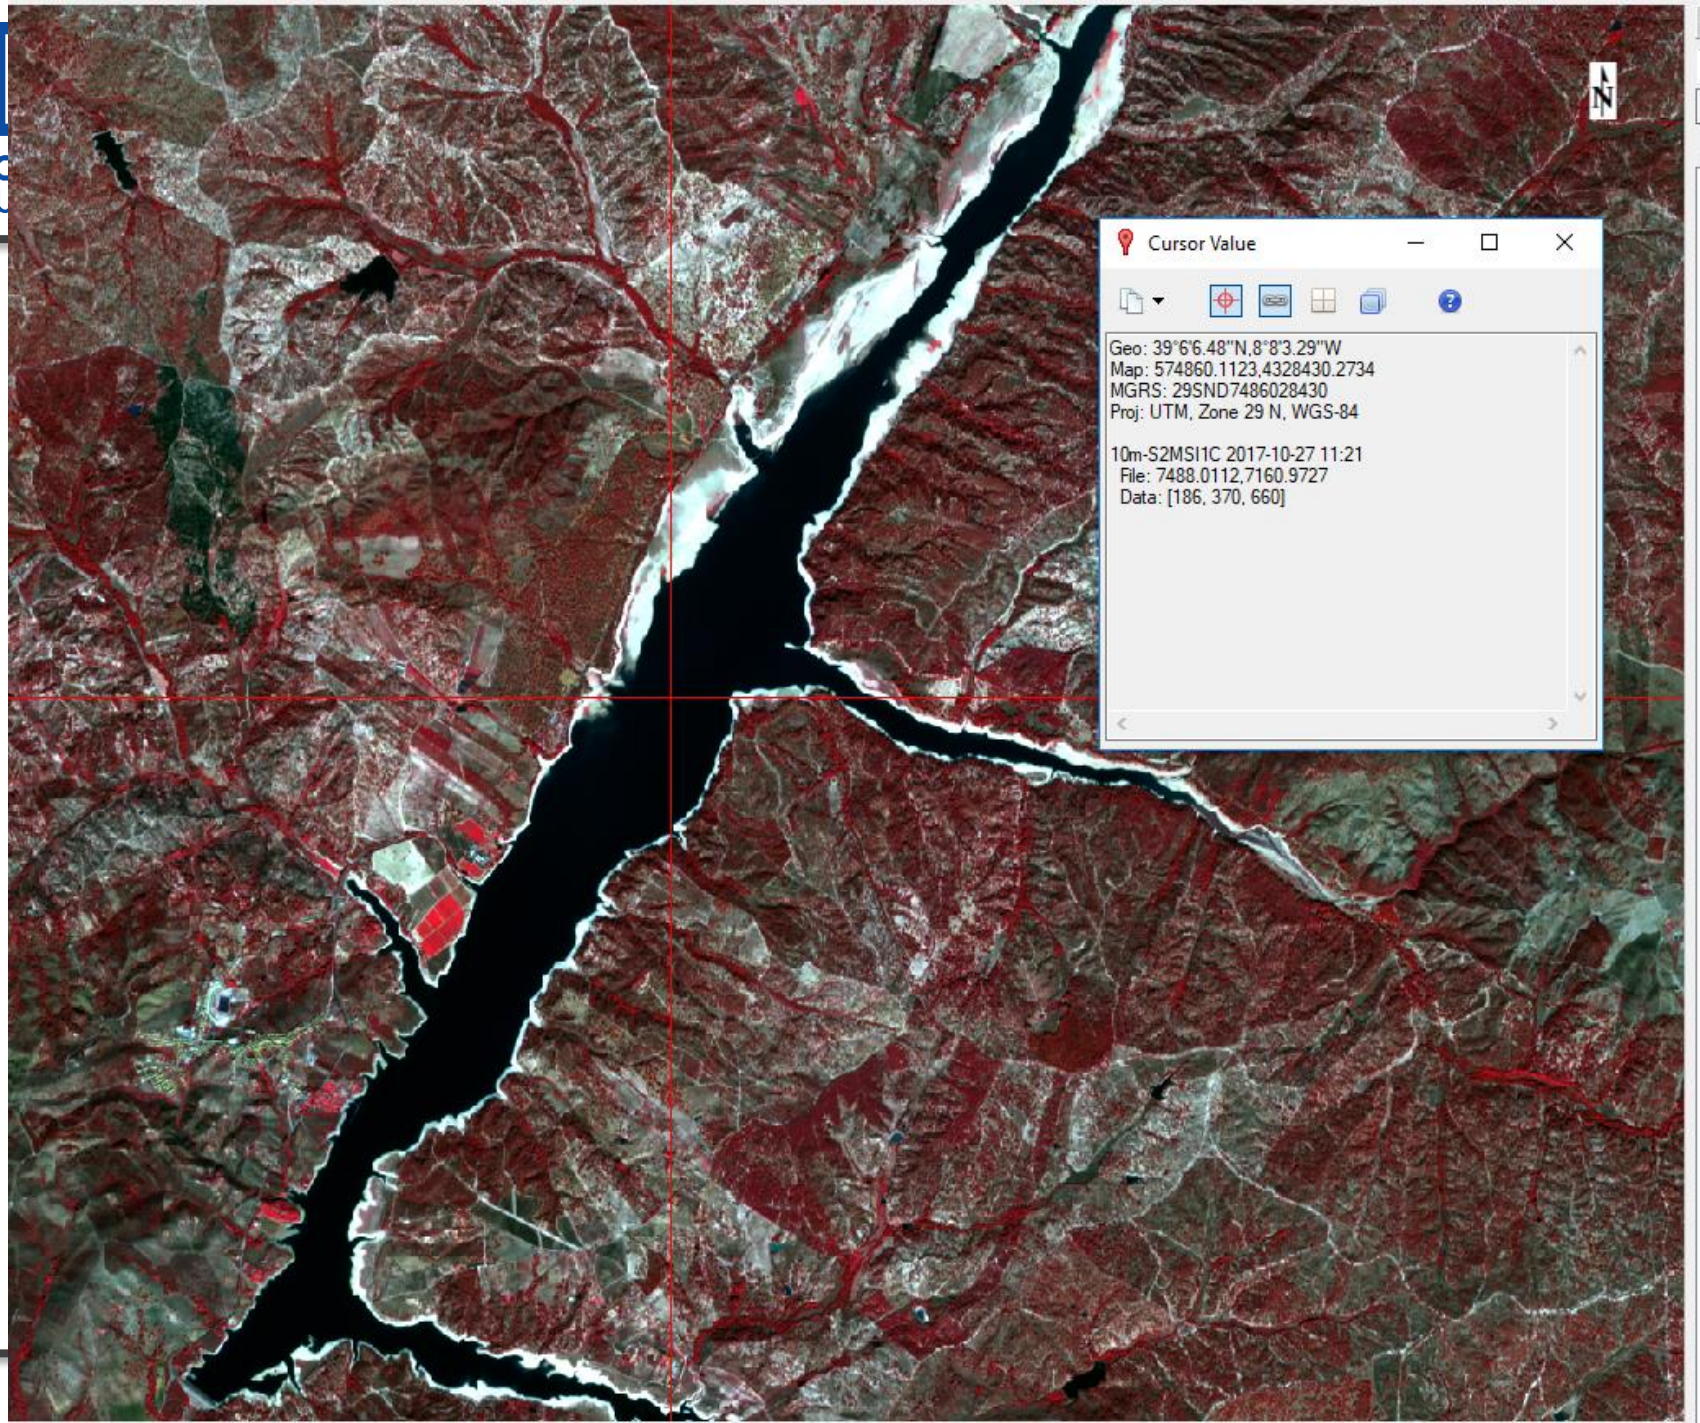
Método Dark-pixel

Não requer modelos atmosféricos.

Os pixéis escuros correspondem a tipos de solo que reflectem pouco e para os quais o sensor deveria supostamente medir uma radiância (devida apenas à atmosfera !) bastante baixa.

Com base na radiância destes pixéis registada no sensor podemos determinar a transmitância e a radiância atmosféricas.

Em geral os “dark pixels” usados para corrigir os efeitos atmosféricos são as águas oligotróficas (baixa refletividade na região do visível) e as florestas de coníferas (baixa refletividade nas banda do azul e do vermelho).



Cursor Value

Geo: 39°6'6.48"N, 8°8'3.29"W
Map: 574860.1123, 4328430.2734
MGRS: 29SND7486028430
Proj: UTM, Zone 29 N, WGS-84

10m-S2MSI1C 2017-10-27 11:21
File: 7488.0112, 7160.9727
Data: [186, 370, 660]



FLAASH Atmospheric Correction Model Input Parameters

Input Radiance Image:

Output Reflectance File: C:\Users\JCFERN~1\AppData\Local\Temp\

Output Directory for FLAASH Files: C:\Users\JCFERN~1\AppData\Local\Temp\

Rootname for FLAASH Files:

Scene Center Location: DD <> DMS Sensor Type: UNKNOWN-HSI Flight Date: Jan 1 2000

Lat: 0 0 0.00 Sensor Altitude (km): 0.000

Lon: 0 0 0.00 Ground Elevation (km): 0.000

Pixel Size (m): 0.000

Flight Time GMT (HH:MM:SS): 0 : 0 : 0

Atmospheric Model: Tropical Aerosol Model: Rural Spectral Polishing:

Water Retrieval: Yes Aerosol Retrieval: 2-Band (K-T) Width (number of):

Water Absorption Feature: 1135 nm Initial Visibility (km): 40.00 Wavelength Rec:

FLAASH Advanced Settings

Spectrograph Definition File:

For Non-nadir Looking Instruments: DD <> DMS

Zenith Angle: 180 0 0.00

Azimuth Angle: 0 0 0.00

Aerosol Scale Height (km): 1.50

CO2 Mixing Ratio (ppm): 390.00

Use Square Slit Function: No

Use Adjacency Correction: Yes

Reuse MODTRAN Calculations: No

Modtran Resolution: 5 cm-1

Modtran Multiscatter Model: Scaled DISORT

Number of DISORT Streams: 8

Use Tiled Processing: Yes Tile Size (Mb): 100

Radiance Image: Spatial Subset Full Scene

Re-define Scale Factors For Radiance Image: Choose

Output Reflectance Scale Factor: 10000

Automatically Save Template File: Yes

Output Diagnostic Files: No

- Search the Database
- /Radiometric Correction/Atmospheric Correction
- Favorites
- Anomaly Detection
- Band Algebra
- Change Detection
- Classification
- Feature Extraction
- Filter
- Geometric Correction
- Image Sharpening
- LIDAR
- Mosaicking
- Radar
- Radiometric Correction
 - Apply Gain and Offset
 - Atmospheric Correction Module
 - FLAASH Atmospheric Correction**
 - Quick Atmospheric Correction (K)
 - Calibrate AVHRR
 - Calibrate TIMS
 - Cross-Track Illumination Correction
 - Dark Subtraction
 - EFFORT Polishing
 - Emissivity Alpha Residuals
 - Emissivity Normalization
 - Emissivity Reference Channel
 - Empirical Line Compute Factors and
 - Empirical Line Correct Using Existing
 - Flat Field Correction
 - IAR Reflectance Correction
 - Log Residuals Correction
 - Radiometric Calibration
 - Thermal Atmospheric Correction
- Raster Management
- Regions of Interest
- Spatiotemporal Analysis
- SPEAR
- Spectral
- Statistics
- Target Detection
- THOR
- Terrain
- Transform
- Vector
- Extensions

... in New View

... Grayscale



Geometric corrections

Como as imagens de detecção remota são usadas em conjunto com outras informações, sobretudo de origem cartográfica, é preciso corrigir geometricamente as imagens no sentido de usar a mesma referência cartográfica.

As imagens de detecção remota são caracterizadas por diferentes tipos de distorções geométricas que em geral são corrigidas usando dois tipos de técnicas de correções:

Correções sistemáticas

Ligadas ao sensor e plataforma e por isso constantes no tempo

Correções de precisão



Geometric Correction

As correcções de precisão, para além de corrigir geometricamente a imagem de maneira coerente com o sistema de referência escolhido (georreferenciação), podem corrigir também os efeitos devidos à topografia.

Os sistemas de transformação que são geralmente usados podem ser divididos em duas categorias:


Polinomial

Orto-rectificação

Correcção pelo método polinomial

Identifica-se um conjunto de Pontos de Apoio no terreno e na imagem, chamados na literatura GCP (*Ground Control Points*).

Com base nesse conjunto de pontos, é definido um conjunto de equações de transformação que ligam as coordenadas imagem e as coordenadas cartográficas.



