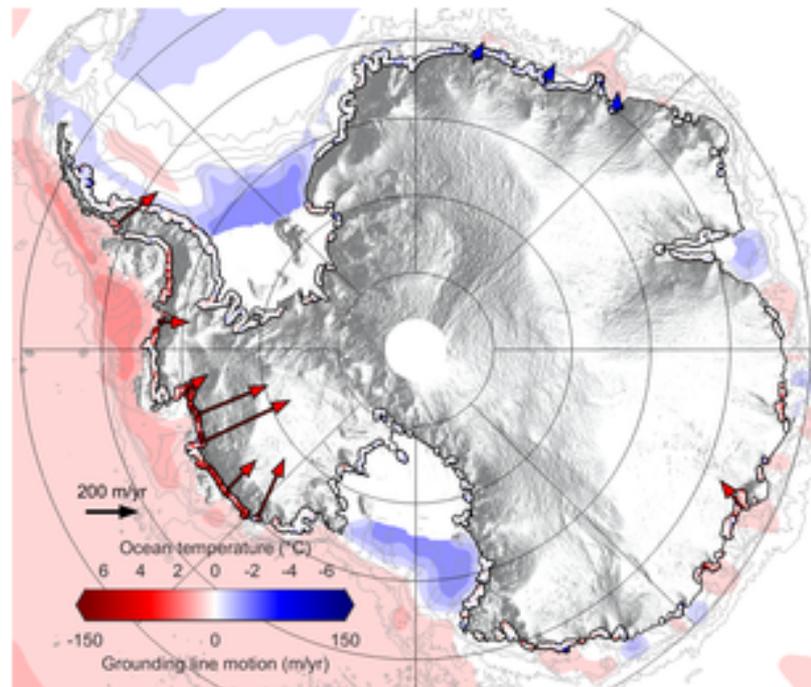


# PRINCIPIOS E APLICAÇÕES DA DETECÇÃO REMOTA



## ANTARCTICA LOSES GRIP



Shifting grounding lines

3 April 2018 ESA's CryoSat mission has revealed that, over the last seven years, Antarctica has lost an area of underwater ice the size of Greater London. This is because warm ocean water beneath the continent's floating margins is eating away at the ice attached to the seabed.

Most Antarctic glaciers flow straight into the ocean in deep submarine troughs. The place where their base leaves the seabed and begins to float is known as the grounding line.

These grounding lines typically lie a kilometre or more below sea level and are inaccessible even to submersibles, so remote methods for detecting them are extremely valuable.

A [paper](#) published today in *Nature Geoscience* describes how CryoSat was used to map grounding-line motion along 16 000 km of Antarctic coastline.

Research led by Hannes Konrad from the Centre for Polar Observation and Modelling at the UK's University of Leeds shows that between 2010 and 2017 the Southern Ocean melted 1463 sq km of underwater ice.

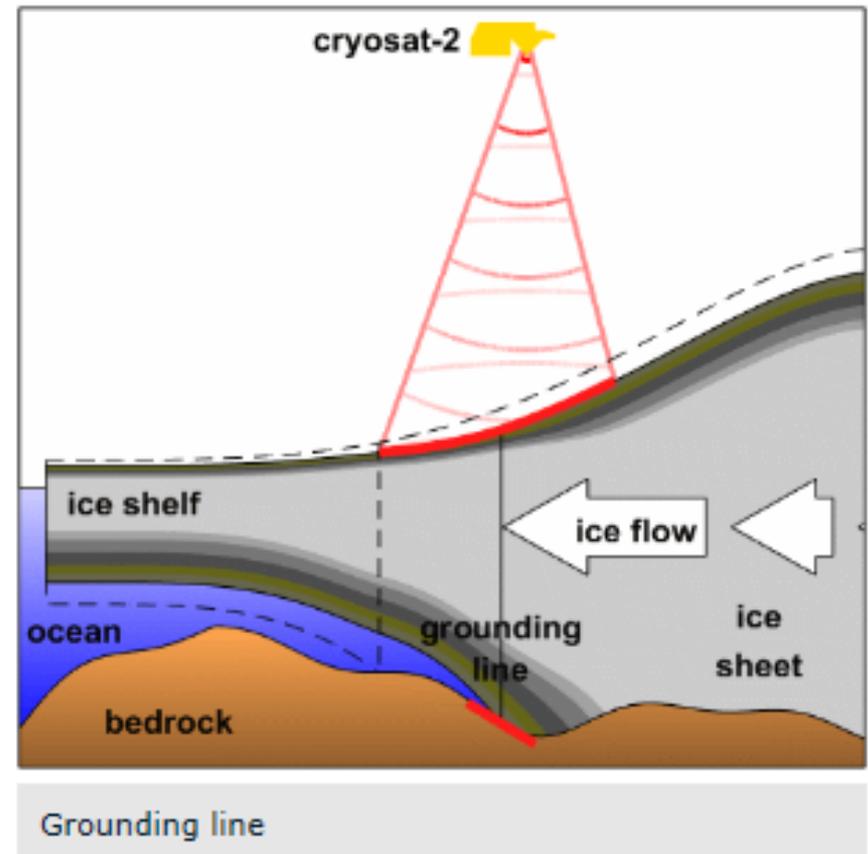
The team tracked the movement of Antarctica's grounding line thanks to CryoSat and has produced the first complete map showing how this submarine edge is losing its grip on the seafloor.

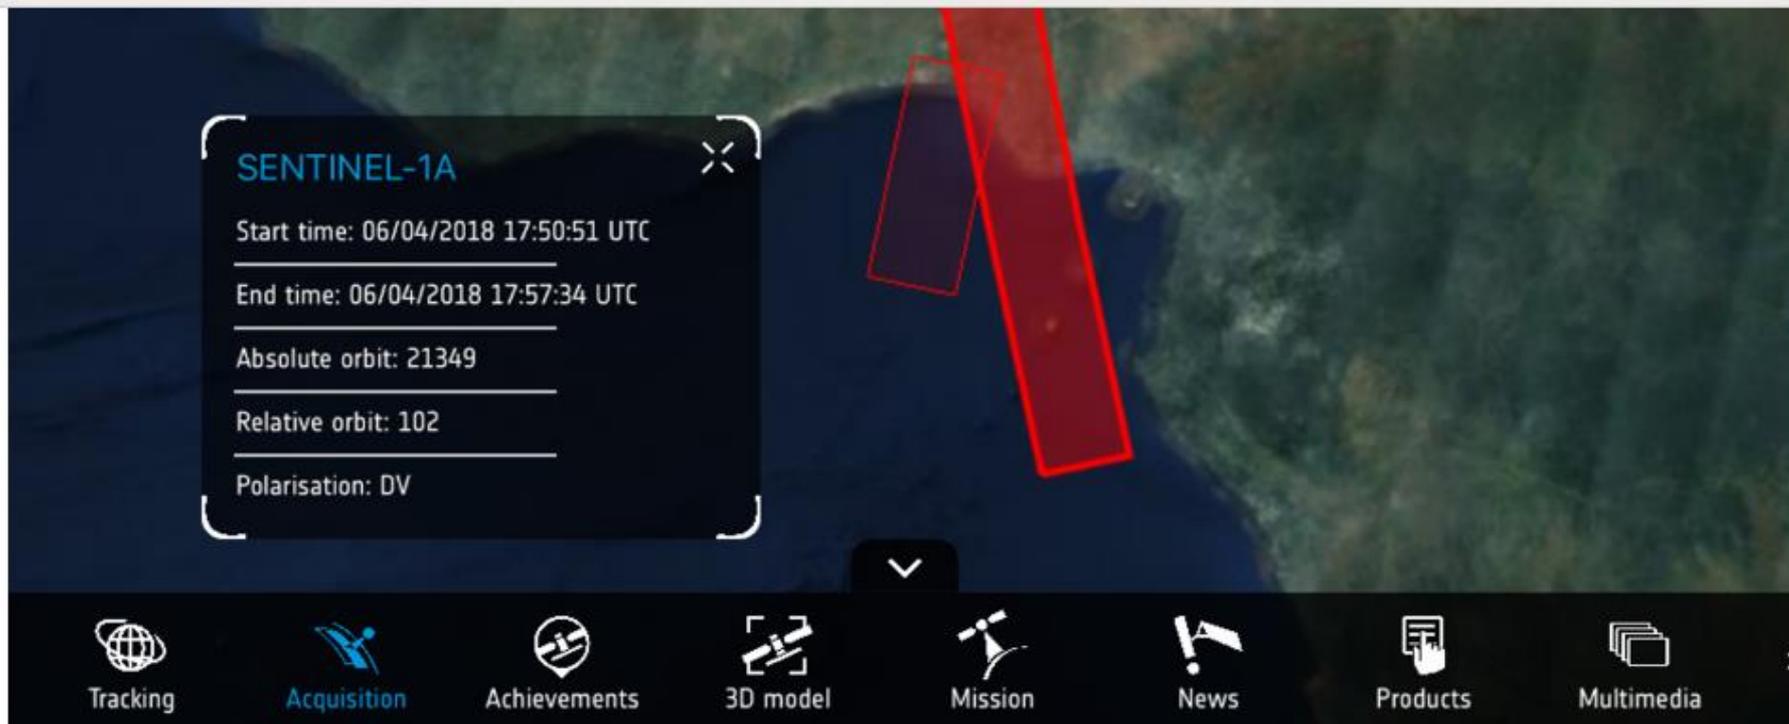
The biggest changes are seen in West Antarctica, where more than a fifth of the ice sheet has retreated across the seafloor faster than the pace of deglaciation since the last ice age.

Dr Konrad said, "Our study provides clear evidence that retreat is happening across the ice sheet due to ocean melting at its base, and not just at the few spots that have been mapped before now."

"This retreat has had a huge impact on inland glaciers, because releasing them from the seabed removes friction, causing them to speed up and contribute to global sea-level rise."

Although CryoSat is designed to measure changes





## AT YOUR FINGERTIPS

Download the latest version of the Sentinel App to your mobile device and learn more about Europe's flagship constellation of Earth observation satellites.

Developed by ESA and the European Commission, the Copernicus Sentinel App is a free App for iOS and Android mobile devices. It allows users to track the Sentinel satellites in orbit and see when and where they send their data back to Earth, either directly or by laser to the European Data Relay System. You can also set alerts to see when any of the Sentinels are flying overhead.

There is a 3D model of each satellite that you can explore to see where the scientific instruments and other key components are positioned. You can also learn about how these trailblazing missions are improving everyday lives and how they are helping us to understand our home planet.

Europe's Copernicus programme has been put in place to manage the environment and help respond to the challenges of global change. This innovative global monitoring programme, the largest ever conceived, offers a set of key information services for a wide range of practical applications. While the Sentinel satellite missions have been built specifically for Copernicus, their data are open and free to everyone.

The Copernicus Sentinel App is available at the [Apple App Store](#) and [Google Play](#).

*Credits: ESA*





## ESA INVESTIGATING DETECTION OF FLOATING PLASTIC LITTER FROM ORBIT



Ocean plastic

19 March 2018 The millions of tonnes of plastic ending up in the oceans every year are a global challenge. ESA is responding by looking at the detection of marine plastic litter from space, potentially charting its highest concentrations and understanding the gigantic scale of the problem.

We dump around 10 million tonnes of plastic in the oceans annually. Though most conspicuous along coastlines, plastic litter is also found out in the open ocean and from the equator to the pole – even frozen in polar ice.

Gradually broken down into micro-fragments by weathering and waves, it is not only endangering marine animals but it is also entering the global food chain, with unknown long-term consequences for animal life and our own health.

“Indirect measurements from space are already used to get to grips with the marine plastic litter problem,” explains ESA’s Paolo Corradi, overseeing the project.

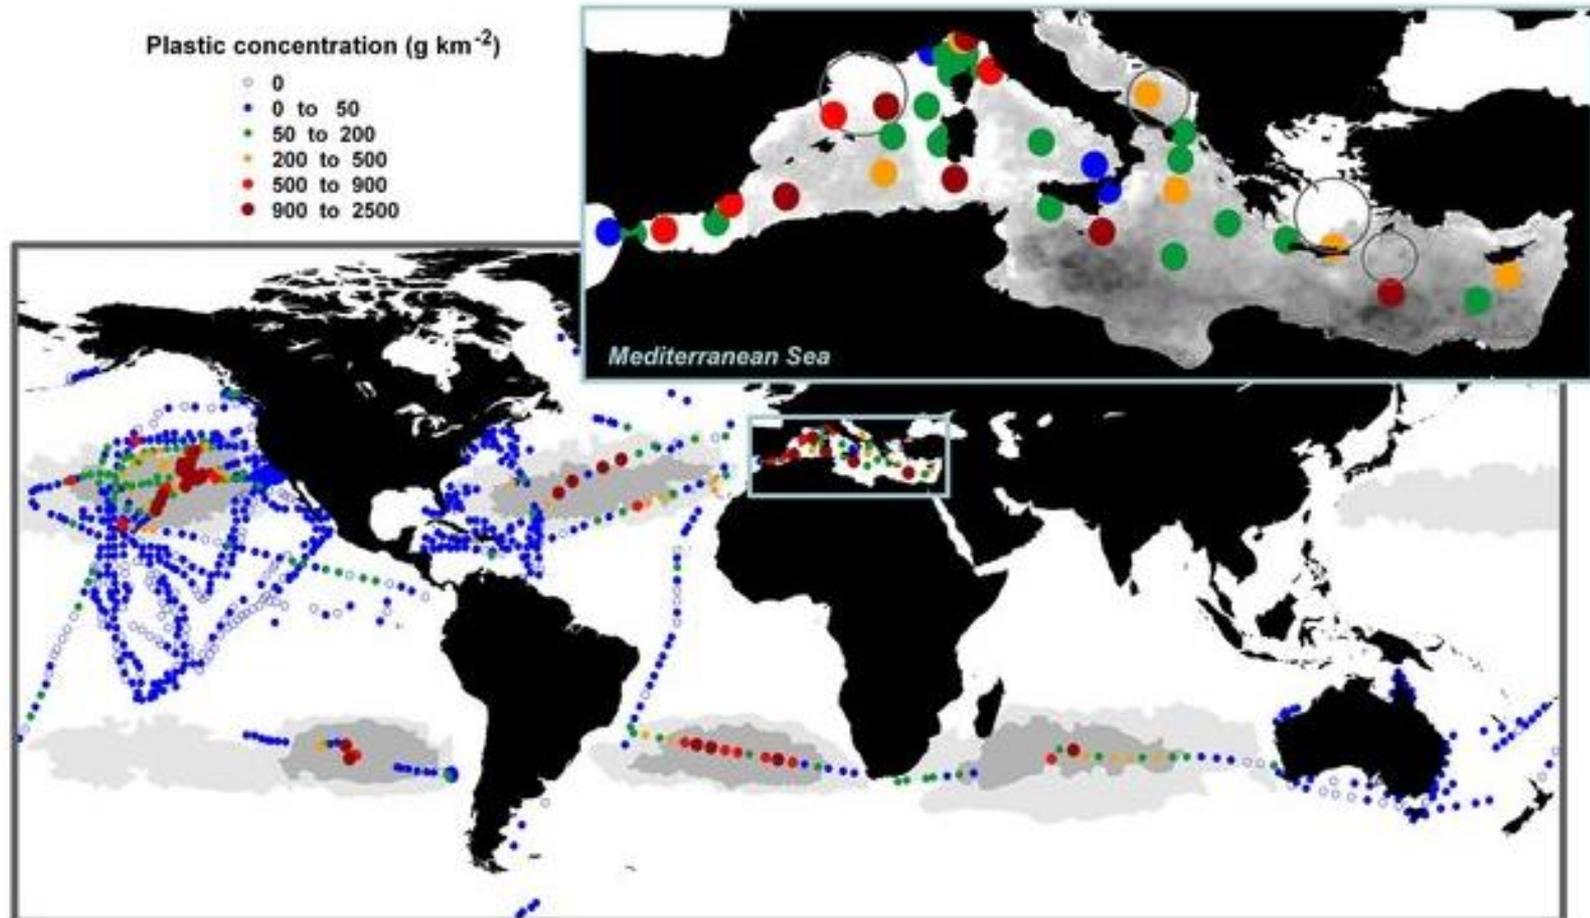
“For instance, satellite maps of ocean currents let us simulate accumulation of litter in vast ‘gyres’ within the Pacific, Atlantic and Indian Oceans.



Floating plastic

“What we are now looking at in this new project is to assess the feasibility of direct optical measurement of seaborne plastic waste from satellites. This might sound like mission impossible, but there are reasons to believe it might be indeed doable, at least for certain concentrations.

"We're not talking about actually spotting floating litter items but instead to identify a distinct spectral signature of plastic picked up from orbit, in the same way that processing software can today pick out concentrations of phytoplankton, suspended sediments and water-borne pollution.



Plastic litter in global oceans

"In particular, plastic has specific infrared fingerprints that are sometimes used in the recycling industry to sort plastic items from other refuse on a conveyor belt."

Supported by ESA's [Basic Activities](#), two teams are working in parallel, led by Argans Limited and Plymouth Marine Laboratory in the UK. Their work began last September with an initial assessment of requirements and technologies, along with a workshop bringing together marine litter experts with remote sensing specialists.



Satellite images from missions such as the Copernicus Sentinels are being checked against aerial coverage plus ground surveys where drifting plastic is collected from the sea to be assessed in close-up. Initial results were presented last week at the [International Marine Debris Conference](#) in San Diego, USA.

Paolo adds, "We hope to get an idea of what kind of concentration of marine litter is viewable from the top of the atmosphere using current technology, or if we'd have to operate from the middle of the atmosphere using aircraft or drones. Or would we have to improve the technology?"

The project will deliver a preliminary set of requirements for a satellite to detect marine plastic litter in the shortwave infrared.

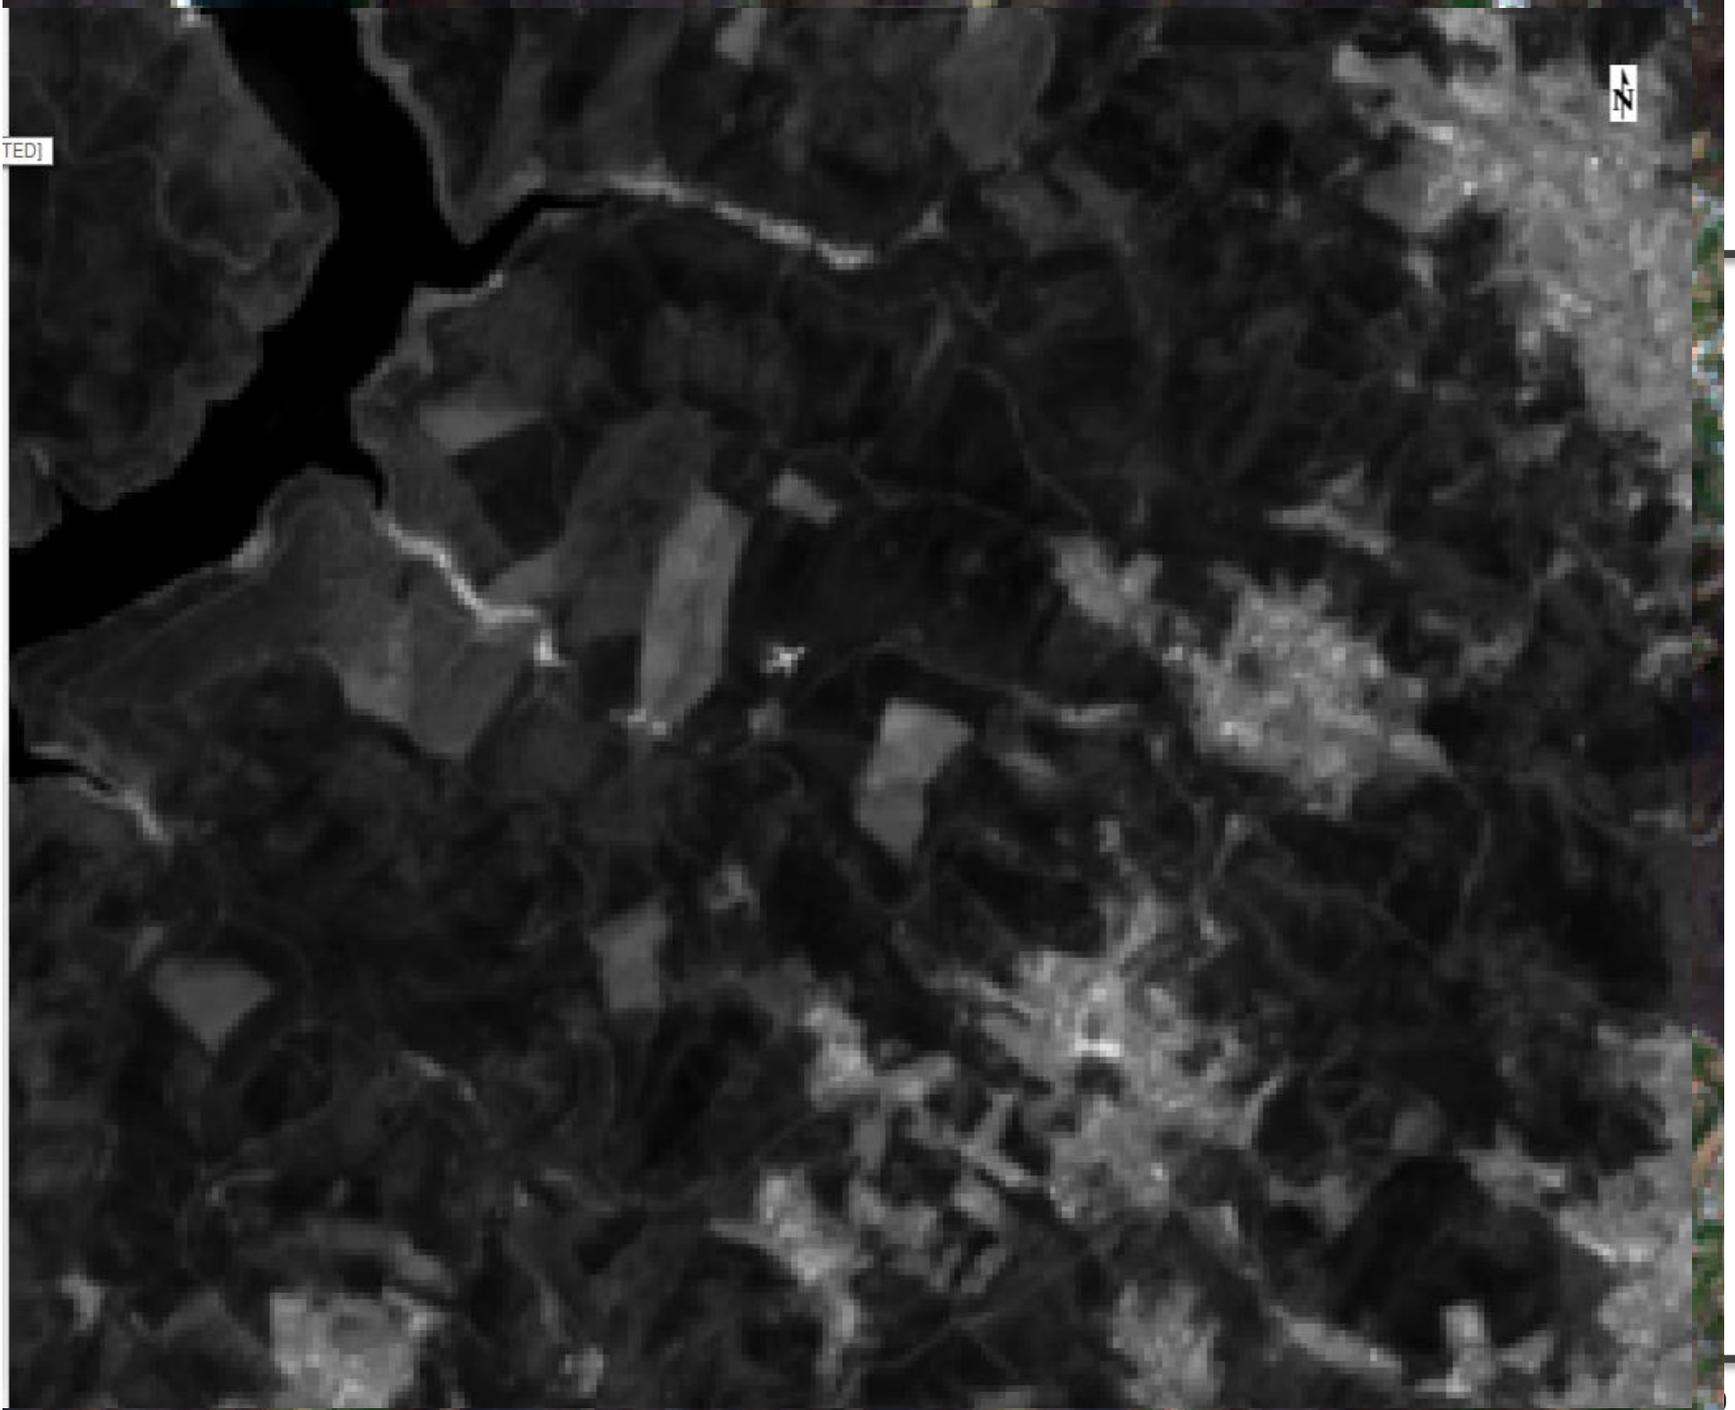


# Giving up forests



TEDJ

N





## - MultiSpectral Instrument (MSI) Overview

The design of the MultiSpectral Instrument (MSI) on-board SENTINEL-2 has been driven by the requirement for large swath high geometrical and spectral performance of the measurements.

The MSI measures the Earth's reflected radiance in 13 spectral bands from VNIR to SWIR (Table 1).

Table 1: Spectral bands for the SENTINEL-2 sensors (S2A & S2B)

| Band Number | S2A                     |                | S2B                     |                | Spatial resolution (m) |
|-------------|-------------------------|----------------|-------------------------|----------------|------------------------|
|             | Central wavelength (nm) | Bandwidth (nm) | Central wavelength (nm) | Bandwidth (nm) |                        |
| 1           | 443.9                   | 27             | 442.3                   | 45             | 60                     |
| 2           | 496.6                   | 98             | 492.1                   | 98             | 10                     |
| 3           | 560.0                   | 45             | 559                     | 46             | 10                     |
| 4           | 664.5                   | 38             | 665                     | 39             | 10                     |
| 5           | 703.9                   | 19             | 703.8                   | 20             | 20                     |
| 6           | 740.2                   | 18             | 739.1                   | 18             | 20                     |
| 7           | 782.5                   | 28             | 779.7                   | 28             | 20                     |
| 8           | 835.1                   | 145            | 833                     | 133            | 10                     |
| 8a          | 864.8                   | 33             | 864                     | 32             | 20                     |
| 9           | 945.0                   | 26             | 943.2                   | 27             | 60                     |
| 10          | 1373.5                  | 75             | 1376.9                  | 76             | 60                     |
| 11          | 1613.7                  | 143            | 1610.4                  | 141            | 20                     |
| 12          | 2202.4                  | 242            | 2185.7                  | 238            | 20                     |

Figure 1 (below) shows the S2A spectral response functions (SRF) and transmission due to vertical column Water Vapour (WV) absorption for subarctic winter atmosphere (light blue, lowest WV content) and tropical atmosphere (darker blue, highest WV content). WV transmission data comes from MODTRAN.

## MSI Description

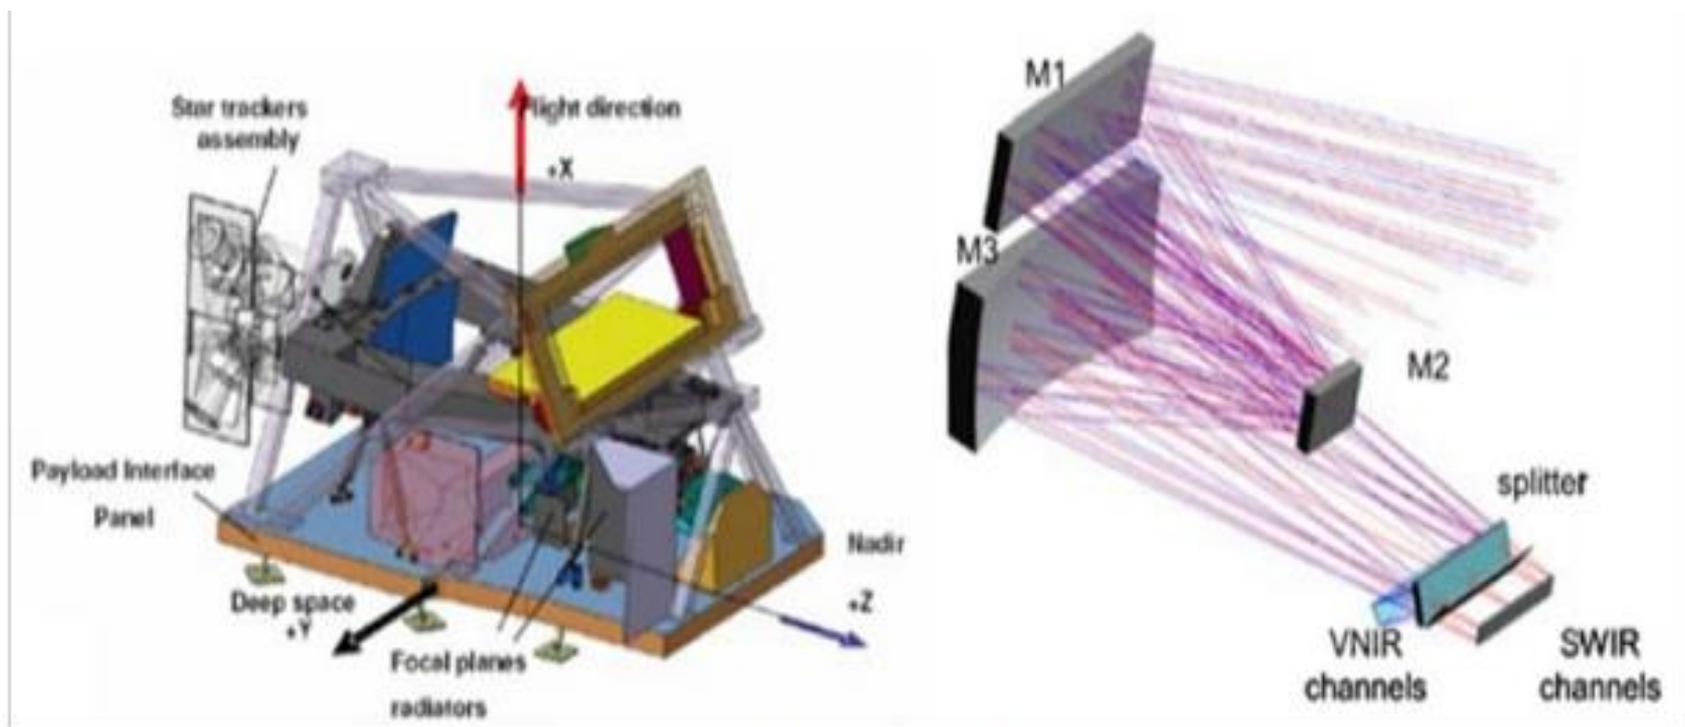
The MSI is designed and built by Airbus Defence and Space, France, and is based on a push-broom concept (Figure 1).