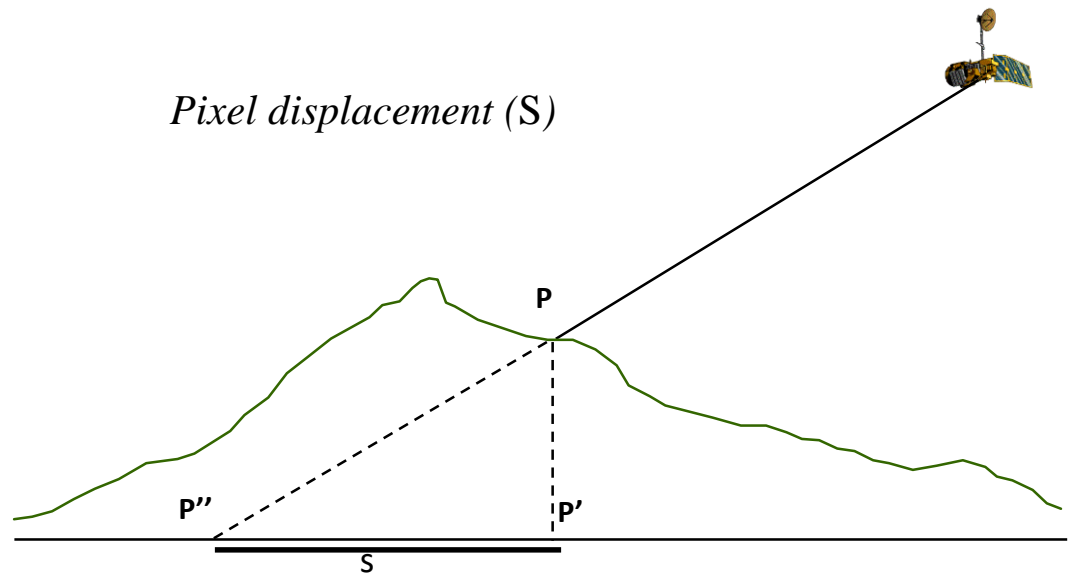
Essas equações podem ser polinómios de diferente ordem.

Transformação bilinear: $x = a u + b v + d$; $y = e u + f v + g$

Correcção por ortorrectificação

A topografia do terreno tem o efeito de deslocar radialmente o pixel em função do seu afastamento ao centro da imagem e da sua altitude.

Para corrigir este efeito efetua-se a operação de ortorrectificação baseada num MDT e no conhecimento dos parâmetros orbitais.





Reamostragem / Resampling

No processo de correcção geométrica da imagem é necessário calcular o valor radiométrico de cada pixel na sua nova posição.

O procedimento de cálculo do valor do nível radiométrico de cada pixel na imagem final designa-se por reamostragem.

Os algoritmos mais usados são:

Vizinho mais próximo

Bilinear

Bicúbico


Nearest Neighbour

O valor de radiância DN (x,y) que vamos escrever no pixel de output é o valor correspondente ao pixel que tem coordenadas linha-coluna (l,c) mais perto das coordenadas (x,y) obtidas pela transformação.

Como resultado obtemos imagens com efeito de degrau.

Por outro lado mantêm-se inalterados os valores dos pixels originais


(isso é importante por exemplo na georreferenciação dos mapas de uso do solo)



Bilinear

O novo valor de radiância DN (x,y) é calculado por interpolação que abrange os quatros pixéis mais próximos ao ponto de coordenadas (x,y) obtidas pela transformação geométrica.


Os valores de radiância originais são alterados e a imagem obtida é caracterizada por menos contrastes e variações radiométricos mais suaves (efeito da filtragem !)



Bicubic

Neste caso a interpolação (de ordem superior) abrange os 16 pixéis mais próximos.

Do ponto de vista geométrico este método é mais fiável, mas o conteúdo radiométrico é mais alterado.




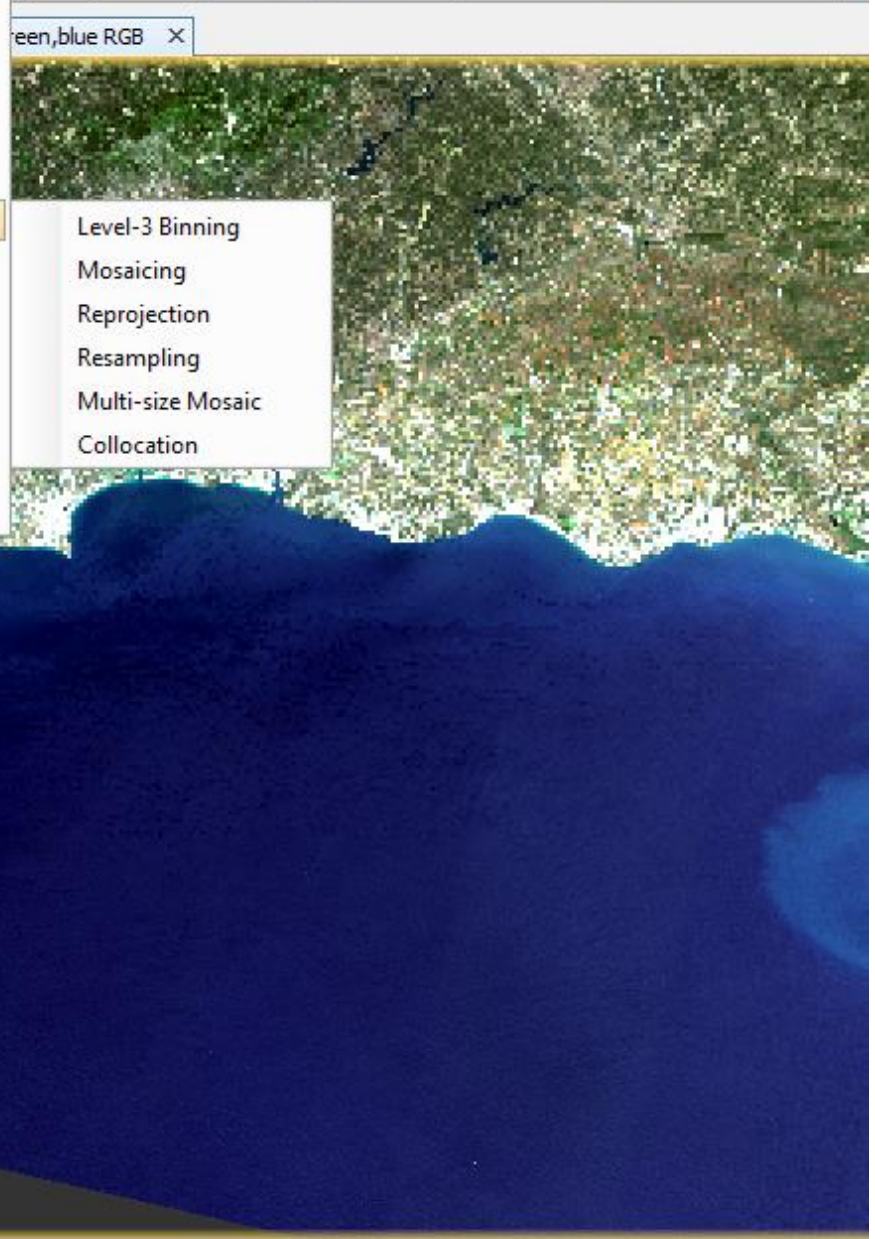
Esta técnica só faz muito sentido se o fim for a interpretação visual da imagem interpolada mas não deveria ser usada nos casos de análise numérica dos valores radiométricos.



Product Explorer × **Pixel Info**

- [1] LC08_L1TP_203034_20170523
- Metadata
- Flag Codings
- Vector Data
- Bands
- Masks

- Band Maths...
- Filtered Band...
- Convert Band
- Propagate Uncertainty...
- Geo-Coding Displacement Bands...
- Subset...
- Geometric Operations** >
- DEM Tools >
- Masks >
- Data Conversion >
- Image Analysis >
- Classification >
- Segmentation >
- Export >



Navi... × Unce... Worl... -

Red Green Blue

Name: red
Unit: W/(m²*sr*μm)
Min: 13.515
Max: 257.919
Rough statistics!

14.95 76.53

More Options ?



Reprojection

File Help

I/O Parameters Reprojection Parameters

Coordinate Reference System (CRS)

Custom CRS

Geodetic datum: World Geodetic System 1984

Projection: Geographic Lat/Lon (WGS 84)

Projection Parameters...

Predefined CRS Select...

Use CRS of ...

Output Settings

Preserve resolution Reproject tie-point grids

Output Parameters... No-data value: NaN

Add delta lat/lon bands Resampling method: Nearest


Output Information

Scene width: 19228 pixel	Center longitude: 7°45'44" W
Scene height: 15582 pixel	Center latitude: 37°28'09" N
CRS: WGS84(DD)	Show WKT

Run Close

Spectral Signature

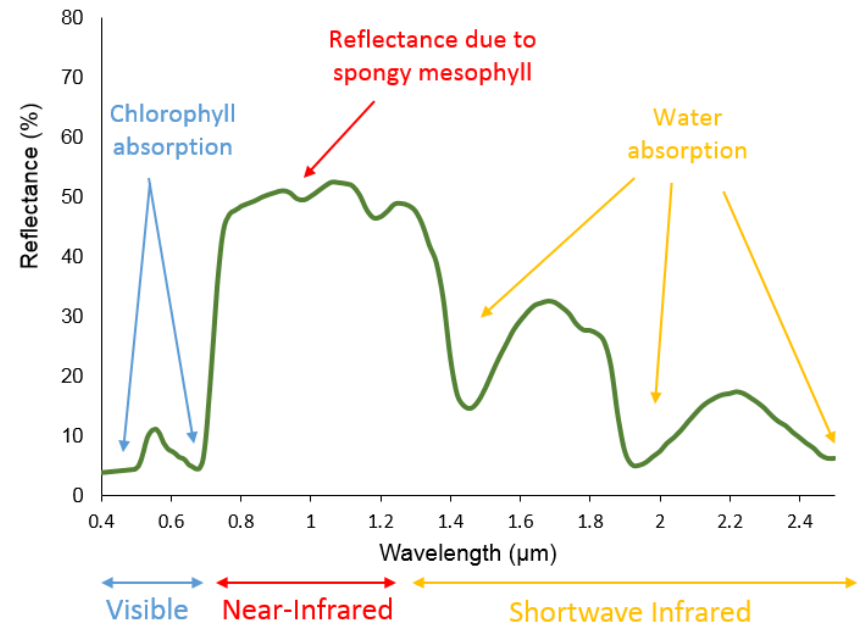
These differences in reflectance make it possible to identify different earth surface features or materials by analysing their spectral reflectance signatures. **Spectral reflectance curves** graph the spectral reflectance of objects as a function of wavelengths.



Spectral Signature

Red lights absorption start to decline at the edge of the visible range and infrared wave reflectance increases sharply.


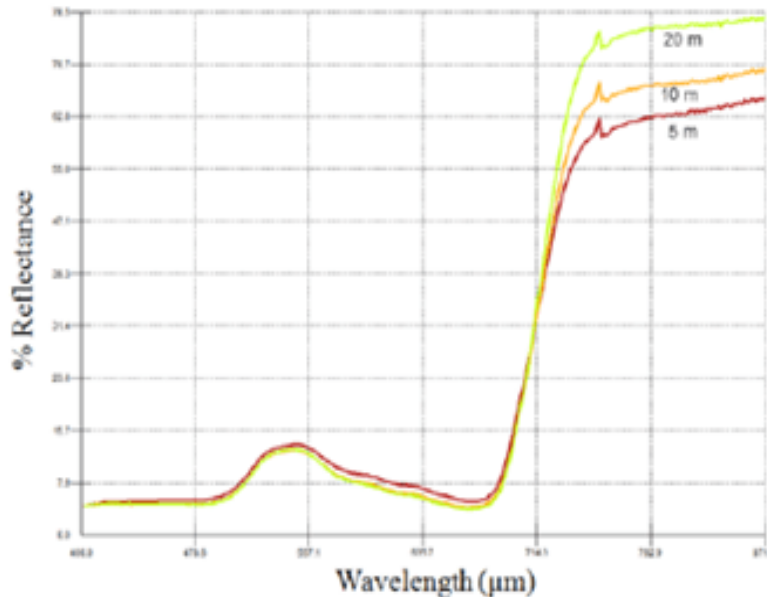
If reflectance of energy is to measure in both visible and infrared region then curve will be very high in infrared region compared to visible range in a **healthy vegetation** leaf.



This infrared behaviour helps researchers to study the vegetation; also help to differentiate between **vegetation** and **non-vegetation**.