### MSI instrument features

- A Three-Mirror Anastigmat (TMA) telescope with a pupil diameter equivalent to 150 mm, isostatically mounted on the platform to minimise thermo-elastic distortions. The optical design has been optimised to achieve state-of-the-art imaging quality across its very wide field of view. Its 290 km swath width is a larger swath than previous multi-spectral optical missions such as SPOT and LANDSAT. The telescope structure and the mirrors are made of silicon carbide, which provides a very high optical stability to mass ratio and minimises thermal deformation.
- Two focal planes based on:
  - monolithic CMOS detectors for VNIR
  - mercury-cadmium-telluride detectors hybridised on a CMOS read-out circuit for SWIR (the SWIR focal plane is passively thermo-controlled at temperatures below 195 K).
- A dichroic VNIR/SWIR beam splitter. Spectral separation in the various bands is provided by stripe filters mounted on top of the detectors.
- Two distinct arrays of 12 detectors mounted on each focal plane covering VNIR and SWIR channels respectively. The 12 detectors on each focal plane are in a staggered configuration to cover the entire field of view.
- A full-field and full-pupil on-board diffuser for radiometric calibration to guarantee high-quality radiometric performance.
- A shutter mechanism preventing the instrument from direct illumination by the sun. This mechanism is also used as a calibration device by collecting the sunlight after reflection by a diffuser.



Figure 2: The Multi Spectral Instrument (Airbus Defence and Space)



**Figure 3: MSI Internal Configuration**

The 12 detectors on each focal plane are mounted in a staggered formation (Figure 3) to cover the whole 20.6° instrument field of view, resulting in a compound swath width of 290 km on the ground track. As illustrated in the figure below, due to the staggered positioning of the detectors on the focal planes, a parallax angle between the two alternating odd and even clusters of detectors is induced in the measurements, resulting in a shift along track of approximately 46 km (maximum) inter-detector. Likewise, the hardware design of both the VNIR and SWIR detectors imposes a relative displacement of each spectral channel sensor within the detector resulting in an inter-band measurement parallax amounting to a maximum along track displacement of approximately 14 km.

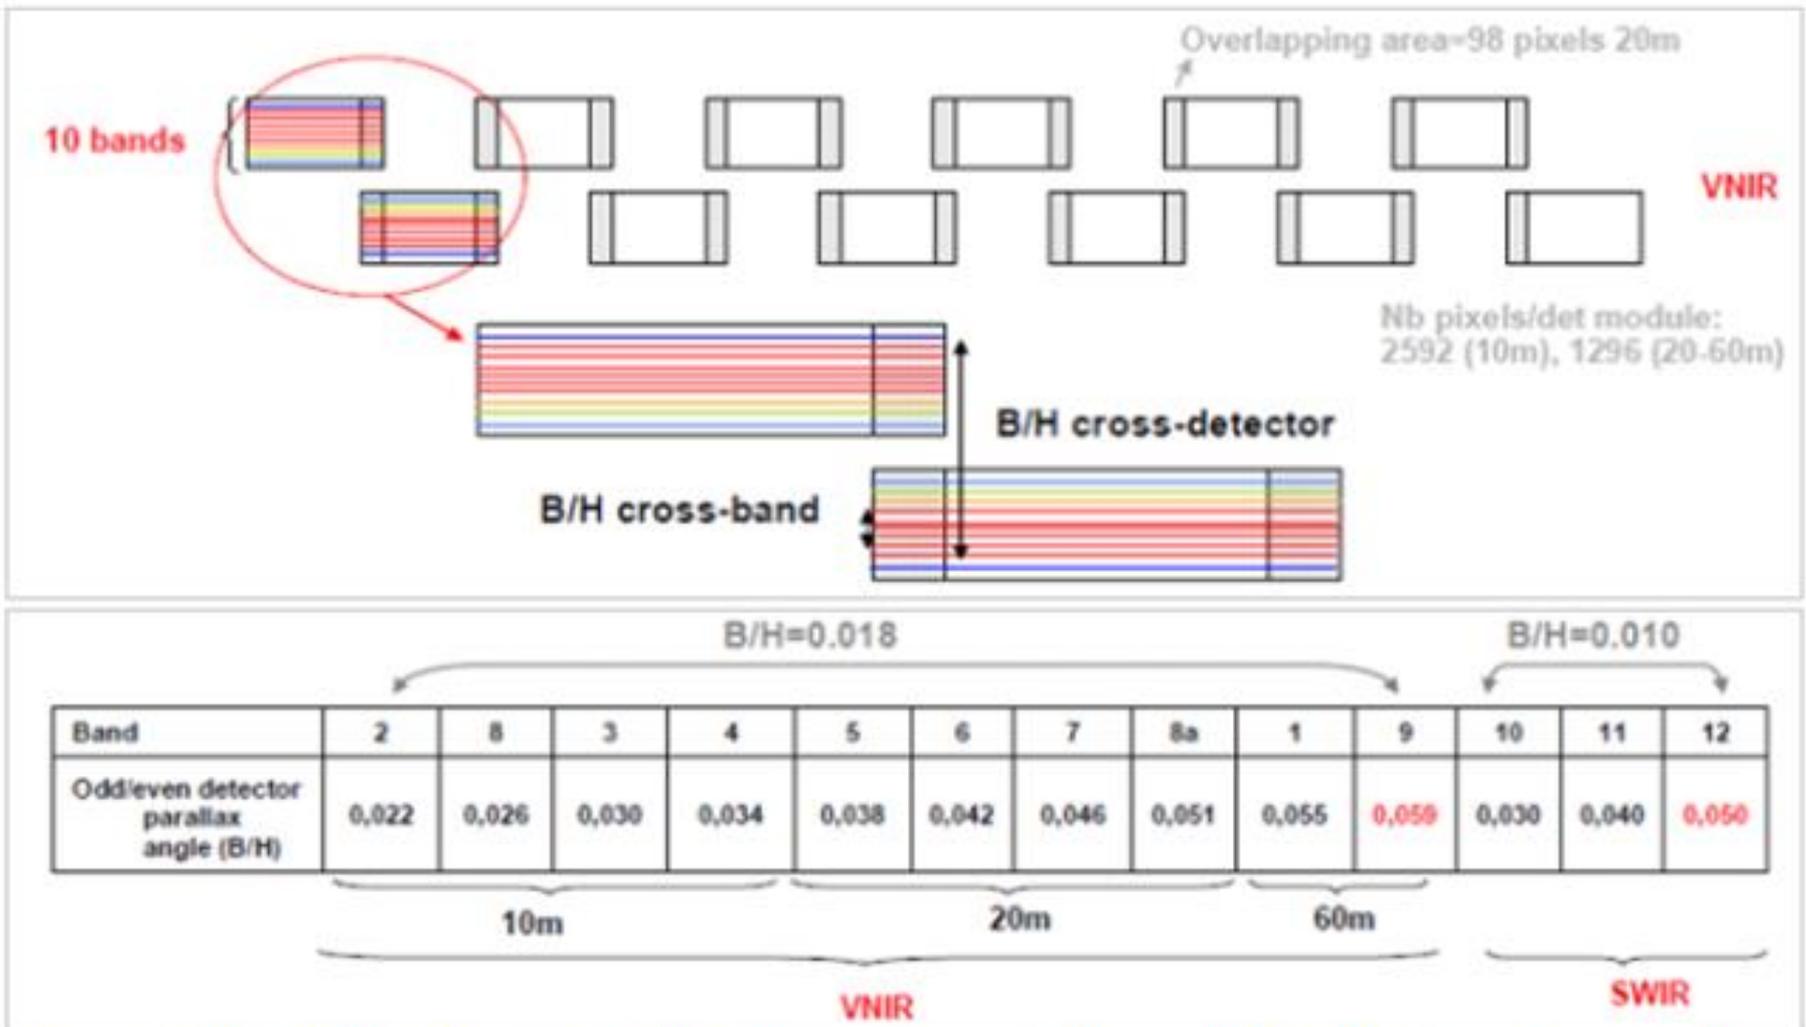


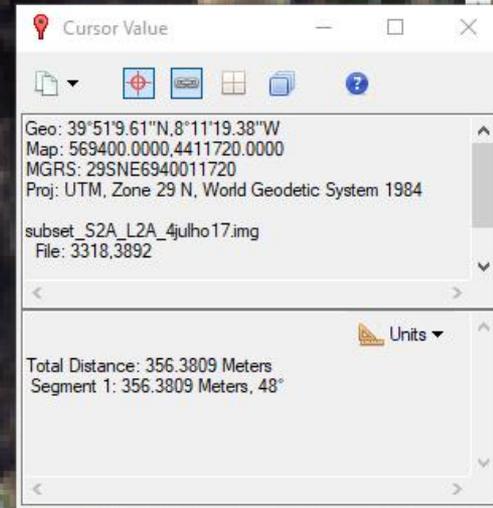
Figure 4: Staggered Detector Configuration and Inter-Detector / Inter-Band Parallax Angles (parallax figures

Due to the particular geometrical layout of the focal plane, each spectral band of the MSI observes the ground surface at different times.

**Table 2: The temporal offset (in seconds) between selected Bands**

| Inter-band Pair | Temporal offset between bands (seconds) |
|-----------------|---|
| B08 / B02       | 0.264                                   |
| B03 / B08       | 0.264                                   |
| B03 / B02       | 0.527                                   |
| B10 / B03       | 0.324                                   |
| B10 / B02       | 0.851                                   |
| B04 / B10       | 0.154                                   |
| B04 / B02       | 1.005                                   |
| B05 / B04       | 0.264                                   |

$$350 \text{ m} * 3600 \text{ s} = 1260 \text{ km/h}$$



Cursor Value

Geo: 39°51'9.61"N, 8°11'19.38"W  
Map: 569400.0000, 4411720.0000  
MGRS: 29SNE6940011720  
Proj: UTM, Zone 29 N, World Geodetic System 1984

subset\_S2A\_L2A\_4julho17.img  
File: 3318,3892

Units ▾

Total Distance: 356.3809 Meters  
Segment 1: 356.3809 Meters, 48°

## Capítulo 5 – Classificação Temática

- 5.1 Correção de imagens
  - 5.1.1 Correções Radiométricas
  - 5.1.2 Correções Geométricas
  - 5.1.3 Reamostragem
- 5.2 Índices (empíricos) de Vegetação
- 5.3 O Processo de Classificação
- 5.4 Classificação de Máxima Verosimilhança (supervisionada paramétrica)
  - 5.4.1. Classes multivariadas normais
  - 5.4.2 Limites
- 5.5 Classificador Distância mínima
- 5.6 Classificador Paralelepípedo
- 5.7 Classificador Mahalanobis
- 5.8 Método não supervisionado
  - 5.8.1 K-Means
  - 5.8.2 ISODATA (Iterative Self-Organizing Data Analysis Techniques)
- 5.9 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

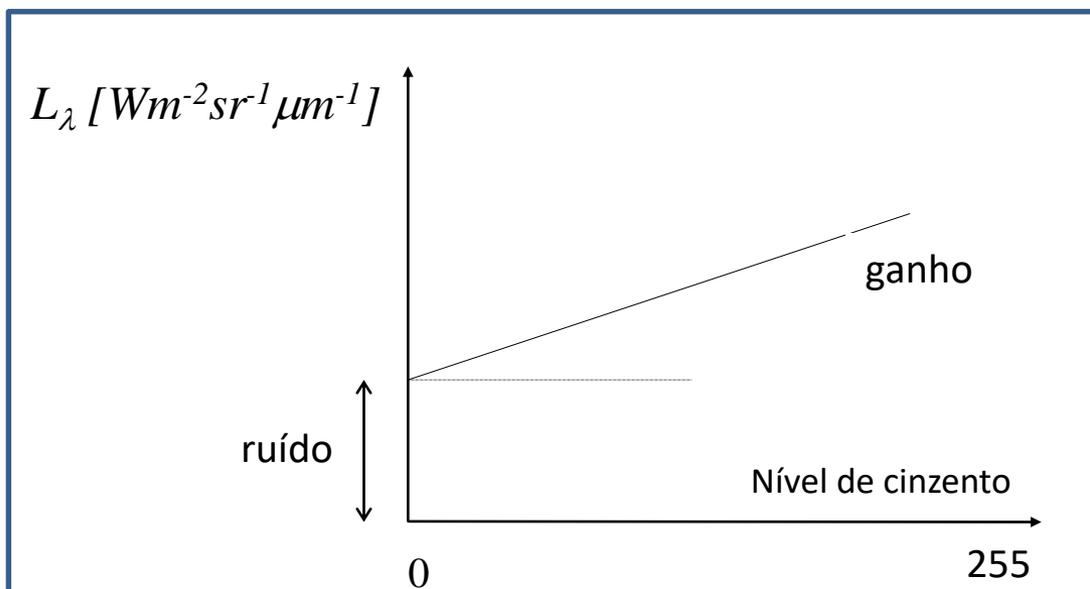
Correcção da linhas e pixéis não gravados

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, trata-se de calcular a equação que permite de obter a reflectância espectral da superfície terrestre ao nível do topo da atmosfera:

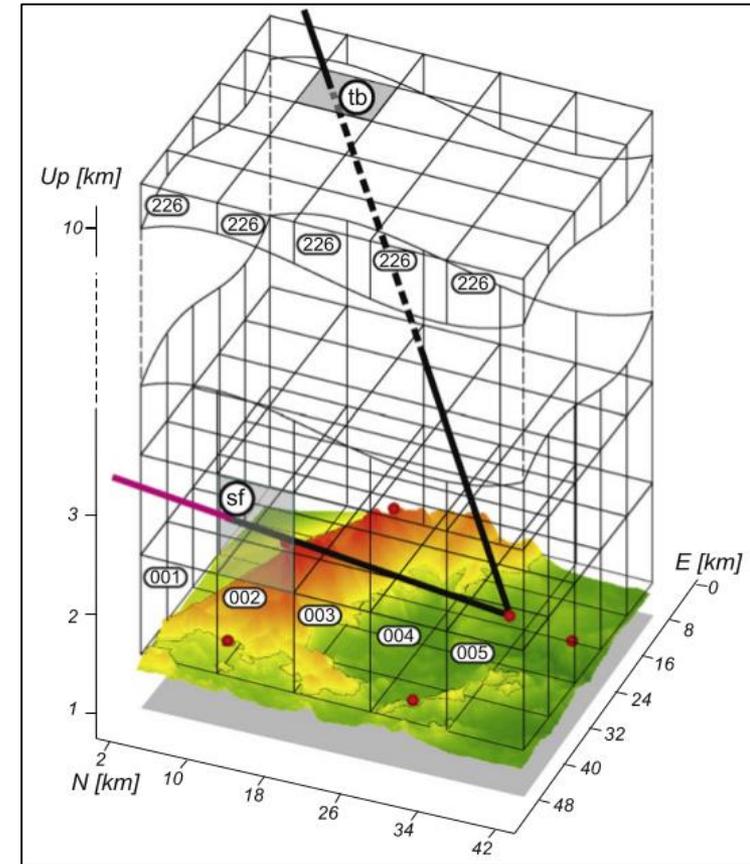
$$\rho_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot d^2}{E_{SUN_{\lambda}} \cos \theta_s}$$

Reflectancia 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.).

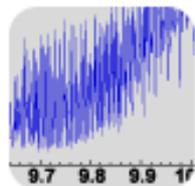
Estes modelos, os mais conhecidos *Lowtran* e *Modtran* (MODerate resolution atmospheric TRANsmission) fornecem valores precisos da transmitância e da radiação atmosférica para calcular  $L_{sp}$  ed  $E_d$ .



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

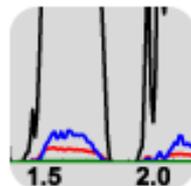


MODTRAN® is an atmospheric radiative transfer model developed by Spectral Sciences Inc. and the US Air Force Research Laboratory. It has been extensively validated and serves as a standard atmospheric band model for the remote sensing community.

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

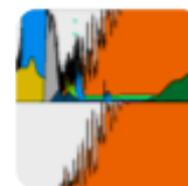
#### Increased Spectral Resolution

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

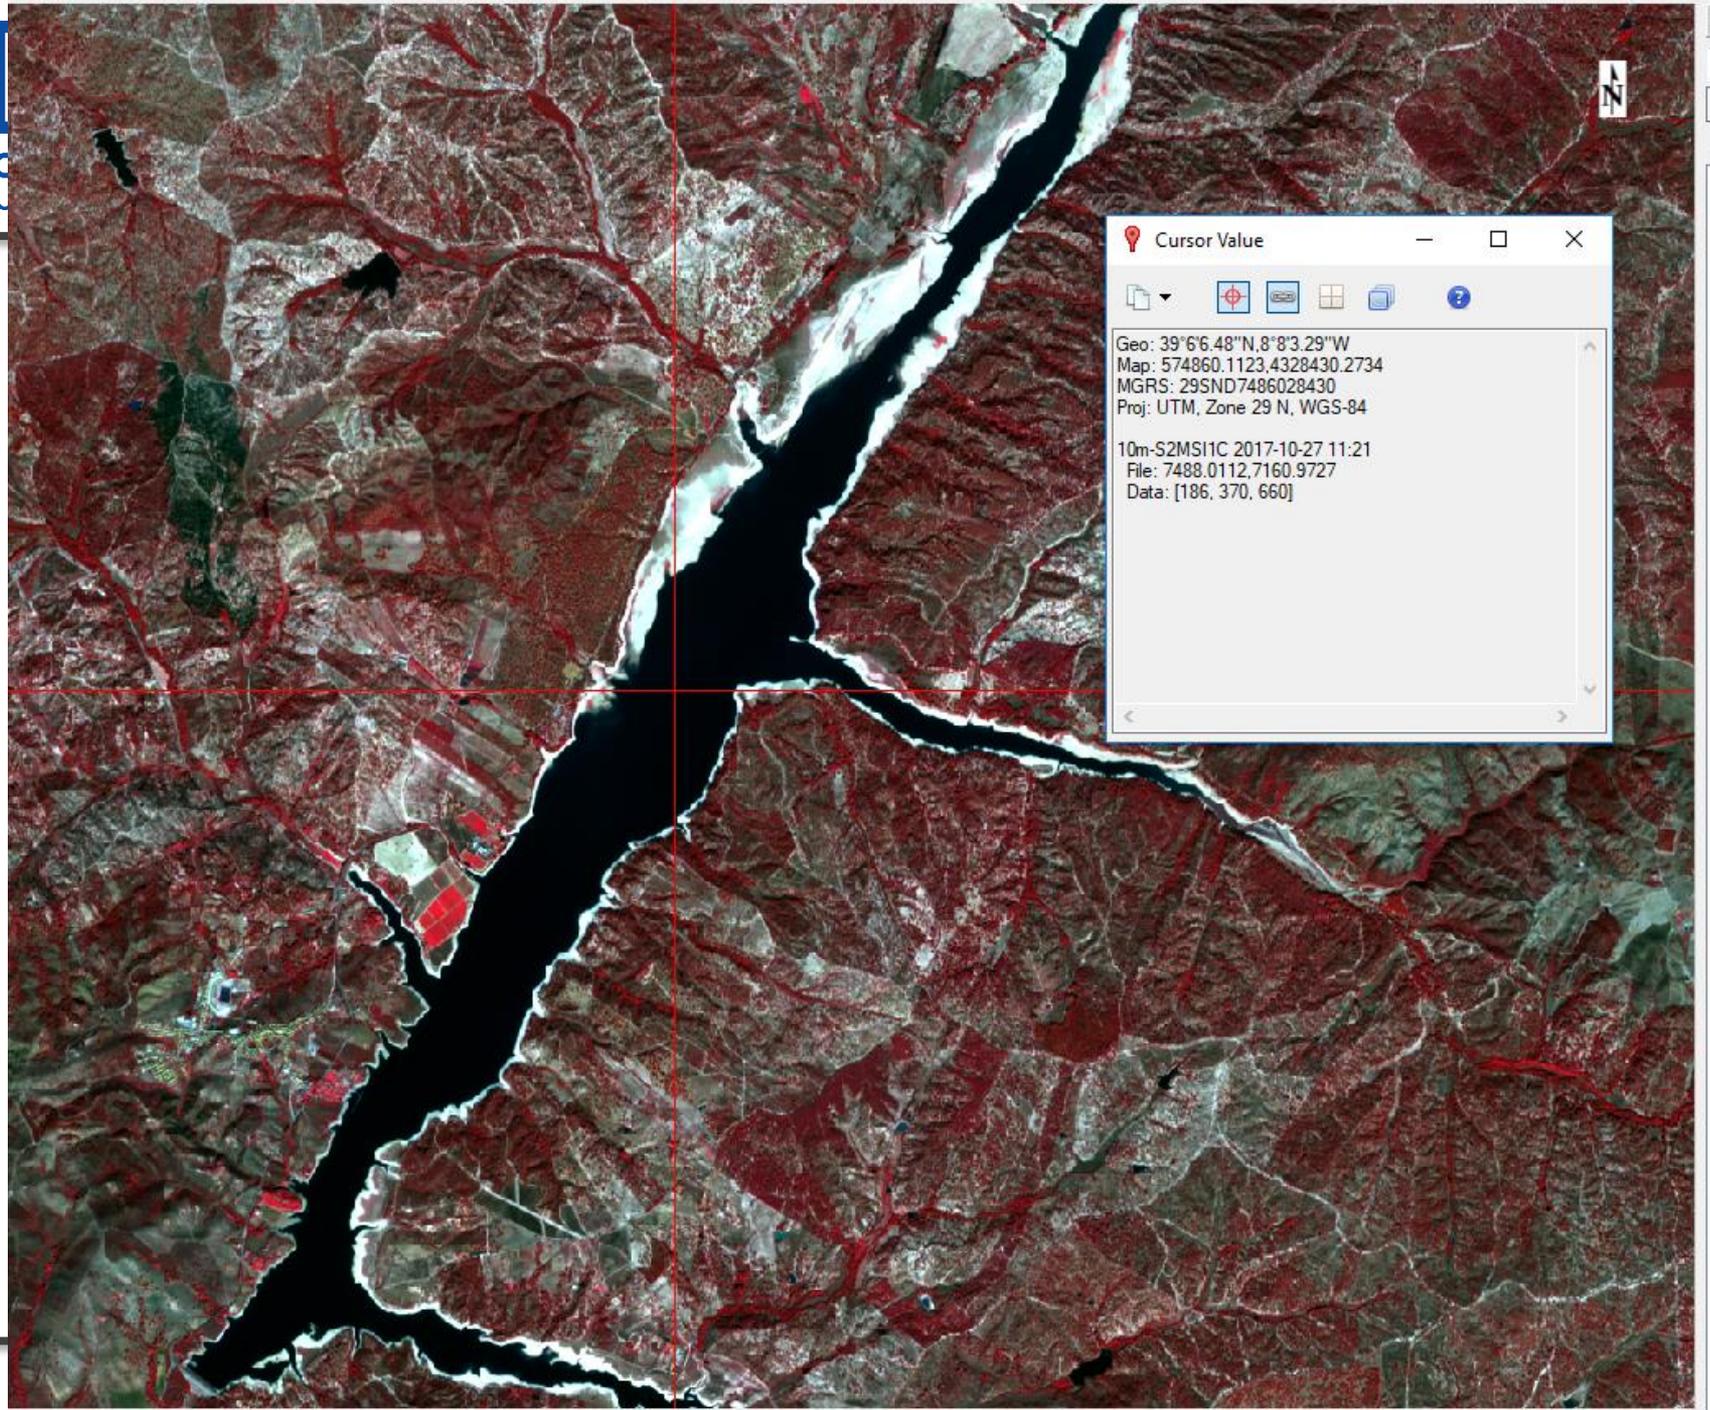
## Método Dark-pixel

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

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

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

- Search the toolbar
- /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

ad 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 correcções:

**Correcções sistemáticas**

Ligadas ao sensor e plataforma e por isso constantes no tempo

**Correcções de precisão**

---



# Geometric Correction

---

As correcções de precisão, para além de corrigir geometricamente a imagem de maneira coerente com o sistema de referencia 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**

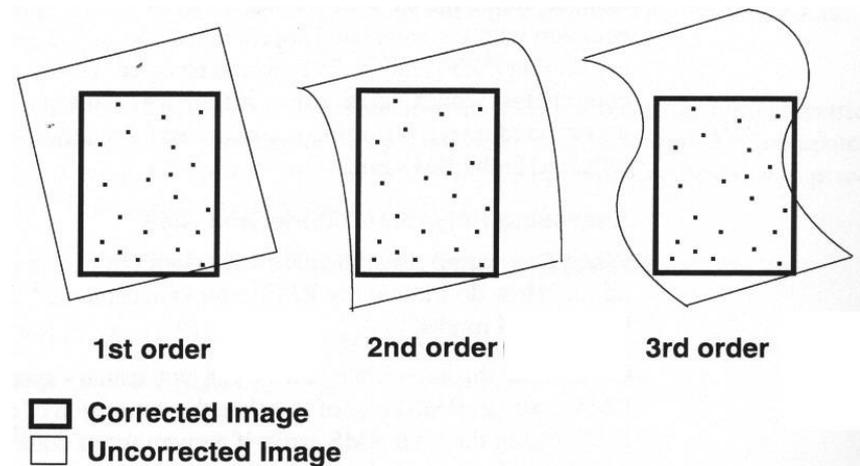
**Orto-rectificação**

---

# 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 geográficas ou cartográficas.



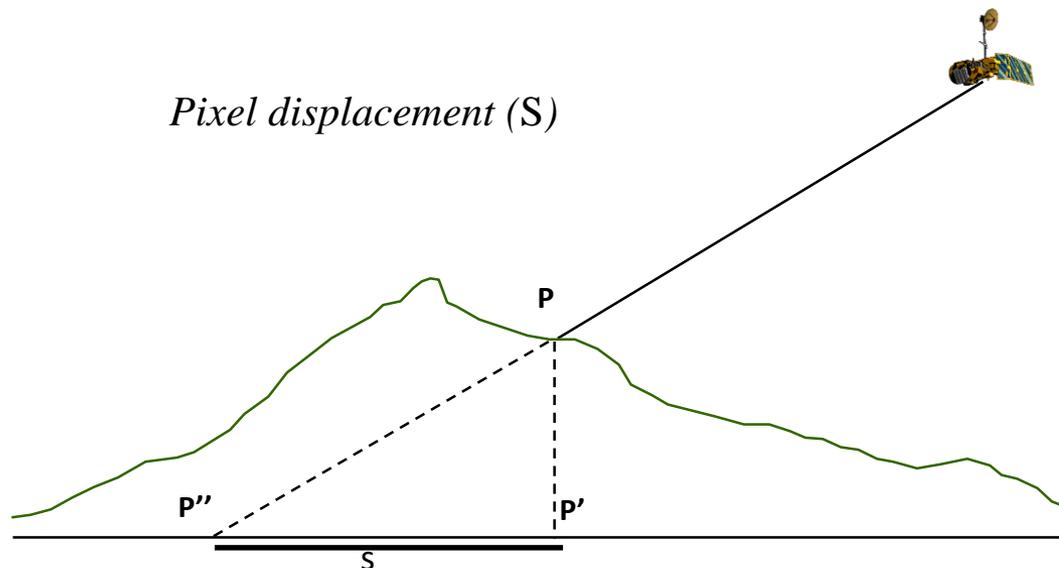
Essas equações podem ser polinómios de diferente ordem.

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.





# 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**

---

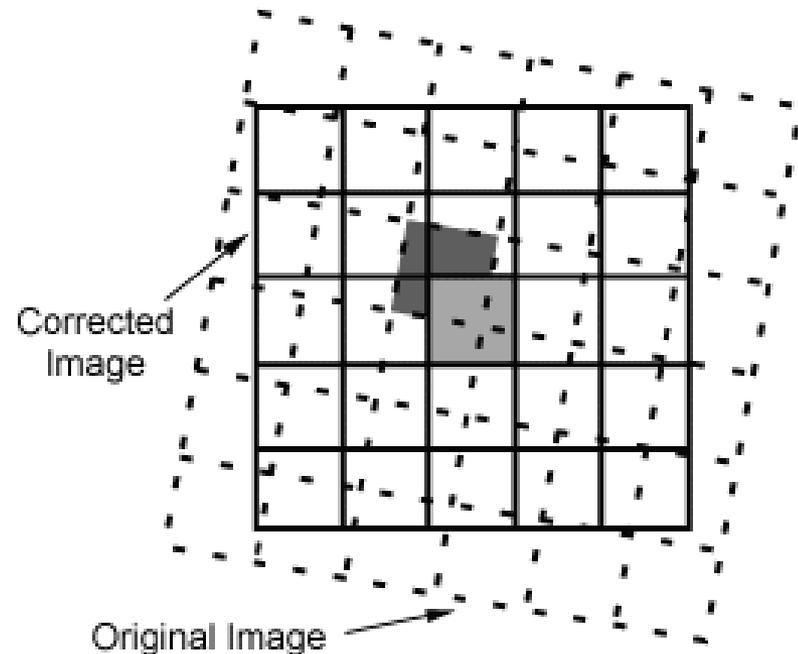
# Nearest Neighbour

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

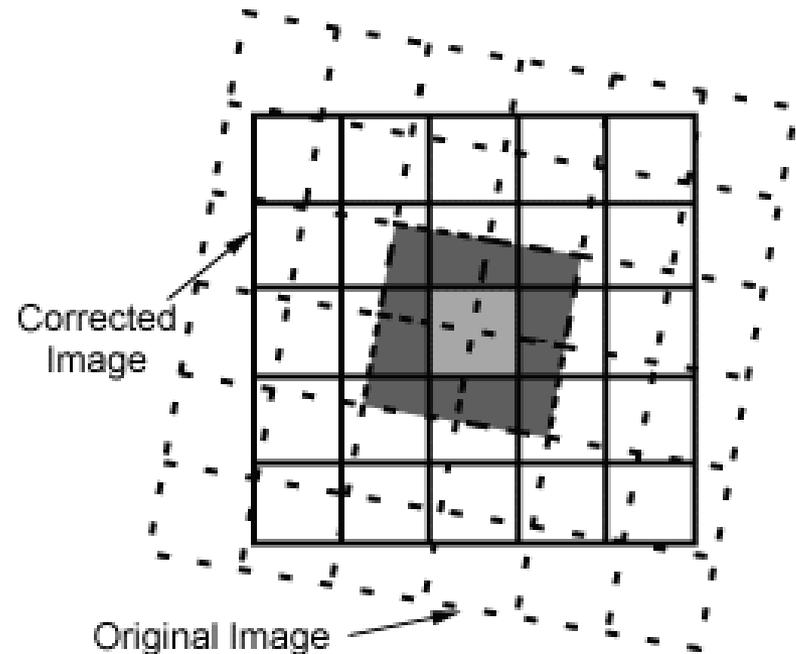
(isso é importante por exemplo na georreferenciação dos mapas de uso do solo)