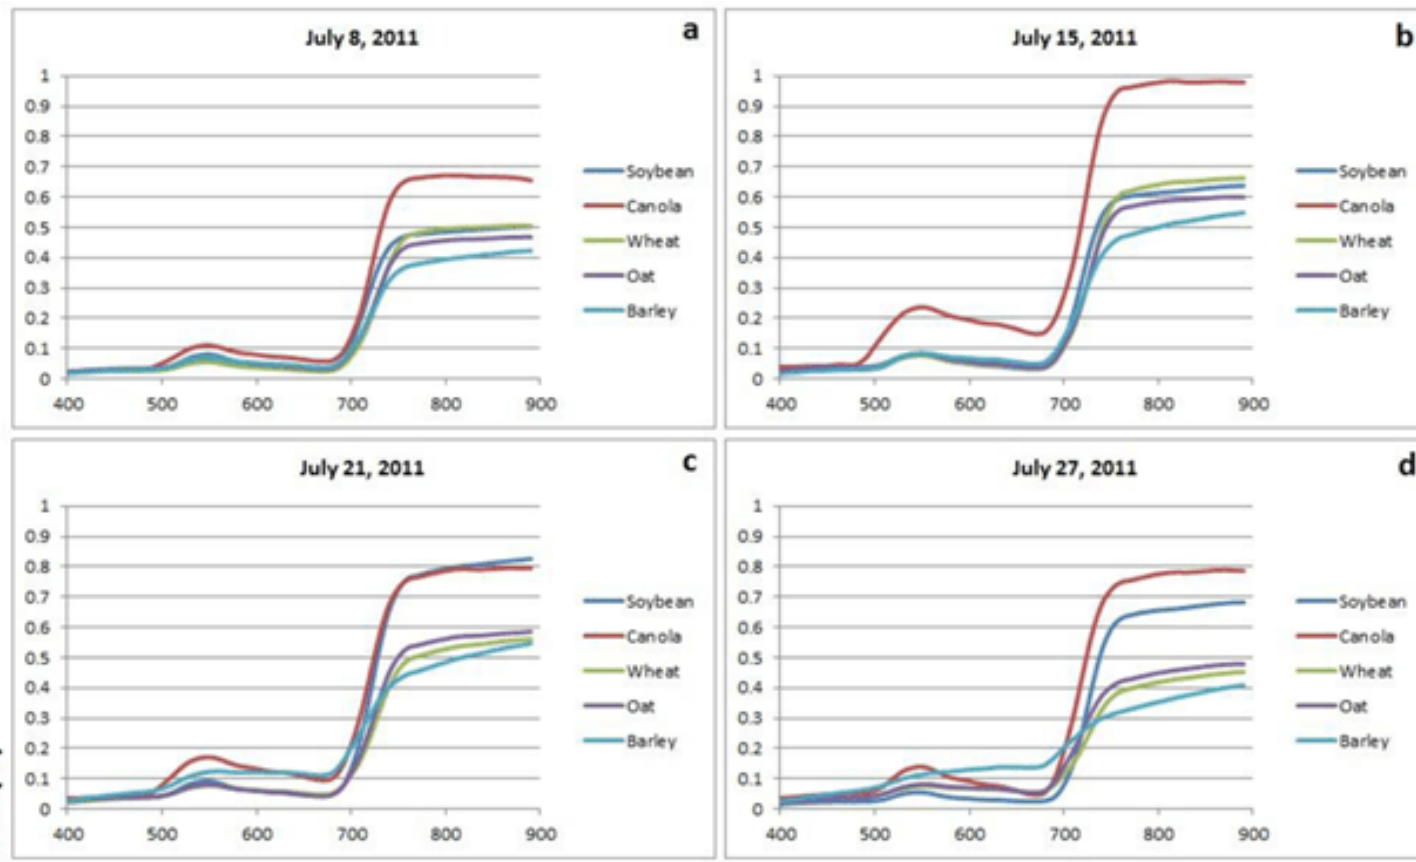
Spectral Signature

Infrared reflectance also helps to differentiate vegetation classes and different reflectance value for **different vegetation**. If plants **matured or under stress** they behave differently in infrared or in visible range. But this type characteristic is more recognizable in the infrared region.



Spectral Signature

Spectral signatures for **different crops** organized by number of days after planting.




Vegetation Index

Baseiam-se no facto que a vegetação “verde” interage de forma característica com a radiação eletromagnética.

Os índices de vegetação relacionam a refletância na zona do infravermelho e na zona do visível.

A clorofila absorve a radiação na banda do azul e vermelho para realizar a fotossíntese e a estrutura interna das folhas reflete fortemente a radiação do infravermelho próximo





Vegetation Index

Índice razão.

$$I_1 = \frac{BLand_{red}}{BLand_{NIR}} = \frac{\text{vermelho}}{\text{infravermelho próximo}}$$

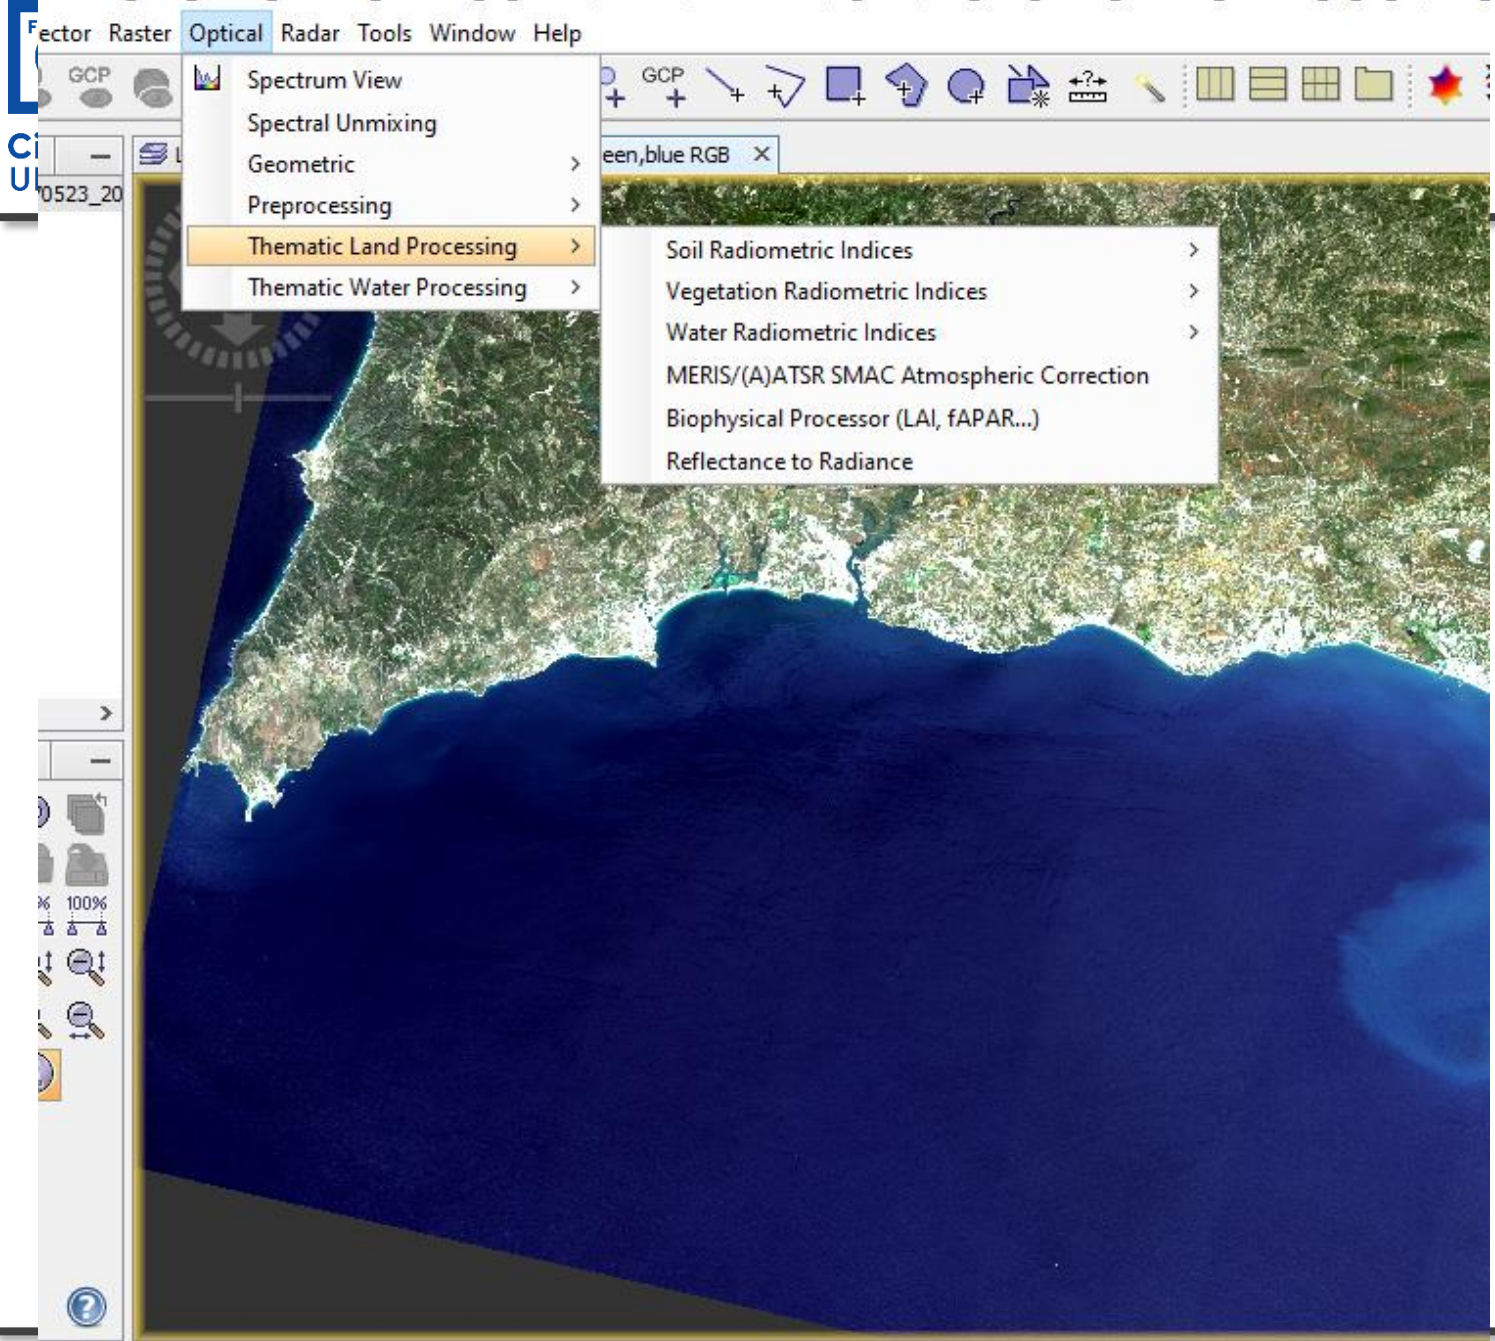
Índice de vegetação normalizado NDVI


Normalized Difference Vegetation Index


$$NDVI = \frac{\text{InfraRED} - \text{red}}{\text{InfraRed} + \text{Red}}$$

Sempre entre -1 e +1. Valores típicos para a vegetação são superiores a 0.3.

Valores superiores a 0.5 indicam a presença de vegetação no pleno do seu estado vegetativo.





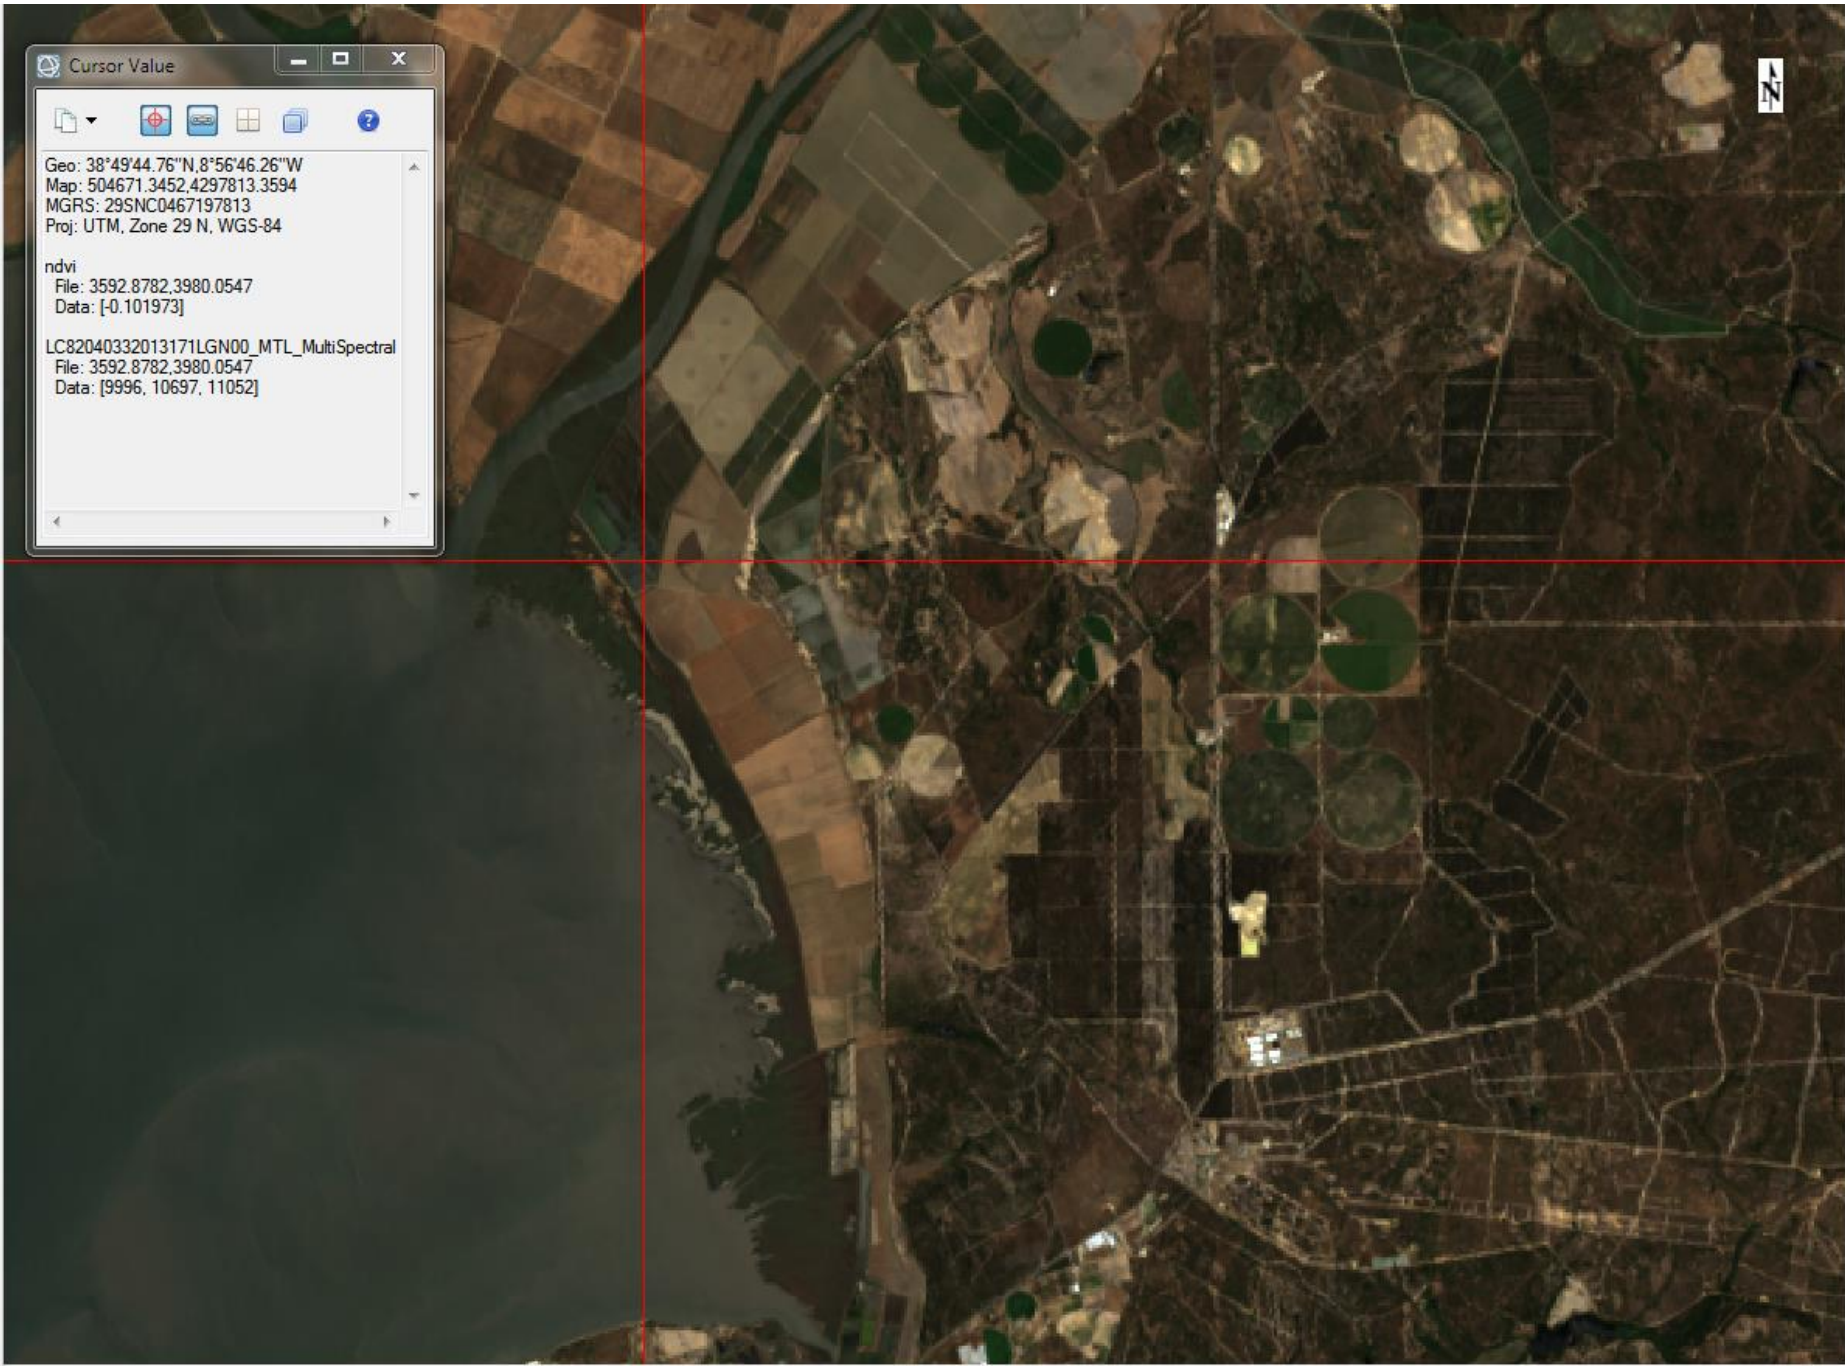


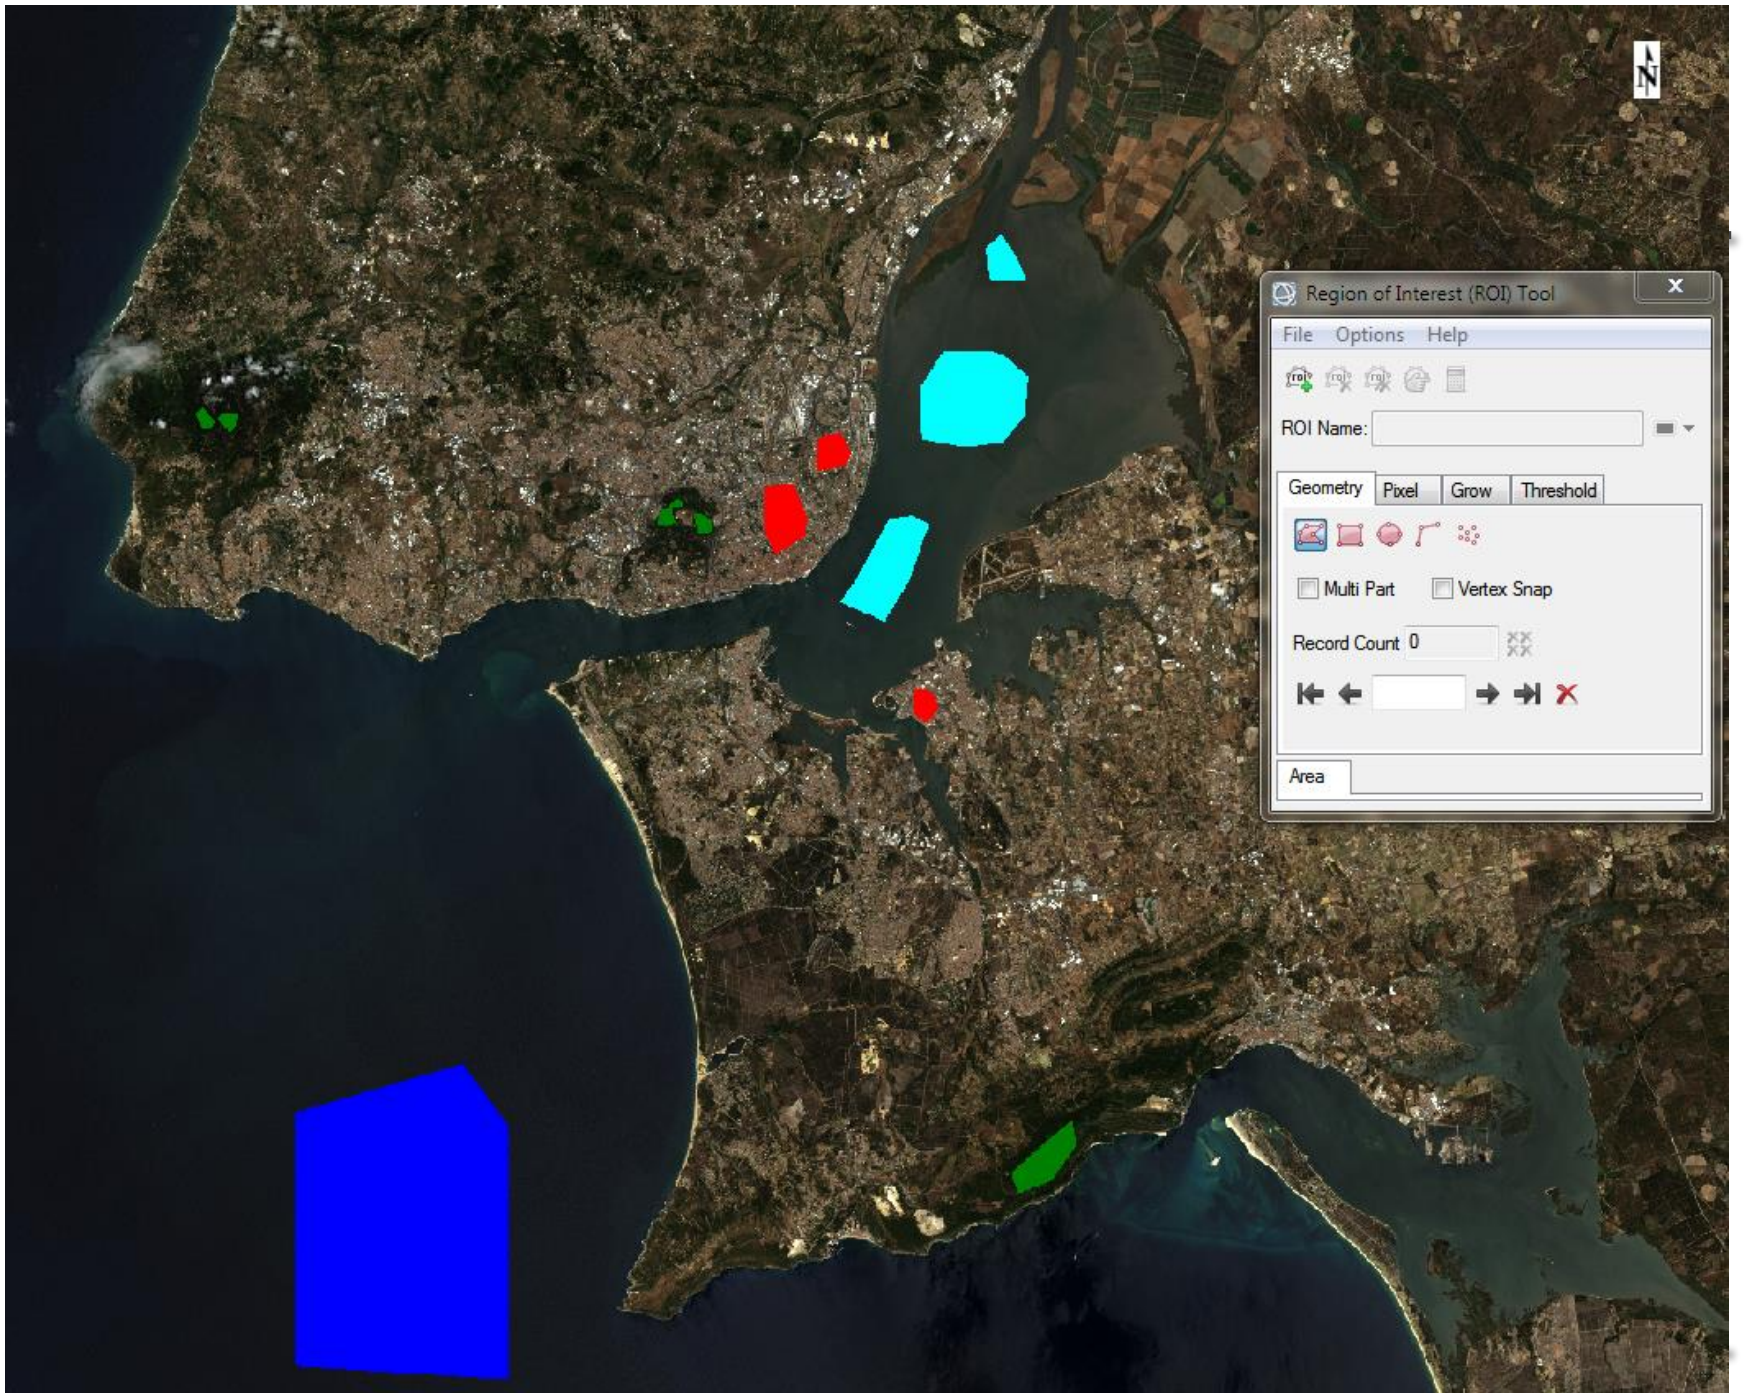
Cursor Value

Geo: 38°49'44.76"N, 8°56'46.26"W
Map: 504671.3452, 4297813.3594
MGRS: 29SNC0467197813
Proj: UTM, Zone 29 N, WGS-84

ndvi
File: 3592.8782, 3980.0547
Data: [-0.101973]