# 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.

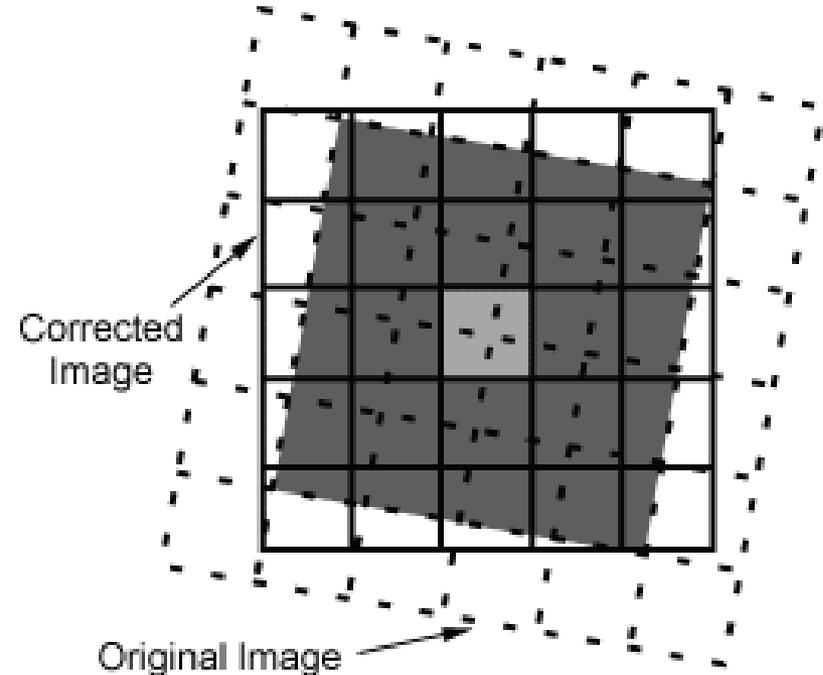
Os valores de radiância originais são alterados e a imagem obtida é caracterizada por menos contrastes e variações radiométricos mais suaves (efeito da filtragem ! )



# 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.



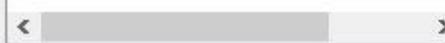
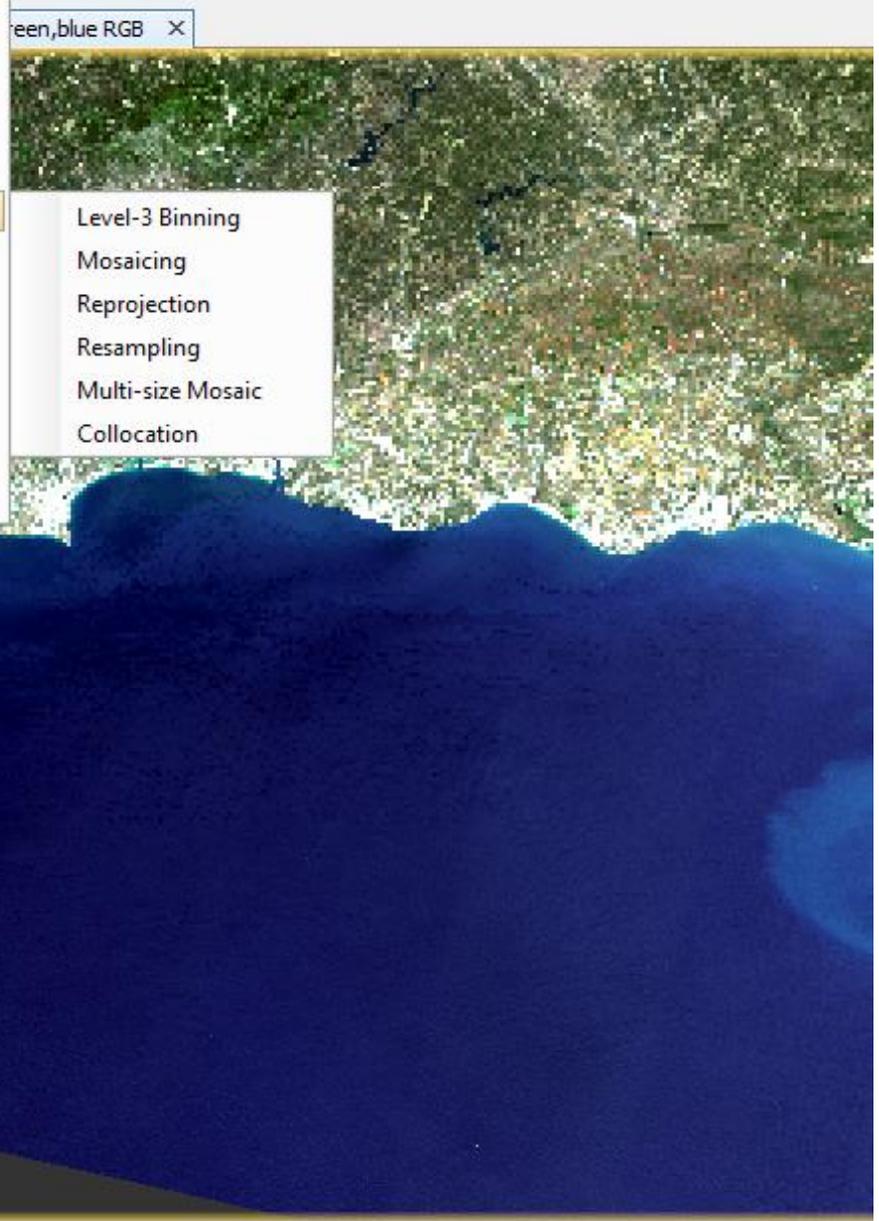
Esta técnica só faz muito sentido se o fim for a interpretação visual da imagem interpolada mas não deveria ser usada nos casos de análise numérica dos valores radiométricos.



**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 >



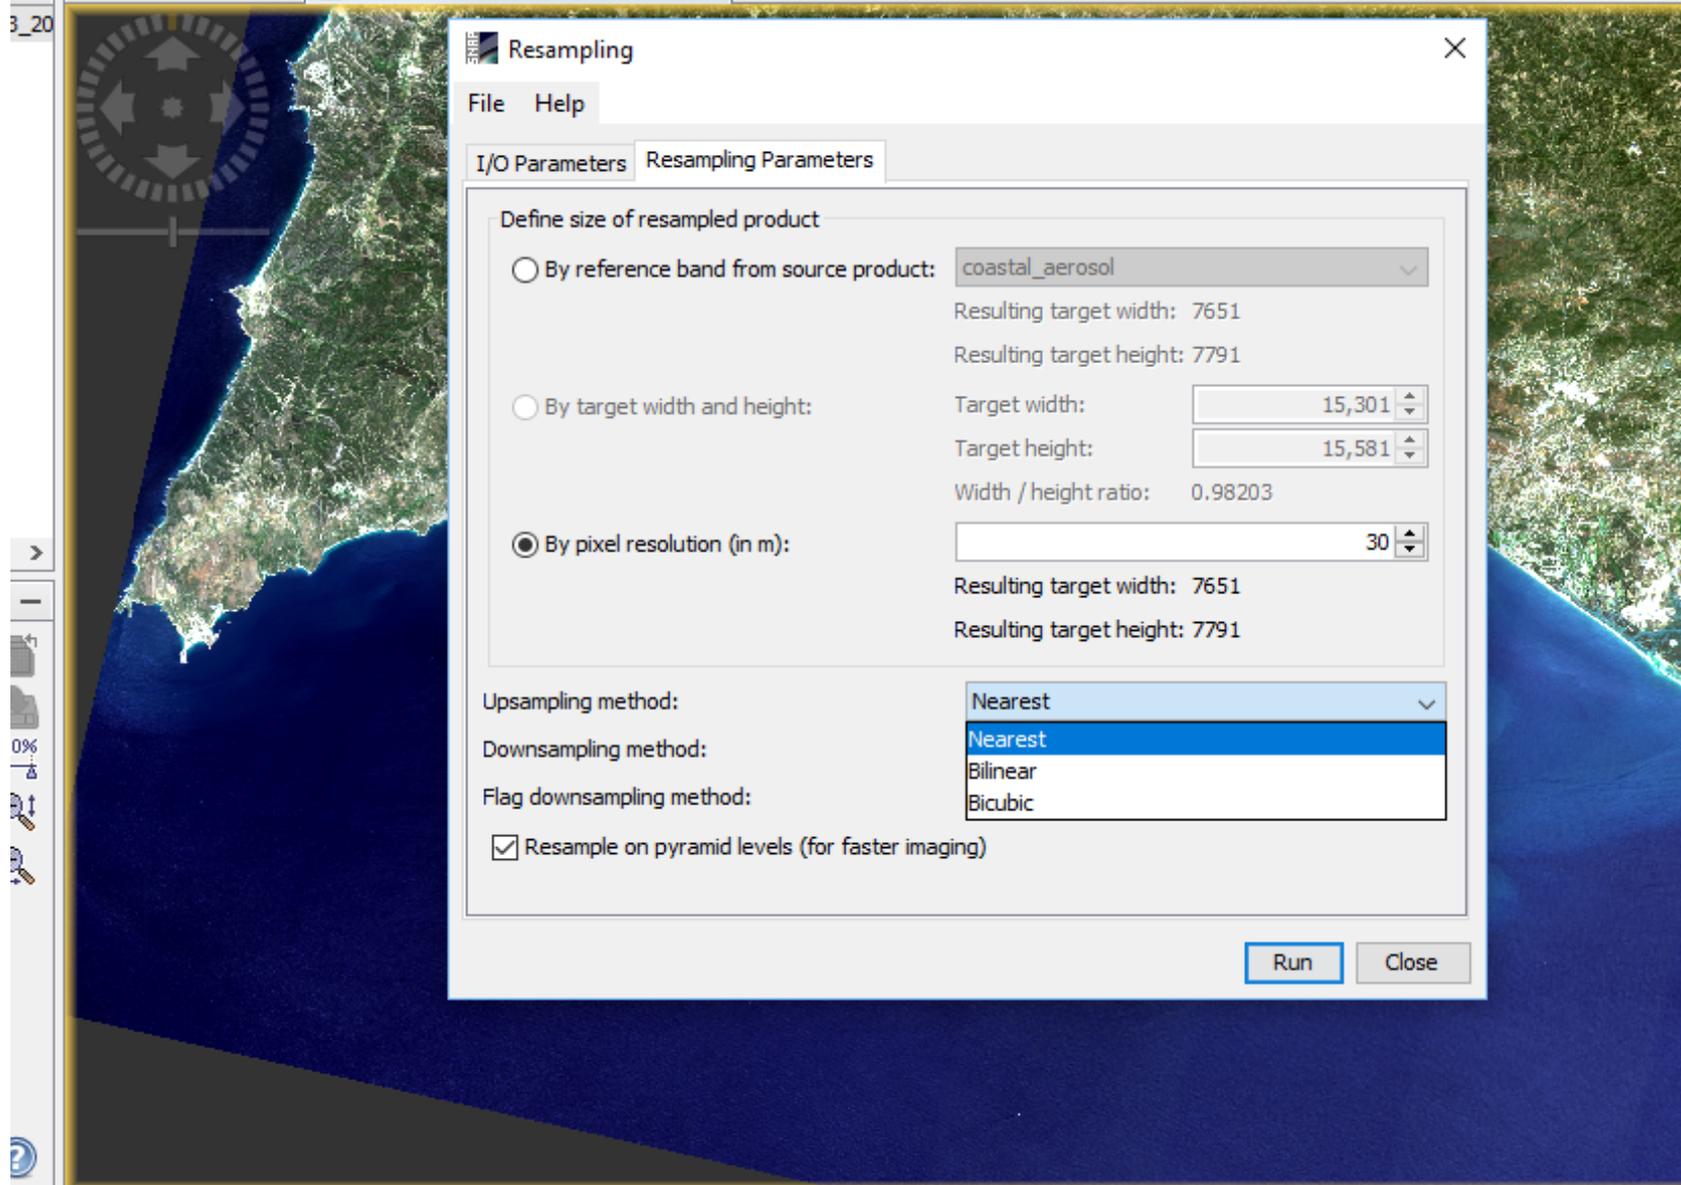
Navi... × Unce... Worl... -

Red  Green  Blue

Name: red  
Unit: W/(m<sup>2</sup>\*sr\*μm)  
Min: 13.515  
Max: 257.919  
Rough statistics!

14.95 76.53

More Options ?



### Resampling

File Help

I/O Parameters Resampling Parameters

Define size of resampled product

By reference band from source product: coastal\_aerosol  
Resulting target width: 7651  
Resulting target height: 7791

By target width and height: Target width:   
Target height:   
Width / height ratio: 0.98203

By pixel resolution (in m):   
Resulting target width: 7651  
Resulting target height: 7791

Upsampling method: Nearest

Downsampling method: Nearest  
Bilinear  
Bicubic

Flag downsampling method:

Resample on pyramid levels (for faster imaging)

Run Close



### 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

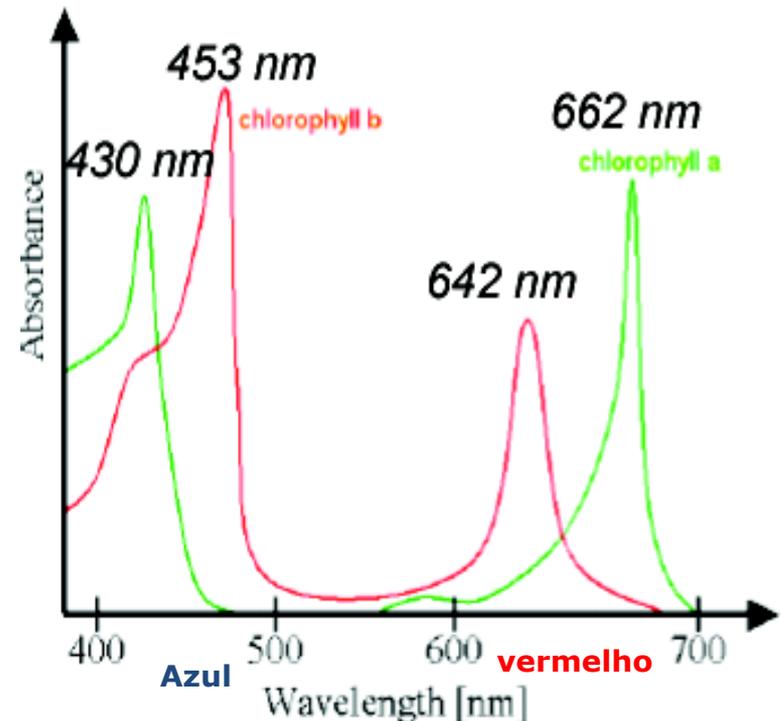


# Vegetation Index

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

Na banda do visível a clorofila absorve a radiação pelo processo de fotossíntese (especialmente os comprimentos de onda do vermelho e do azul).