LC82040332013171LGN00_MTL_MultiSpectral
File: 3592.8782, 3980.0547
Data: [9996, 10697, 11052]





Region of Interest (ROI) Tool

File Options Help

ROI Name:

Geometry Pixel Grow Threshold


Multi Part Vertex Snap

Record Count 0

Area




Spectral Reflectance



Import Export Options

Histograms: LC82040332013171LGN00_MTL.txt




Legend for Band 2:

- Histogram: Band 2: urbano
- Histogram: Band 2: agua-estuario
- Histogram: Band 2: agua

Import Export Options

Histograms: LC82040332013171LGN00_MTL.txt




Legend for Band 3:

- Histogram: Band 3: urbano
- Histogram: Band 3: agua-estuario
- Histogram: Band 3: agua
- Histogram: Band 3: vegetacao

Import Export Options

Histograms: LC82040332013171LGN00_MTL.txt




Legend for Band 4:

- Histogram: Band 4: urbano
- Histogram: Band 4: agua-estuario
- Histogram: Band 4: agua
- Histogram: Band 4: vegetacao

Import Export Options

Histograms: LC82040332013171LGN00_MTL.txt

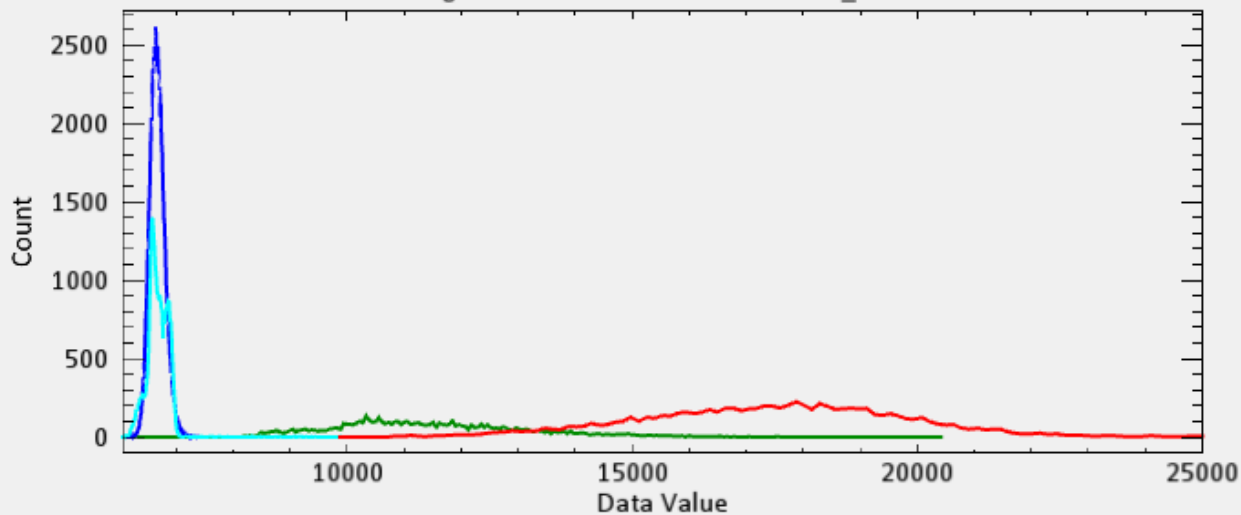


Legend for Band 5:

- Histogram: Band 5: urbano
- Histogram: Band 5: agua-estuario
- Histogram: Band 5: agua
- Histogram: Band 5: vegetacao

Import Export Options

Histograms: LC82040332013171LGN00_MTL.txt



Legend for Band 6:


- Histogram: Band 6: urbano
- Histogram: Band 6: agua-estuario
- Histogram: Band 6: agua
- Histogram: Band 6: vegetacao

General Curve

X Axis Min Range	6067
X Axis Max Range	25000
Y Axis Min Range	-98.137503899634
Y Axis Max Range	2715.1375038996
Font Name	Calibri
Font Size	12

X: Data Value Y: Data Value

Histograms: LC82040332013171LGN00_MTL.txt




Água Oceano

X: Data Value Y: Data Value

- Histogram: Band 1
- Histogram: Band 2
- Histogram: Band 3
- Histogram: Band 4
- Histogram: Band 5
- Histogram: Band 6
- Histogram: Band 7

General		Curve
X Axis Min Range	5928	
X Axis Max Range	12604	
Y Axis Min Range	-394.23751566559	
Y Axis Max Range	10907.237515666	
Font Name	Calibri	
Font Size	12	

Histograms: LC82040332013171LGN00_MTL.txt



Vegetação

X: Data Value Y: Data Value

- Histogram: Band 1
- Histogram: Band 2
- Histogram: Band 3
- Histogram: Band 4
- Histogram: Band 5
- Histogram: Band 6
- Histogram: Band 7

General		Curve
X Axis Min Range	5851	
X Axis Max Range	23912	
Y Axis Min Range	-7.0125002786517	
Y Axis Max Range	194.01250027865	
Font Name	Calibri	
Font Size	12	

Image Classification

A classificação de imagem

Is related with the assignment of the pixels to specific spectral class using the available spectral information.

This operation can be viewed as a mapping function

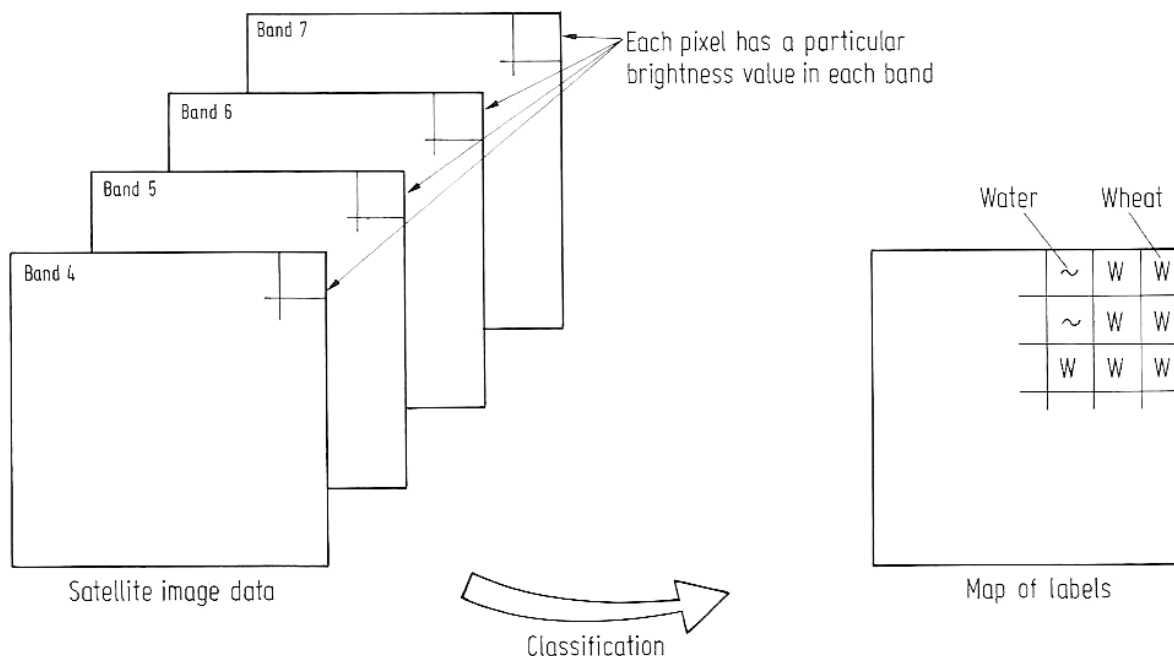


Image Classification

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

UnSupervised

(clustering)

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

Supervised

Training areas

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

Parametric

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

Non-parametric

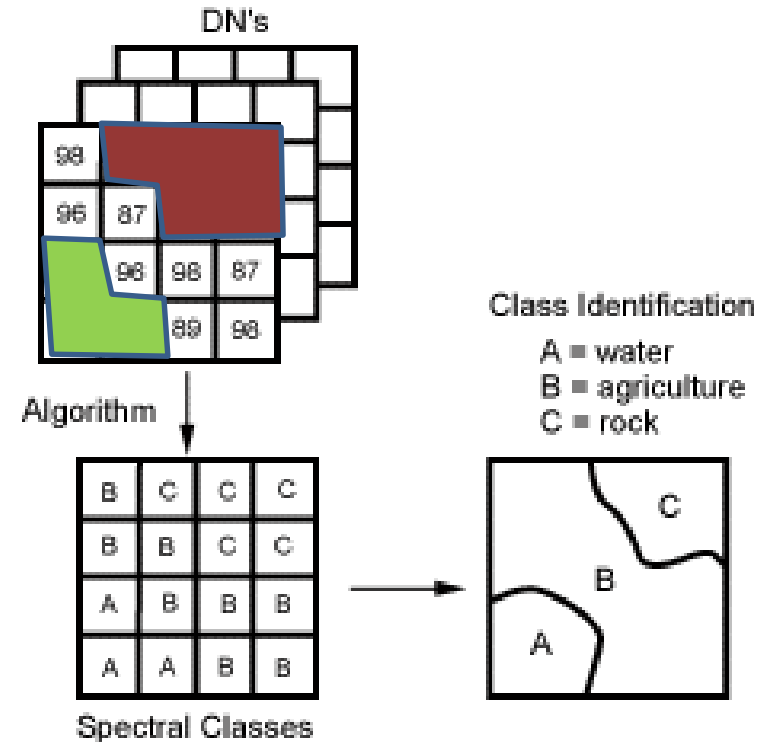
ISOData
K-Means
Aprendizagem automática

Unsupervised methods

Não é necessário ter um conhecimento prévio do terreno, nem ter dados treino.


Este método baseia-se em algoritmos que analisam todos os pixéis e formam conjuntos de pixéis (os chamados *cluster* ou padrões) apenas olhando ao valores dos pixéis.

Em geral o utilizador pode escolher alguns parâmetros como o numero máximo de padrões ou o numero mínimo de pixéis que é preciso para formar um *cluster*.



Unsupervised method– K-Means

NDWI temporal variability




Band 1

Two bands / 3 classes

Band 2

NDWI temporal mean






Ciências
ULisboa

Unsupervised method– K-Means

Blue: water
Red: Land
Green: intertidal



Unsupervised method– K-Means

K-Means

Processo iterativo no qual são definidos o número M de classes e calculados valores médios para M classes distribuídas aleatoriamente no espaço e depois agregados iterativamente os restantes pixels a essas classes usando a medida da mínima distância.

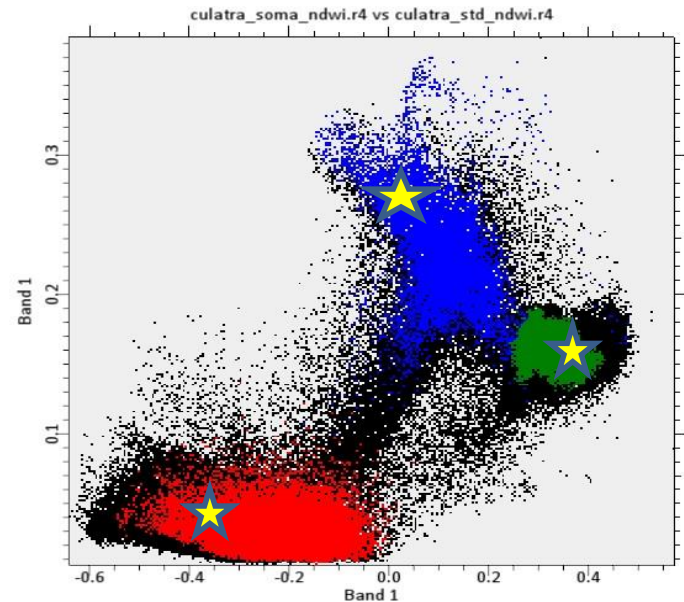
Cada iteração recalcula a média e reclassifica os pixéis relativamente à nova média

Todos os pixéis são classificados na classe mais próxima a menos que um limite seja especificado

O processo é continuado até que o numero máximo de iterações seja atingido

Algoritmo K-Means

1. Selecionar k pontos como centróides iniciais
2. Formar k clusters associando cada objecto ao seu centróide mais próximo
3. Recalcular o centróide de cada cluster
4. Até que os centróides não apresentem mudanças




Centróide = centro de gravidade do cluster

Coordenada i = média aritmética das coordenadas i de seus objectos constituintes.

Algoritmo K-means


Exemplo K = 3



2ª Iteração



Banda 1 (media do NDWI) / banda 2 (Std do NDWI)



The background image is a grayscale aerial photograph of a river delta, showing a complex network of channels and distributaries. A north arrow is visible in the top right corner of the image.

K-Means Parameters

Number of Classes

Change Threshold % (0-100)

Maximum Iterations


Maximum Stdev From Mean

Maximum Distance Error

Output Result to File Memory

Enter Output Filename

Parametros
k-means





Ciências
ULisboa


K-Means unsupervised classification



Unsupervised classification: ISODATA

ISODATA (*Iterative Self-Organizing Data Analysis Techniques*)


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





Ciências
ULisboa

ISODATA unsupervised classification



Isodata unsupervised
classification

Five classes

Supervised Classification

Passos na classificação supervisionada

1. Escolher a legenda

Spectral Classes

Escolher os tipos de cobertura de solo nos quais a imagem será segmentada. Estas são as classes de informação e podem ser: água, região urbana, floresta, pinhal, etc..

2. Escolher os pixéis representativos de cada classe legenda

Sample data
Training data set

Estes pixéis são designados por **dados treino**. Os conjuntos de treino podem ser obtidos por visitas aos locais, mapas, fotografia aérea ou fotointerpretação de uma composição colorida dos dados imagem.



Ciências
ULisboa

Maximum Likelihood Classification



Supervised Classification

3. Usar os dados treino para estimar os parâmetros de um determinado algoritmo de classificação

Estes parâmetros serão as propriedades do modelo de probabilidades usado ou serão as equações que definem as partições no espaço multiespectral.

Os parâmetros para uma dada classe é muitas vezes referido como **assinatura** dessa classe.

4. Classificar

Classificar cada pixel da imagem numa das classes definidas previamente (ponto 1) usando o classificador treinado. Todos os pixels são classificados.

5. Calcular a tabela de confusão

Produzir a tabela de contingência que resume os resultados da classificação.

(Confusion table)

Bayes Classification

Representemos as classes espectrais de uma imagem por:

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

E representemos os pixéis pelo vector \mathbf{x} :

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

Em que x_1, x_2, \dots, x_N é o DN do pixel \mathbf{x} nas bandas 1 a N

Classificação de Bayes

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

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

Probabilidade de ser classe w_i dada a posição \mathbf{x}

A classificação é feita de modo que:

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

Decision Rule

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

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

Em que $p(w_i)$ é a probabilidade da classe w_i ocorrer na imagem. Se por exemplo 20% dos pixels de uma imagem pertencem à classe espectral w_i então $p(w_i) = 0.2$.

$p(\mathbf{x})$ é a probabilidade de encontrar um pixel de qualquer classe na posição \mathbf{x} . O valor de $p(\mathbf{x})$ é dado por:

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

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

Decision Rule

A regra de classificação pode ser escrita como:

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

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

Por conveniência matemática definimos

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

Então a regra fica simplificada

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

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

Normal multivariate classes

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

Vamos assumir que para N bandas:

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

$$f_{\sigma}(x; \mu) = \frac{1}{\sqrt{2\pi}|\sigma|} e^{-(x-\mu)^2/2\sigma^2}$$

Em que \mathbf{m} e Σ são o vector da média e a matriz covariância dos dados da classe w_i .

Usando a função discriminante resulta que o termo $-N/2 \ln(2\pi)$ é comum a todos os $g_i(x)$ e por isso não é discriminativo e será ignorado.

Normal multivariate classes

A função discriminante para classificação de máxima verosimilhança é então dada por:



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

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

$$g_i(x) = -\ln |\Sigma_i| - (x - m_i)^t \Sigma_i^{-1} (x - m_i)$$

Maximum Likelihood discriminant function

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



Isto pode acontecer se as classes são sobrepostas ou sabendo da existência de outras classes não dispomos de dados terreno suficientes para estimar os parâmetros da sua distribuição

Na prática, são aplicados limiares (thresholds) à função discriminante e não às distribuições de probabilidade (uma vez que estas não são de facto calculadas). A regra de decisão fica:

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

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

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

Ou, equivalentemente:

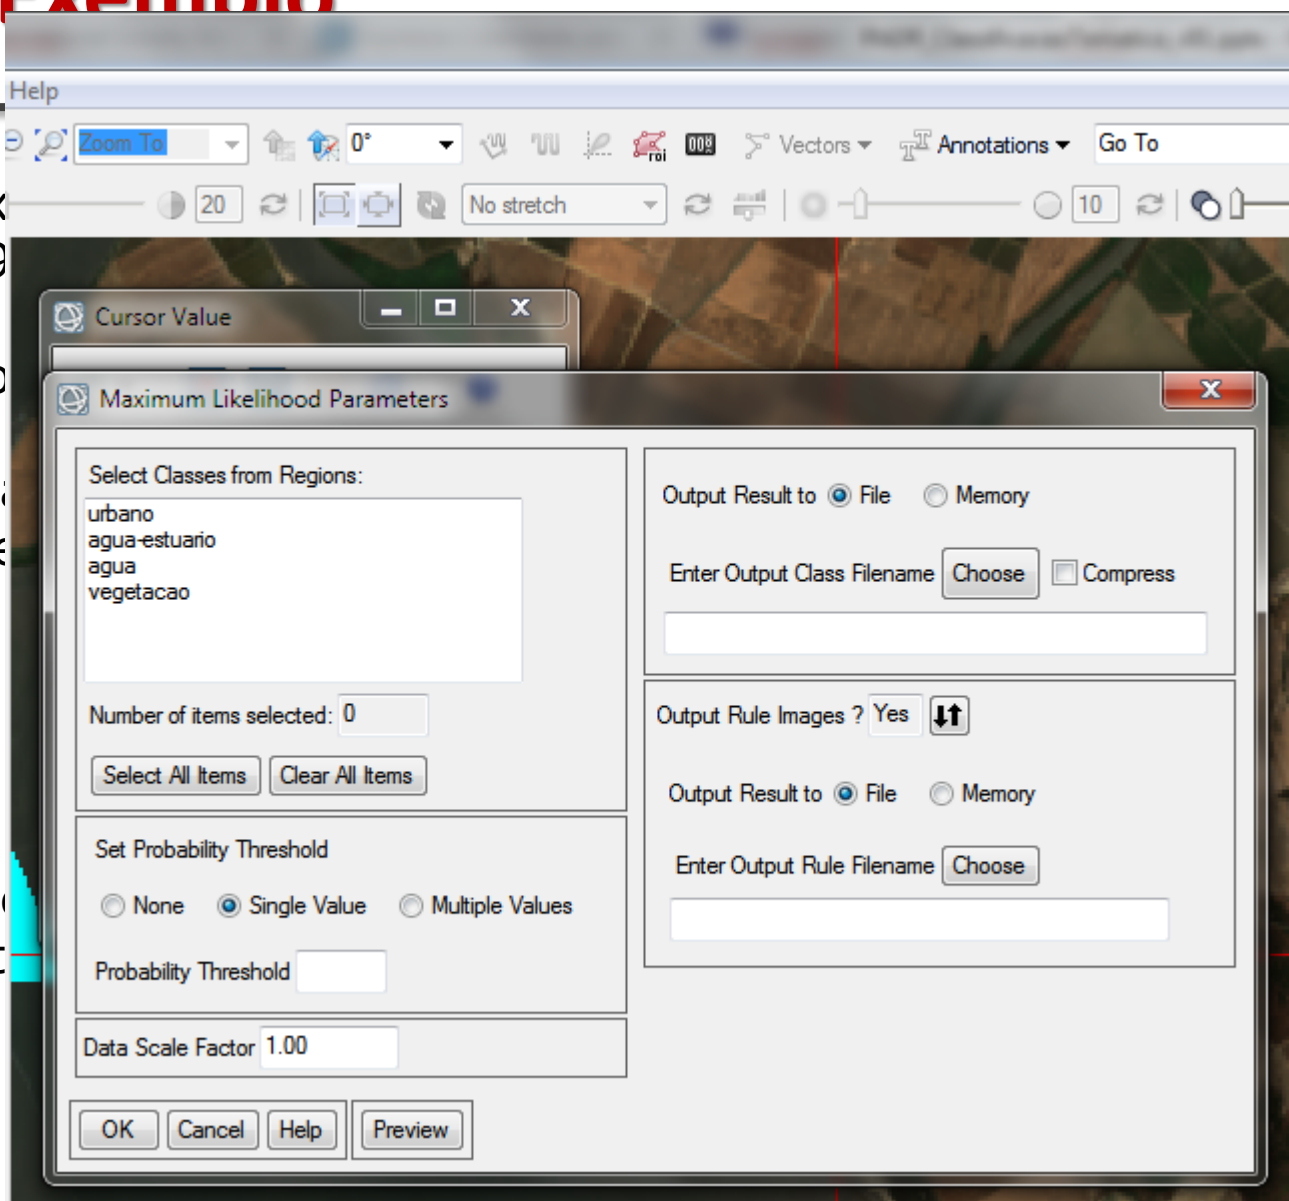
$$(x - m_i)^t \Sigma_i^{-1} (x - m_i) < \underbrace{-2T_i + 2 \ln p(w_i) - \ln |\Sigma_i|}_{\sim \chi^2}$$

Exemplo

Como ex
tal que 9
ou seja,
rejeitado

Da tabel
liberdade

Que pod
e da dist



das
dos,



ral i



Ciências
ULisboa

Maximum Likelihood Classification





x: Data Value y: Data Value

x: Data Value y: Data Value

Locate Stat Report Precision


Locate Stat Report Precision

agua (aa)					
Basic Stats	Min	Max	Mean	StdDev	
Band 1	193	1027	749.51	135.02	
Band 2	291	1177	895.94	147.54	
Band 3	440	1501	927.05	148.40	
Band 4	624	1753	1087.74	145.36	
Band 5	839	1925	1258.07	143.22	
Band 6	1107	2018	1489.62	127.55	
Histogram	DN	Count	Total	Percent	Acc Pct
Band 1	193 - 196	30	30	0.05	0.05
Binsize=4	197 - 200	125	155	0.22	0.28
	201 - 204	246	401	0.44	0.71
	205 - 208	288	689	0.51	1.23
	209 - 212	260	949	0.46	1.69
	213 - 216	160	1109	0.28	1.98
	217 - 220	188	1297	0.33	2.31
	221 - 224	84	1381	0.15	2.46
	225 - 228	105	1486	0.19	2.65
	229 - 232	76	1562	0.14	2.78

intertidal (aa)					
Basic Stats	Min	Max	Mean	StdDev	
Band 1	332	3107	698.89	297.80	
Band 2	536	3737	1182.28	455.11	
Band 3	692	3654	1676.95	492.43	
Band 4	698	3218	1275.94	467.87	
Band 5	846	2527	1310.99	291.09	
Band 6	991	2010	1277.22	149.54	
Histogram	DN	Count	Total	Percent	Acc Pct
Band 1	332 - 342	9	9	0.03	0.03
Binsize=11	343 - 353	4	13	0.02	0.05
	354 - 364	8	21	0.03	0.08
	365 - 375	24	45	0.09	0.17
	376 - 386	28	73	0.11	0.28
	387 - 397	16	89	0.06	0.35
	398 - 408	49	138	0.19	0.54
	409 - 419	125	263	0.49	1.02
	420 - 430	179	442	0.70	1.72
	431 - 441	241	683	0.94	2.66
	442 - 452	463	1146	1.80	4.46

Water


Intertidal



X: Data Value Y: Data Va

terra (aa)					
Basic Stats	Min	Max	Mean	StdDev	
Band 1	930	12207	2346.32	480.61	
Band 2	1395	9494	3126.68	479.18	
Band 3	1101	5307	2689.03	448.60	
Band 4	909	5512	2093.00	522.50	
Band 5	1014	5520	1788.89	401.38	
Band 6	1061	5500	1713.21	346.06	
Histogram	DN	Count	Total	Percent	Acc Pct
Band 1	930 - 974	20	20	0.05	0.05
Binsize=45	975 - 1019	16	36	0.04	0.09
	1020 - 1064	40	76	0.09	0.18
	1065 - 1109	28	104	0.07	0.25
	1110 - 1154	20	124	0.05	0.29
	1155 - 1199	52	176	0.12	0.42
	1200 - 1244	59	235	0.14	0.56
	1245 - 1289	76	311	0.18	0.74
	1290 - 1334	115	426	0.27	1.01
	1335 - 1379	140	566	0.33	1.34

Land



X: Data Value Y: Data Value

areia					
Basic Stats	Min	Max	Mean	StdDev	
Band 1	1879	4823	3622.46	656.10	
Band 2	2672	5512	4465.34	572.53	
Band 3	2316	4459	3458.32	519.28	
Band 4	1283	4109	2917.51	628.17	
Band 5	1244	3406	2430.99	493.78	
Band 6	1250	2811	2094.44	351.57	
Histogram	DN	Count	Total	Percent	Acc Pct
Band 1	1879 - 1890	4	4	0.02	0.02
Binsize=12	1891 - 1902	0	4	0.00	0.02
	1903 - 1914	0	4	0.00	0.02
	1915 - 1926	0	4	0.00	0.02
	1927 - 1938	4	8	0.02	0.04
	1939 - 1950	4	12	0.02	0.06
	1951 - 1962	0	12	0.00	0.06
	1963 - 1974	0	12	0.00	0.06
	1975 - 1986	0	12	0.00	0.06
	1987 - 1998	0	12	0.00	0.06
	1999 - 2010	0	12	0.00	0.06

Sand (beach)




Maximum Likelihood Classification



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

Exemplo

Por simplicidade consideremos uma imagem com duas bandas.