Na banda do infravermelho próximo a radiação é fortemente difundida da estrutura interna da folhas





# Vegetation Index

## Índice razão.

$$I_1 = \frac{B\text{Land}_{red}}{B\text{Land}_{NIR}} = \frac{\text{vermelho}}{\text{infravermelho próximo}}$$

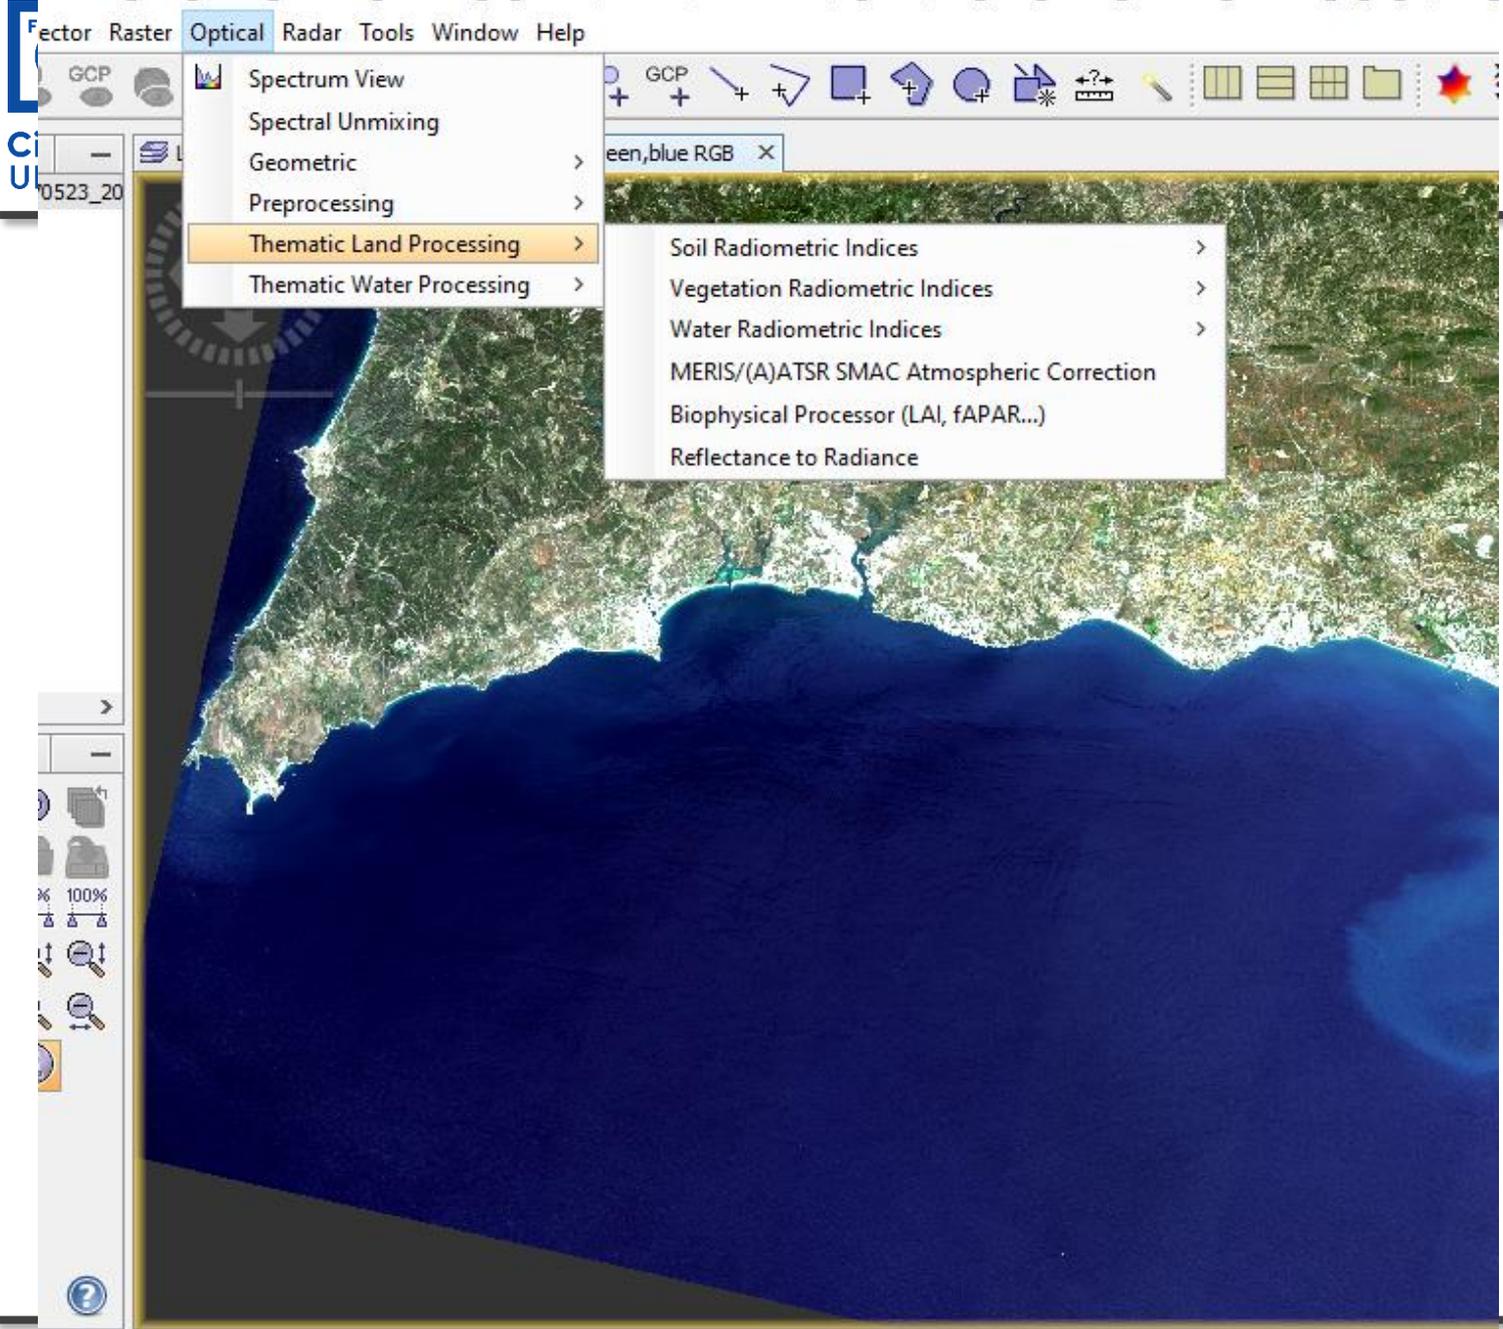
## Índice de vegetação normalizado NDVI

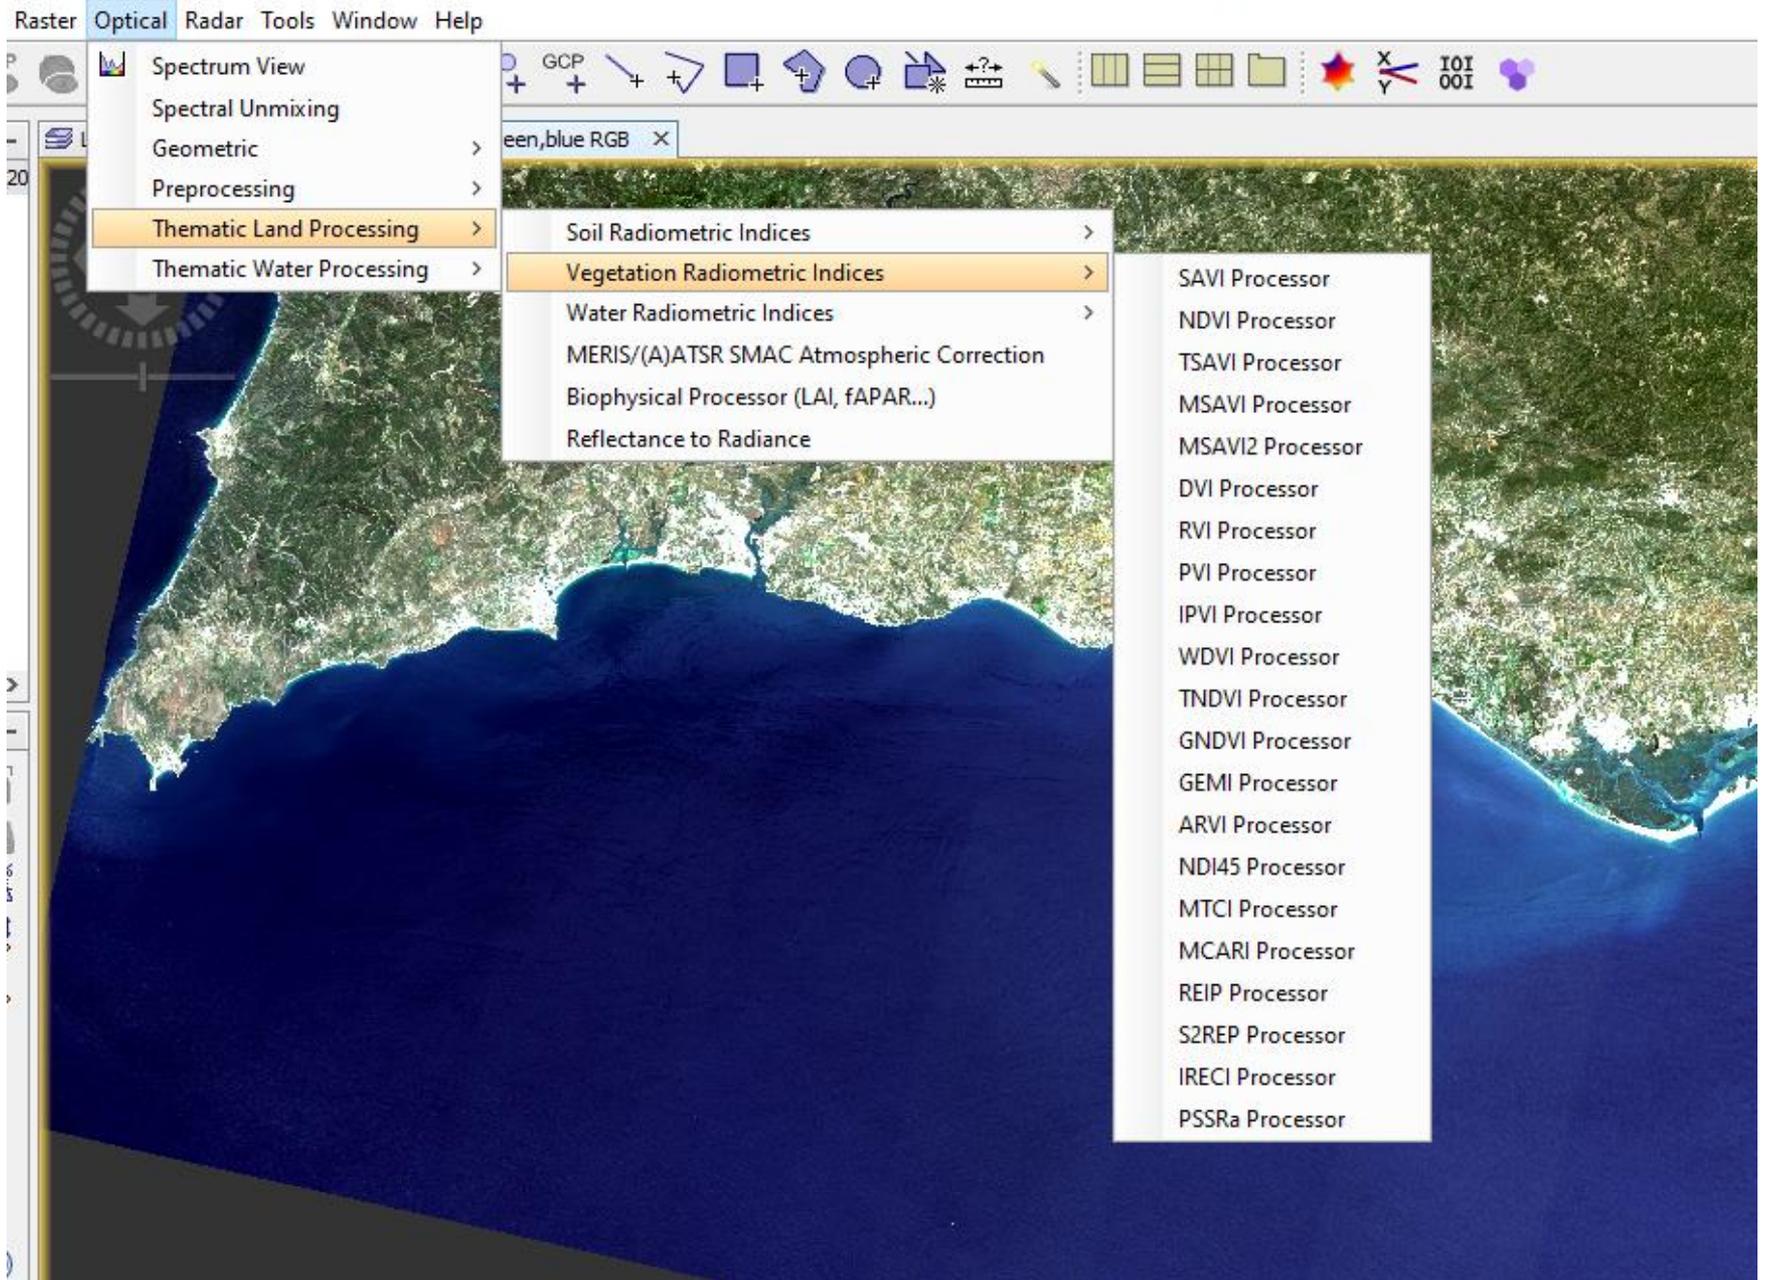
Normalized Difference Vegetation Index

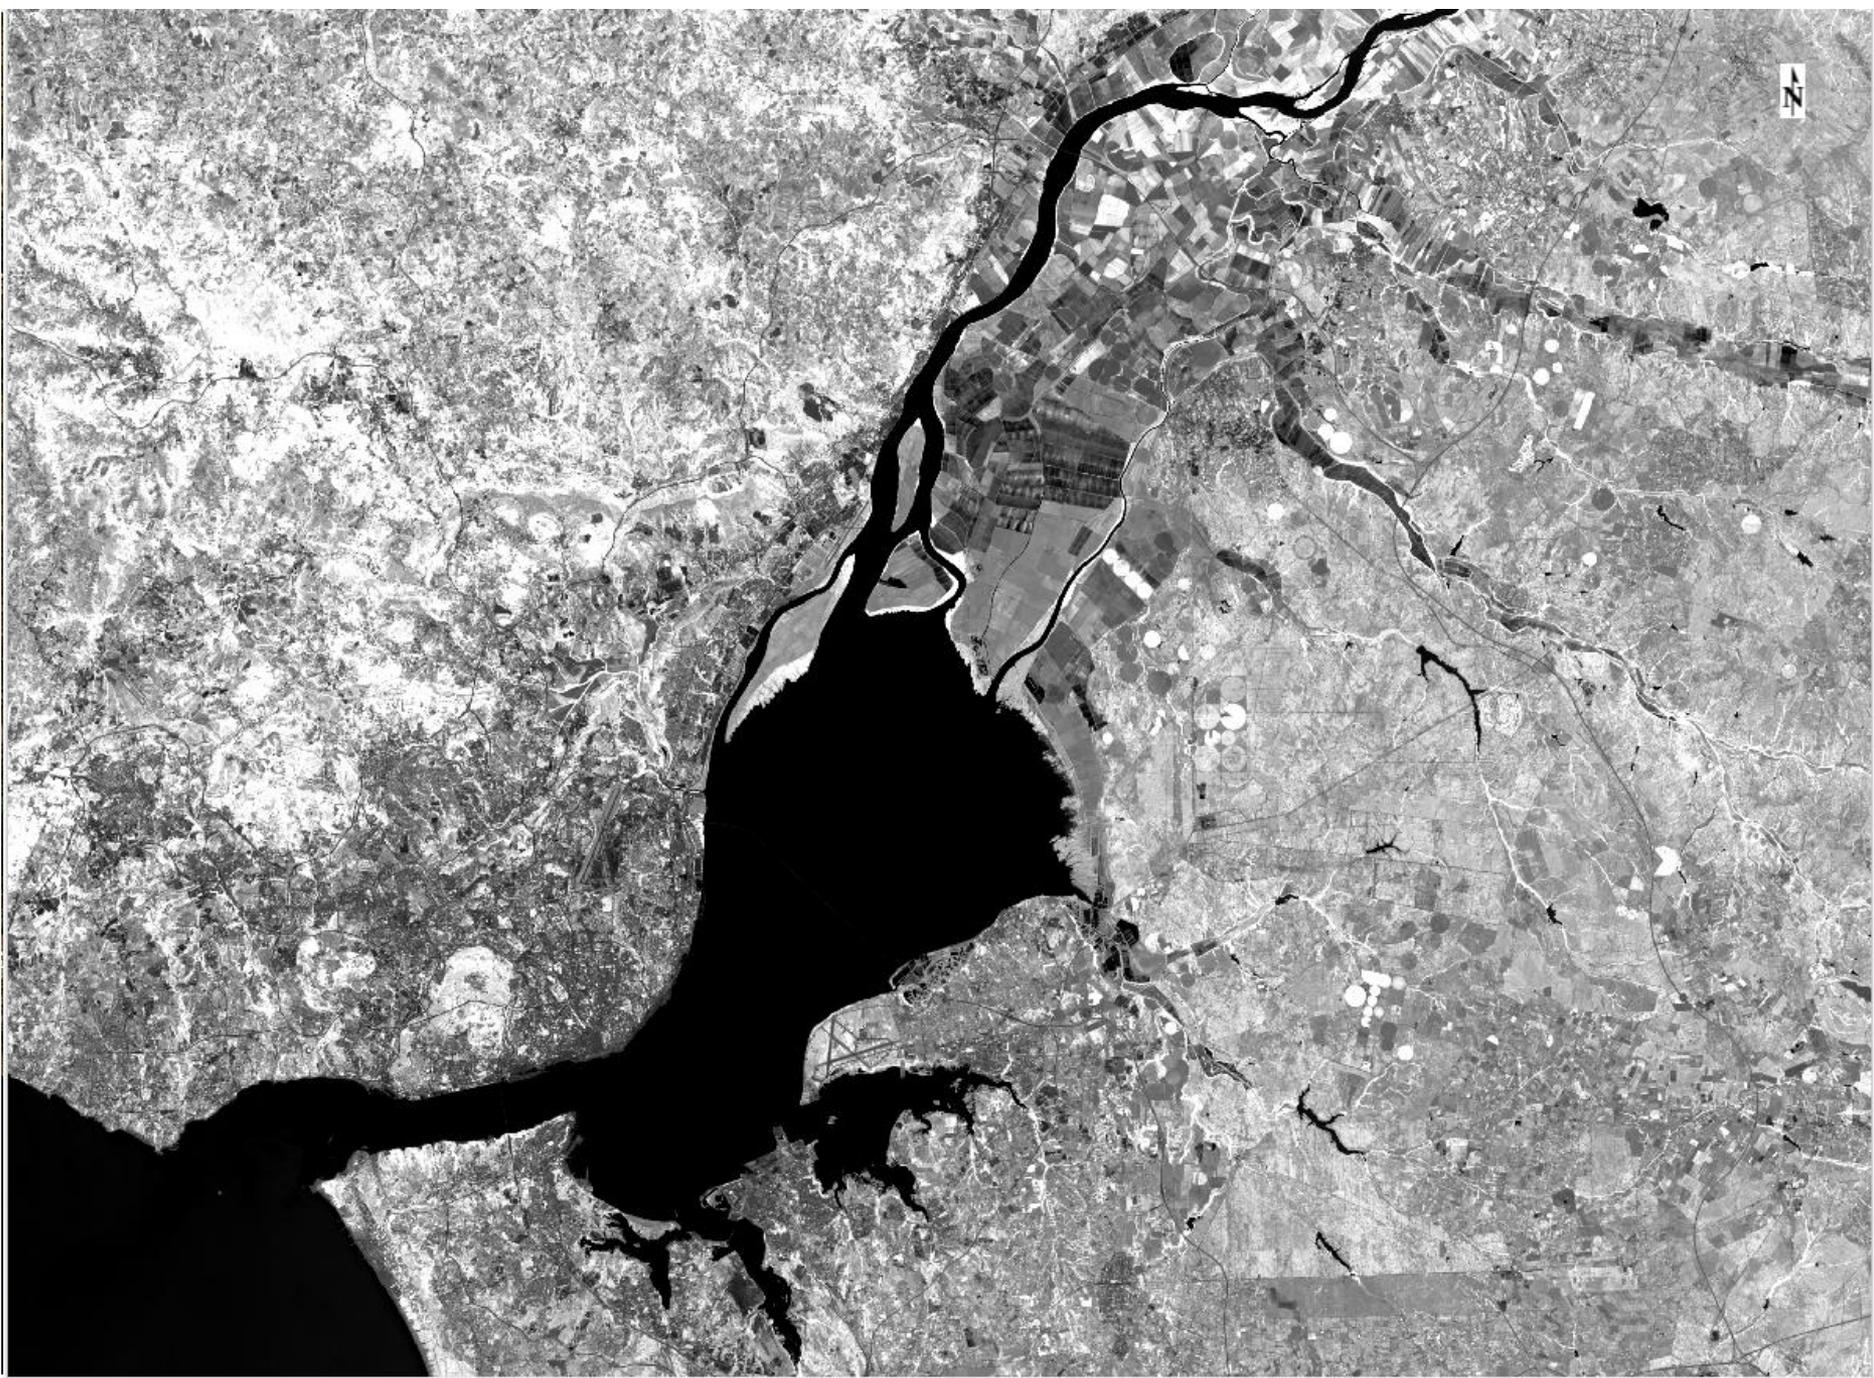
$$NDVI = \frac{\text{InfraRED} - \text{red}}{\text{InfraRed} + \text{Red}}$$

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.