Foram recolhidos dados treino para 6 classes homogéneas. Todos os pontos da mesma cor representam as componentes do vector das amostras obtidas usando os *dados treino* referidos a um padrão.




Exemplo

Pretendem-se classificar os pontos 1,2,3

- urbano
- areia
- milho
- feno
- floresta
- agua

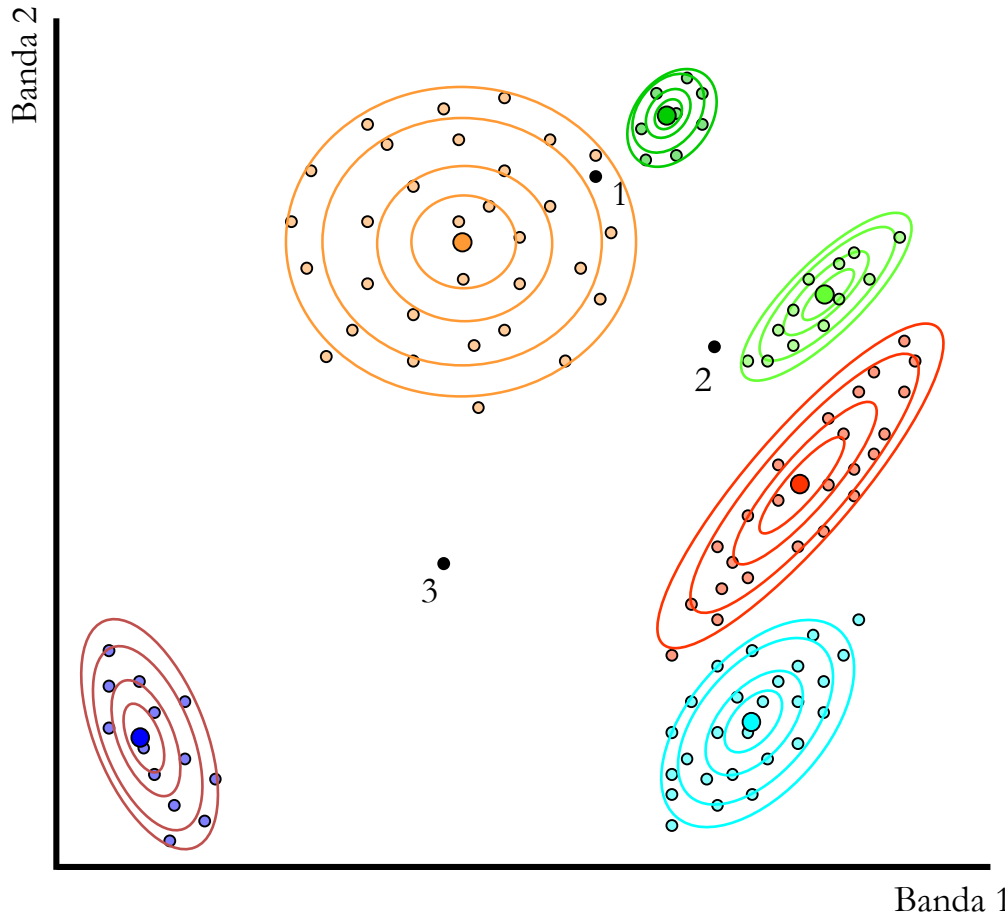
São representados os valores médios de cada classe (círculos maiores).





Maximum Likelihood

- urbano
- areia
- milho
- feno
- floresta
- agua




Classificação
1: urbano
2: não classificado
3: não classificado

Exemplo

Determine o vetor da média, a função covariância e correlação


Conjunto de pixels de uma classe



Banda A	Banda B
1	2
2	1
4	1
5	2
4	4
2	4

Exemplo

Determine o vetor da média, a função covariância e correlação



Banda A	Banda B
2	2
2	3
4	3
3	4
5	4
5	5

Maximum Likelihood classification

Classe 1		Classe 2		Classe 3	
Banda A	Banda B	Banda A	Banda B	Banda A	Banda B
16	13	8	8	19	6
18	13	9	7	19	3
20	13	6	7	17	8
11	12	8	6	17	1
17	12	5	5	16	4
8	11	7	5	14	5
14	11	4	4	13	8
10	10	6	3	13	1
4	9	4	2	11	6
7	9	3	2	11	3

Determine a função discriminante para o classificador da máxima verosimilhança

e classifique os pixéis:

P1 (5,9)

P2 (9,8)

P3(15, 9)

Ver matlab: mv01.m

Minimum Distance

A qualidade do classificador da máxima verosimilhança depende da exactidão na determinação do vector da média e da função covariância para cada classe espectral.

Esta determinação é dependente de ter um suficiente número de dados treino para cada uma dessas classes.

Quando não dispomos de um numero suficiente de dados para treino é preferível usar um classificador que não requiera uma função covariância mas que dependa apenas da posição média das classes espectrais. A média é sempre mais bem determinada que a covariância.



O classificador da distancia mínima satisfaz este requisito.

(distancia mínima ao valor médio da classe)

Classificador Distância Mínima

Assumindo m_i ($i=1,..M$) como o valor médio de cada classe, determinado de dados treino, e \mathbf{x} a posição do pixel a ser classificado.

Calculamos o conjunto de distâncias euclidianas:

$$d(\mathbf{x}, m_i)^2 = (\mathbf{x}-m_i)^t (\mathbf{x}-m_i) \quad i=1,..M$$

Expandindo o produto dá:


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

A classificação é realizada na base de que:

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



Classificador Distância Mínima




Desvantagem: a associação dum pixel ao padrão mais perto poderia introduzir efeitos desagradáveis como por exemplo associar um pixel ao padrão mais perto mas que é bastante “afastado” e portanto com um valor radiométrico (DN) bastante diferente.



Ciências
ULisboa

Minimum Distance






Maximum Likelihood Classification




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



Classificador Paralelepípedo


O classificador do paralelepípedo é treinado por análise dos histogramas de componentes espectrais com base nos dados treino



Histograma das componentes bidimensionais de dados treino corresponde a uma única classe espectral. Os limites inferiores e superiores são identificados como os vértices e um paralelepípedo.



Parallelepiped Classifier



Desvantagem: nem sempre é possível classificar um pixel de maneira unívoca.

Mahalanobis Classifier

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

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

Este é o classificador **distância Mahalanobis**. (raiz quadrada da equação anterior)

Assumindo um constrangimento adicional em que $\Sigma = \sigma I$ o classificador Mahalanobis reduz-se a um classificador de distância mínima.

A vantagem do classificador de Mahalanobis sobre a máxima verosimilhança é que é mais rápido e mantém algum grau na sensibilidade à direcção através da função covariância Σ que pode ser uma covariância média de todas as classes ou um modelo.

Exemplo (distancia mínima)

Classe 1		Classe 2		Classe 3	
Banda A	Banda B	Banda A	Banda B	Banda A	Banda B
16	13	8	8	19	6
18	13	9	7	19	3
20	13	6	7	17	8
11	12	8	6	17	1
17	12	5	5	16	4
8	11	7	5	14	5
14	11	4	4	13	8
10	10	6	3	13	1
4	9	4	2	11	6
7	9	3	2	11	3

Determine a função discriminante para o classificador da distancia mínima

e classifique os pixels:

P1 (5,9)

P2 (9,8)

P3(15, 9)

Exemplo (Paralelepípedo)

Classe 1		Classe 2		Classe 3	
Banda A	Banda B	Banda A	Banda B	Banda A	Banda B
16	13	8	8	19	6
18	13	9	7	19	3
20	13	6	7	17	8
11	12	8	6	17	1
17	12	5	5	16	4
8	11	7	5	14	5
14	11	4	4	13	8
10	10	6	3	13	1
4	9	4	2	11	6
7	9	3	2	11	3

Diga os limites do classificador paralelepípedo

e classifique os pixels:

P1 (5,9)

P2 (9,8)

P3(15, 9)

P4 (3,7)



Algoritmos de Classificação do ENVI



Toolbox

Search the toolbox

/Classification/Supervised Classification

- [-] Favorites
- [+] Anomaly Detection
- [+] Band Algebra
- [+] Change Detection
- [-] Classification
 - Classification Workflow
 - [+] Decision Tree
 - Endmember Collection
 - [+] Post Classification
 - Raster Color Slices
 - [-] Supervised Classification
 - Adaptive Coherence Estimator Classification
 - Binary Encoding Classification
 - Constrained Energy Minimization Classification
 - Mahalanobis Distance Classification
 - Maximum Likelihood Classification
 - Minimum Distance Classification
 - Neural Net Classification
 - Orthogonal Subspace Projection Classification
 - Parallelepiped Classification
 - Spectral Angle Mapper Classification
 - Spectral Information Divergence Classification
 - Support Vector Machine Classification
 - [+] Unsupervised Classification
- [+] Feature Extraction



Classification accuracy assessment

A avaliação baseia-se na tabela de contingências que compara, numa amostra de pixéis, o resultado da classificação efetuada pelo computador e a verdadeira ocupação do solo obtida por um outro qualquer processo independente (fotografias, imagens, mapas).

Há dois possíveis tipos de erro:

Omissão

Pixéis que deveriam ser atribuídos a uma classe e foram erradamente atribuídos a outra classe. Por exemplo um pixel que pertence à classe “água” e não foi atribuído à classe água.

Comissão

Pixéis atribuídos a uma classe e que deveriam ser atribuídos a outra classe. Por exemplo um pixel classificado como “água” na realidade pertence a uma das outras três classes (solo nu, floresta ou solo cultivado).

Classification accuracy assessment

Classes conhecidas → j

Classificação ↑ i

	Água	Solo nu	Solo cultivado	Floresta
Água	187	40	7	0
Solo nu	11	246	12	9
Solo cultivado	0	21	239	39
Floresta	0	0	140	49

E_{ii} é o número de pixéis que foram correctamente classificados

E_{ij} é o número de pixéis que é conhecido pertencer à classe j, mas que foram classificados pelo classificador como pertencentes à classe i.

(p.e. 11 pixéis de água foram classificados como solo nu)

Classification accuracy assessment

Ao longo da diagonal do quadro de contingências está o número de pixéis correctamente classificados para cada uma das quatro classes (padrões) deste exemplo.

Classes conhecidas → j

	Água	Solo nu	Solo cultivado	Floresta
↑ Classificação i	Água	Solo nu	Solo cultivado	Floresta
	187	40	7	0
	11	246	12	9
	0	21	239	39
	0	0	140	49

A linha i -ésima fornece o número dos pixéis que na imagem classificadas são associados à classe i -ésima.

A coluna j -ésima fornece o número de todos os pixéis que no mapa de referência são associados à classe j -ésima.



Classification accuracy assessment

A percentagem de pixéis correctamente classificados é dada por

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

Classes conhecidas → j

	Água	Solo nu	Solo cultivado	Floresta
Classificação ↑ i				
Água	187	40	7	0
Solo nu	11	246	12	9
Solo cultivado	0	21	239	39
Floresta	0	0	140	49

No exemplo do quadro de contingências em cima a direita, a percentagem de pixéis correctamente classificados é 70.6%.

$$N = 4$$

$$\text{Soma } E_{ii} = 187 + 246 + 239 + 49 = 672$$

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

User accuracy / Precision

No que diz respeito o utilizador é definida a **exatidão do utilizador** como

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

Água : 79.9%
 Solo Nu : 88.5%;
 Solo Cultivado : 79.9%
 Floresta: 25.9%

Classes conhecidas → j

	Água	Solo nu	Solo cultivado	Floresta			
Classificação ↑ i	Água	187	40	7	0	79.9	20.1
	Solo nu	11	246	12	9	88.5	11.5
	Solo cultivado	0	21	239	39	79.9	20.1
	Floresta	0	0	140	49	25.9	74.1

Comissão

A exatidão do utilizador de 79.9% para a água diz ao utilizador que 79.9% dos pixéis classificados como água são na realidade associados a pontos sobre a superfície terrestre realmente cobertos de água.

Para o utilizador é importante o que está classificado correctamente!

Producer accuracy / Recall / Revocação

No que diz respeito o produtor é definida a **exatidão do produtor** como

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

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

		Classes conhecidas → j			
		Água	Solo nu	Solo cultivado	Floresta
Classificação ↑ i	Água	187	40	7	0
	Solo nu	11	246	12	9
	Solo cultivado	0	21	239	39
	Floresta	0	0	140	49
		94.4	80.1	60.1	50.5
		5.6	19.9	49.9	49.5

Omissão

A exatidão do produtor de 50.5% para a floresta diz ao produtor que apenas 50.5% da área de floresta (pixéis identificados como floresta) foi classificada como floresta.

Para o produtor é importante o que está no terreno e foi correctamente classificado!

F1-score

O *F1-score*, com valores entre 0 e 1, corresponde à média ponderada entre precisão e revocação, dando igual peso aos dois valores:

$$F1score = 2 * \frac{EU_i * EP_i}{EU_i + EP_i}$$

O *F1-score* é obtido para cada classe, sendo calculada a média aritmética simples para obter um valor único (*macro-averaged F1-score*). T

endo em conta o número de amostras de cada classe, considera-se mais interessante olhar para o *F1-score* ponderado (*weighted F1-score*).



Kappa coefficient

Por último, o coeficiente *Kappa* (k) é uma medida de concordância que dá ideia de quanto os valores observados se afastam dos esperados, fruto do acaso, ou seja, permite aferir o desempenho de um classificador que tem a conta a frequência de cada classe relativamente a outro que prevê aleatoriamente:

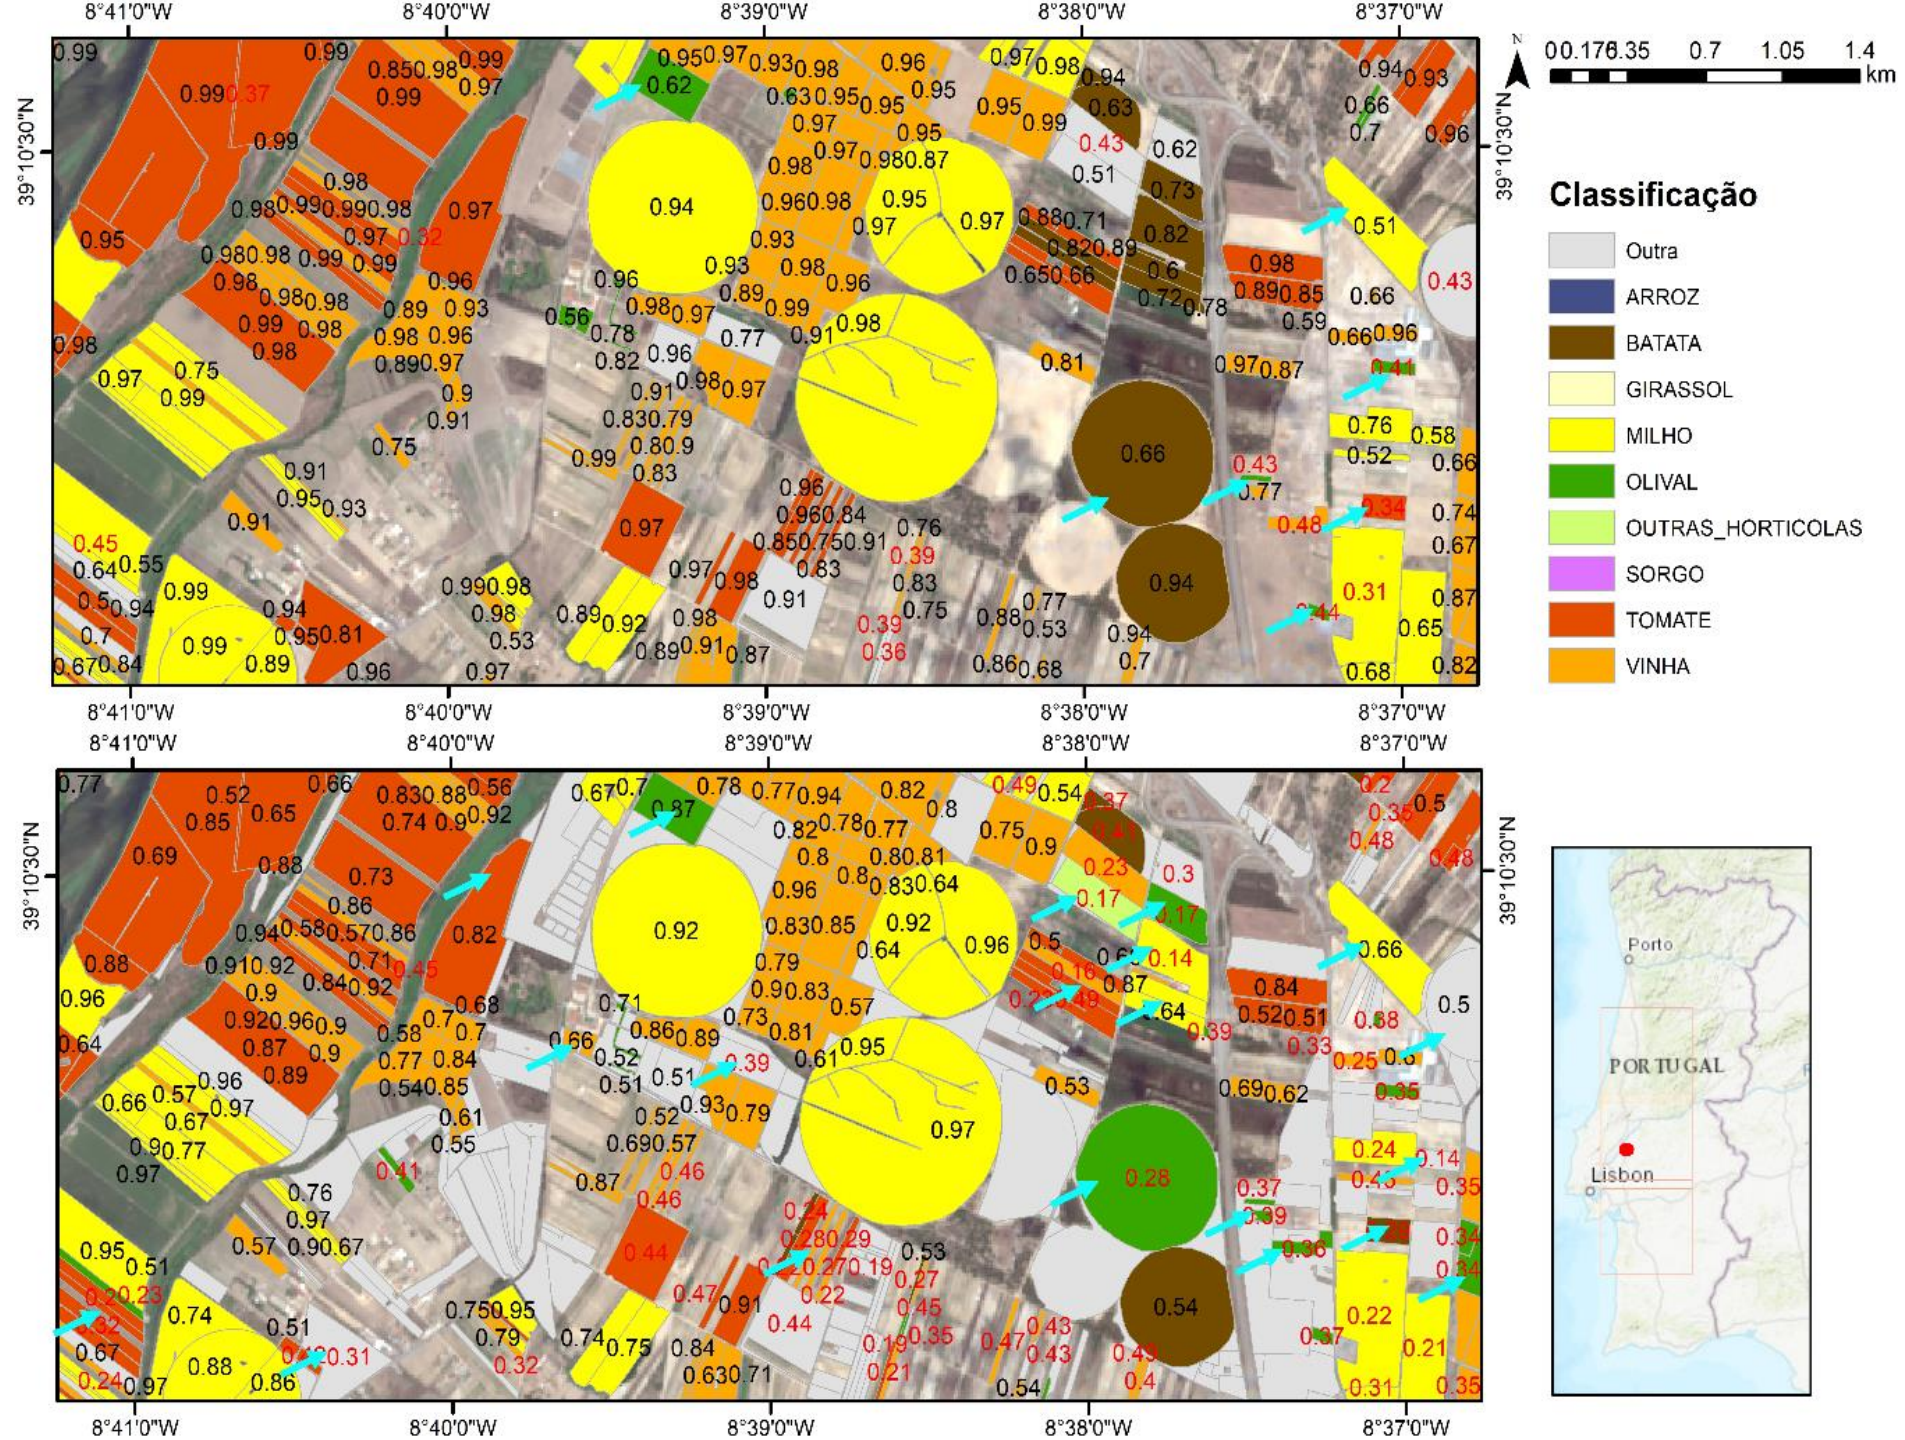
$$k = \frac{N \sum_{i=1}^r n_{ii} - \sum_{i=1}^r (G_i C_i)}{N^2 - \sum_{i=1}^r (G_i C_i)}$$

em que i é a classe; r é o número de classes; N é o número total de elementos classificados que estão a ser comparados à verdade no terreno; n_{ij} é o número de elementos pertencentes à classe i no terreno que também foram classificados como tal pelo modelo; C_i é o número total de elementos classificados pelo modelo como pertencendo a i ; e G_i é número total de elementos da classe i no terreno.

Kappa coefficient

Os valores do kappa são sempre iguais ou inferiores a 1, são interpretados da seguinte forma:

- valores < 0 indicam ausência de concordância, ou um desempenho muito fraco do modelo;
 - valores entre 0 e 0.20, indicam um desempenho fraco;
 - entre 0.21 e 0.40, um desempenho razoável;
 - entre 0.41 e 0.60, um desempenho moderado;
 - entre 0.61 e 0.80, um bom desempenho e,
 - entre 0.81 e 1, um desempenho quase perfeito (ou concordância total entre estimadores).
-





Matriz Confusão

	ABO	ARROZ	BAT	COUVE	FEIJAO	GIRASS	GRAO	MELAO	MILHO	OLIV	HORT	PIM	SORGO	TOM	VINHA	Total	Freq (%)	Revoc ação (%)	F1-score (%)
ABO	31	0	3	0	1	0	0	2	64	10	2	0	0	2	34	151	0.46	20.53	32.0
ARROZ	0	2929	0	0	0	0	0	0	39	15	0	0	2	0	1	2986	9.07	98.09	99.0
BAT	2	0	217	0	4	0	0	0	123	78	3	1	0	2	50	483	1.47	44.93	56.0
COUVE	0	0	6	34	3	1	0	1	26	6	3	0	0	5	10	95	0.29	35.79	51.0
FEIJAO	0	1	1	0	11	0	0	0	89	10	2	0	1	3	21	139	0.42	7.91	13.0
GIRASS	0	2	1	0	0	236	0	0	9	41	0	0	0	14	13	316	0.96	74.68	83.0
GRAO	0	1	7	0	0	1	29	0	3	48	0	0	0	0	9	98	0.3	29.59	45.0
MELAO	0	0	1	0	0	2	0	40	2	1	1	1	0	18	8	74	0.22	54.05	64.0
MILHO	2	12	17	0	6	1	0	0	5706	294	8	6	0	10	210	6274	19.06	90.95	89.0
OLIV	0	0	1	0	0	1	0	1	83	14235	3	0	1	0	592	14917	45.31	95.43	91.0
HORT	3	0	19	4	4	0	0	2	253	173	19	4	0	9	189	679	2.06	2.8	5.0
PIM	0	1	2	0	0	0	0	0	14	3	1	52	0	5	3	82	0.25	63.41	67.0
SORGO	0	3	1	0	0	3	0	0	64	32	0	0	54	1	27	185	0.56	29.19	44.0
TOM	0	1	2	0	0	1	0	0	11	4	0	1	0	585	9	614	1.87	95.28	90.0
VINHA	1	1	1	0	0	0	0	0	85	1407	1	0	0	1	4078	5577	16.94	73.12	75.0
Total	40	2955	294	39	30	250	30	51	6609	16401	43	74	58	679	5290	32920			
Precisão (%)	77.5	99.1	73.8	87.2	36.7	94.4	96.7	78.43	86.34	86.79	44.19	70.3	93.1	86.2	77.09	100	NA	NA	NA



Exatidão da classificação