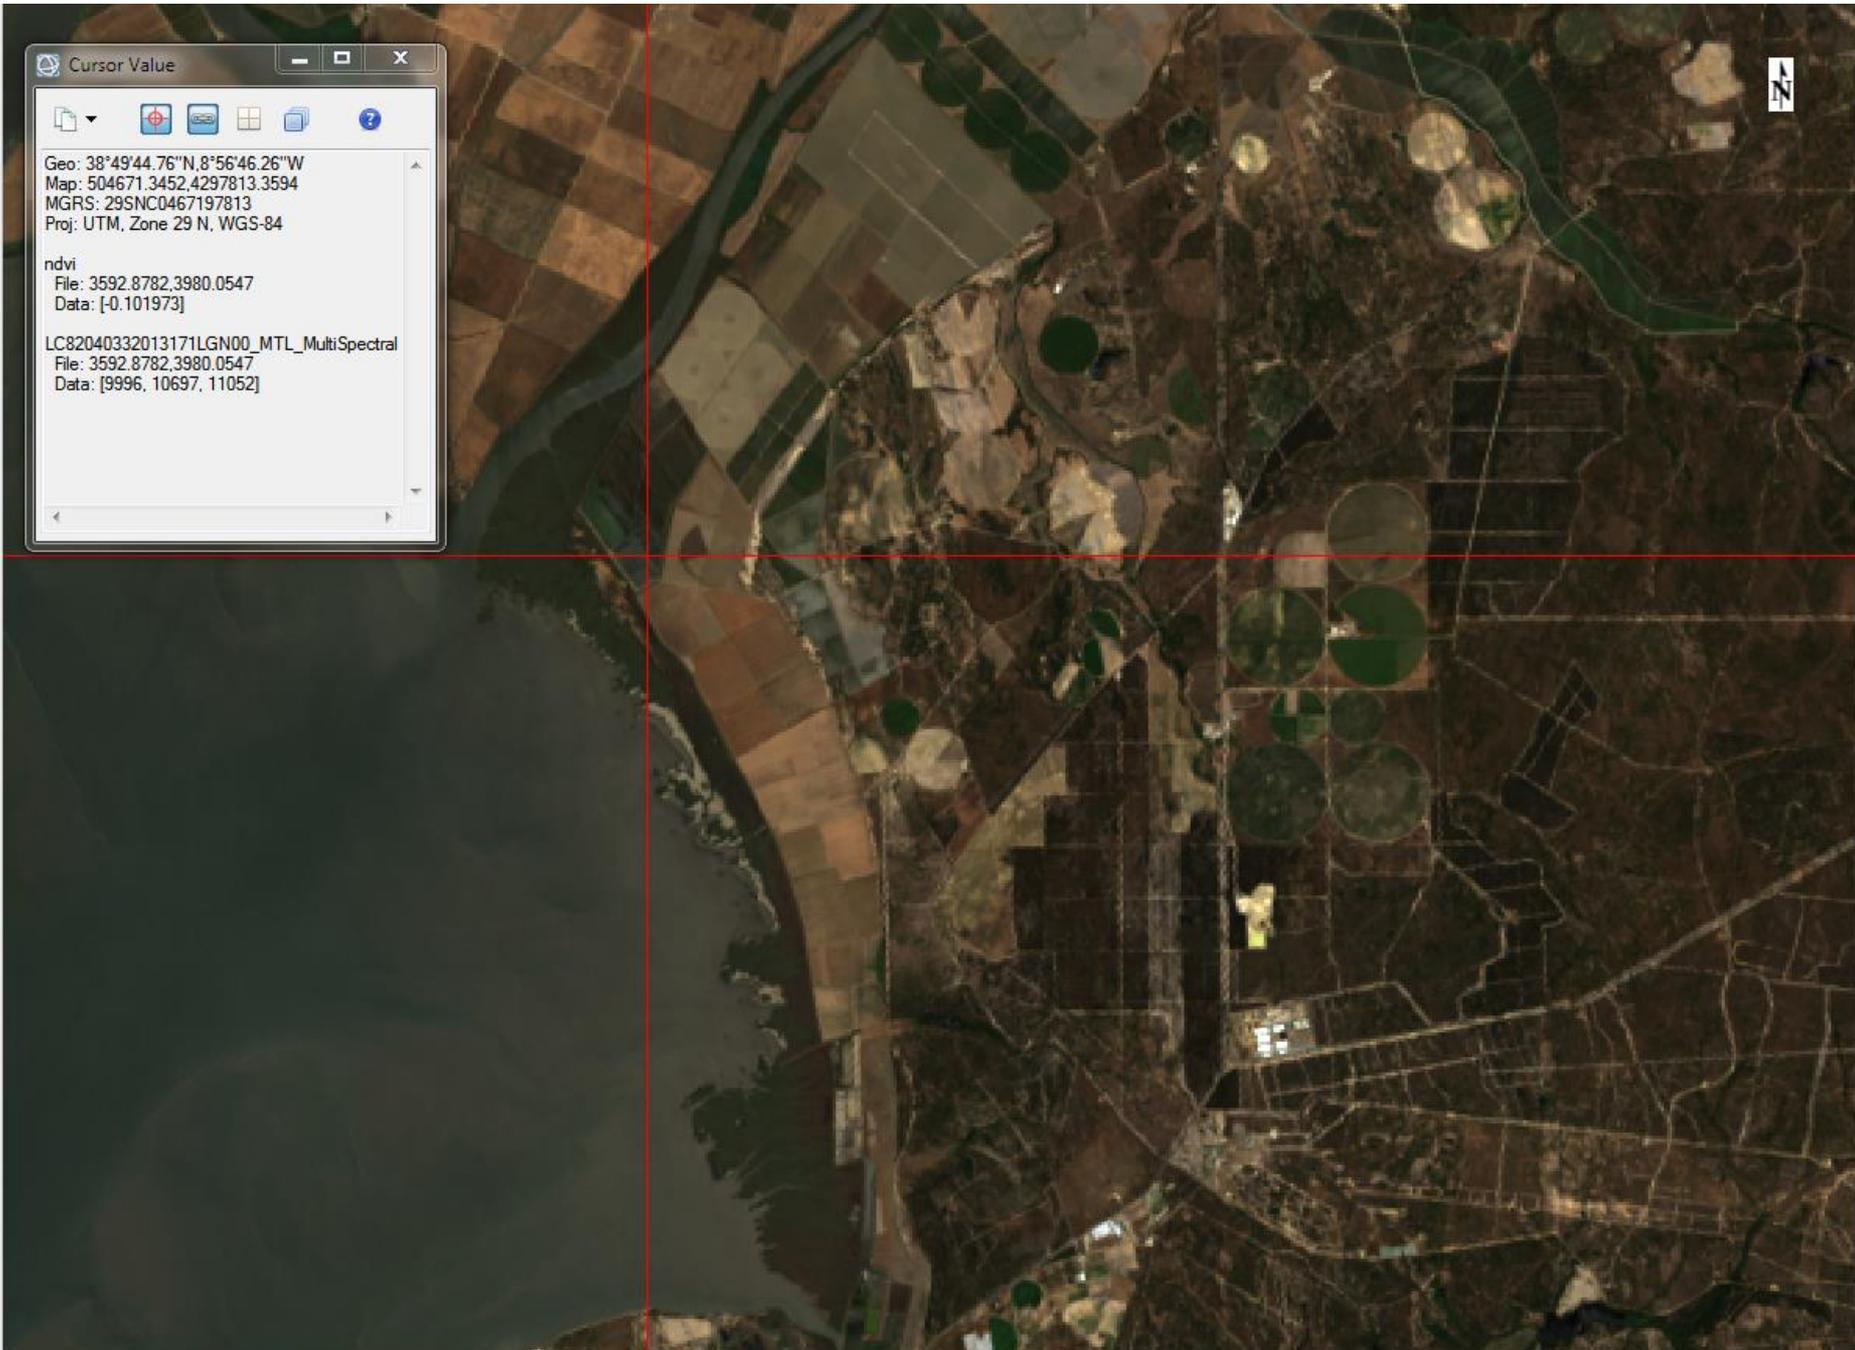


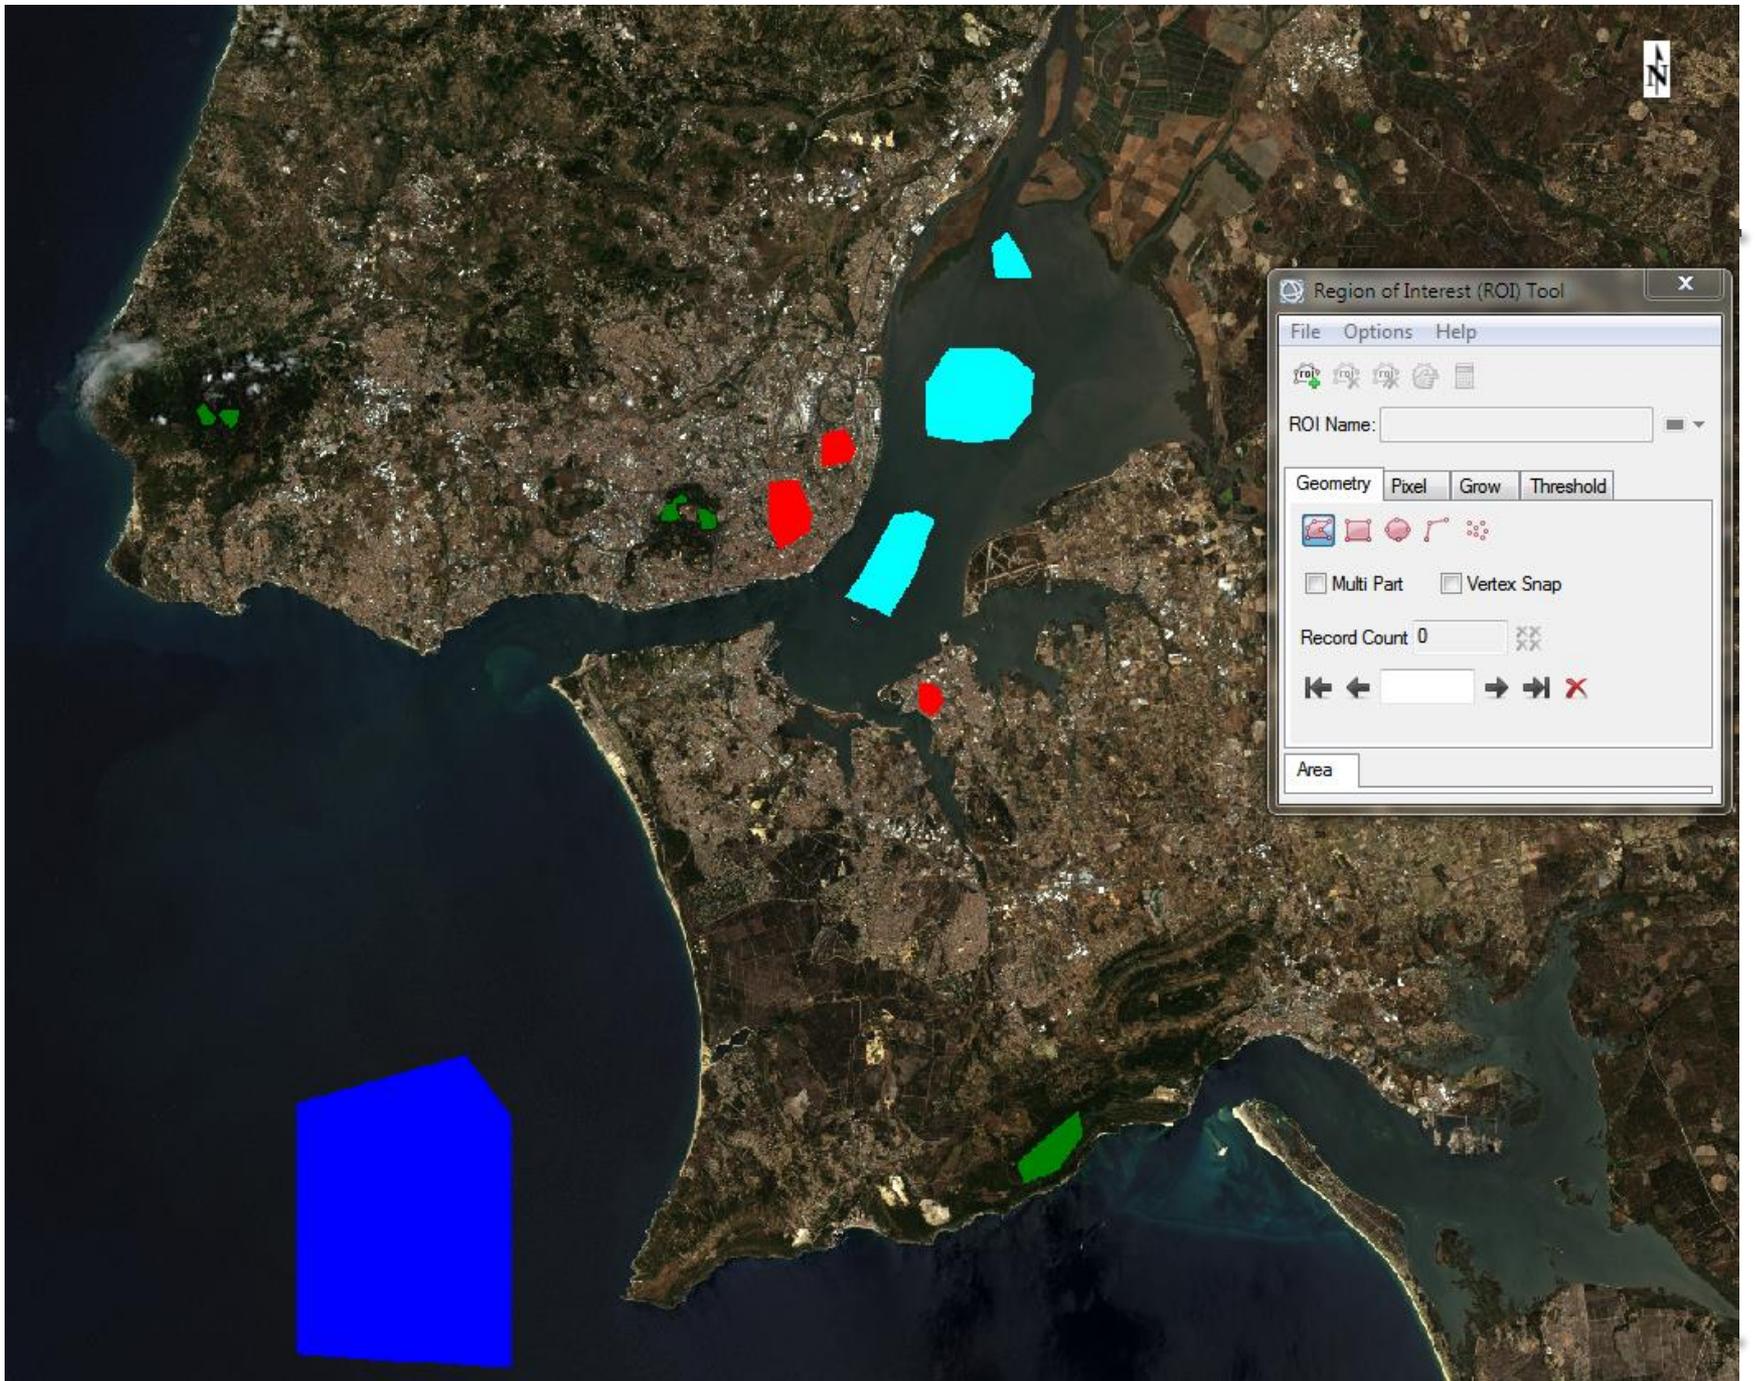
Cursor Value

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

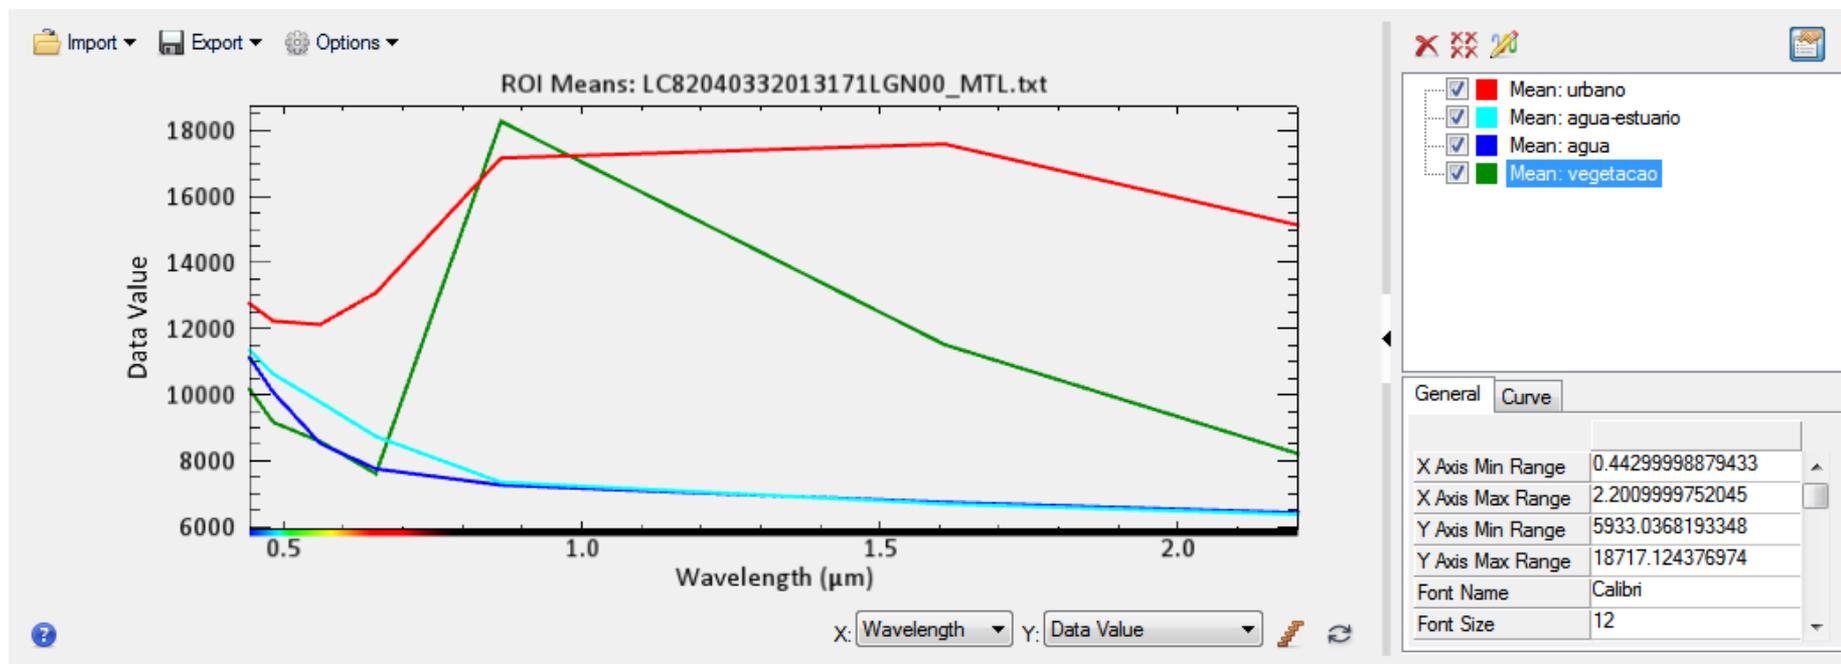
Multi Part  Vertex Snap

Record Count 0

Area

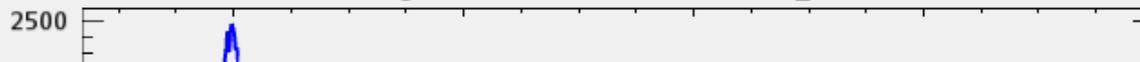


# Spectral Reflectance



Import Export Options

Histograms: LC82040332013171LGN00\_MTL.txt

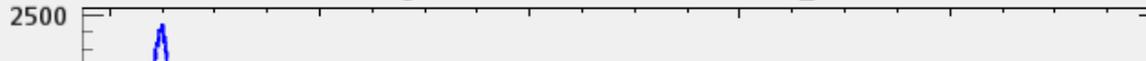


Legend for Band 2:

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

Import Export Options

Histograms: LC82040332013171LGN00\_MTL.txt

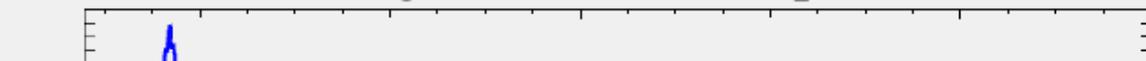


Legend for Band 3:

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

Import Export Options

Histograms: LC82040332013171LGN00\_MTL.txt

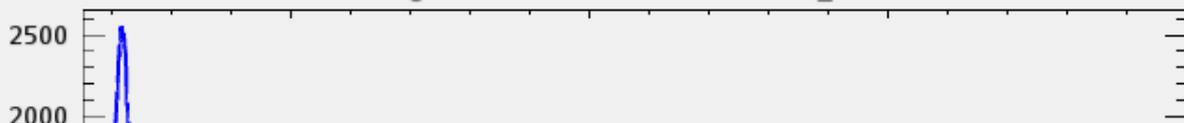


Legend for Band 4:

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

Import Export Options

Histograms: LC82040332013171LGN00\_MTL.txt

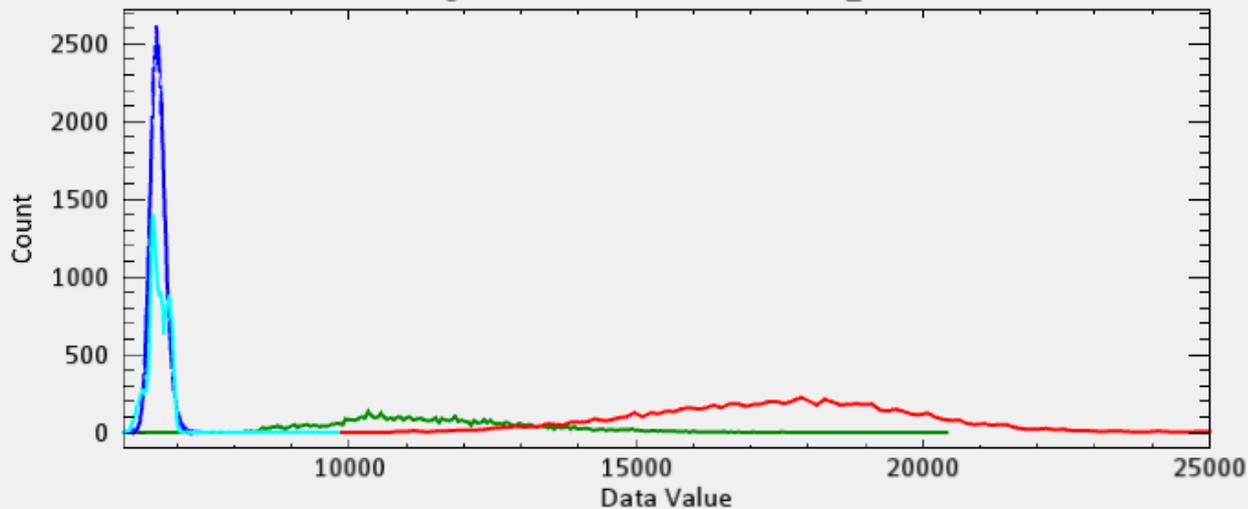


Legend for Band 5:

- 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:

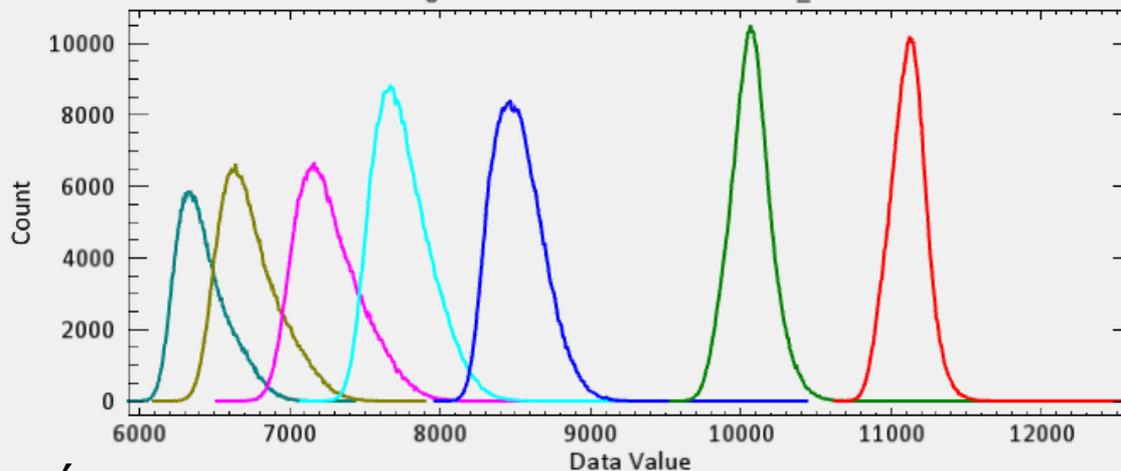
- Histogram: Band 6: urbano
- Histogram: Band 6: agua-estuario
- Histogram: Band 6: agua
- Histogram: Band 6: vegetacao

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

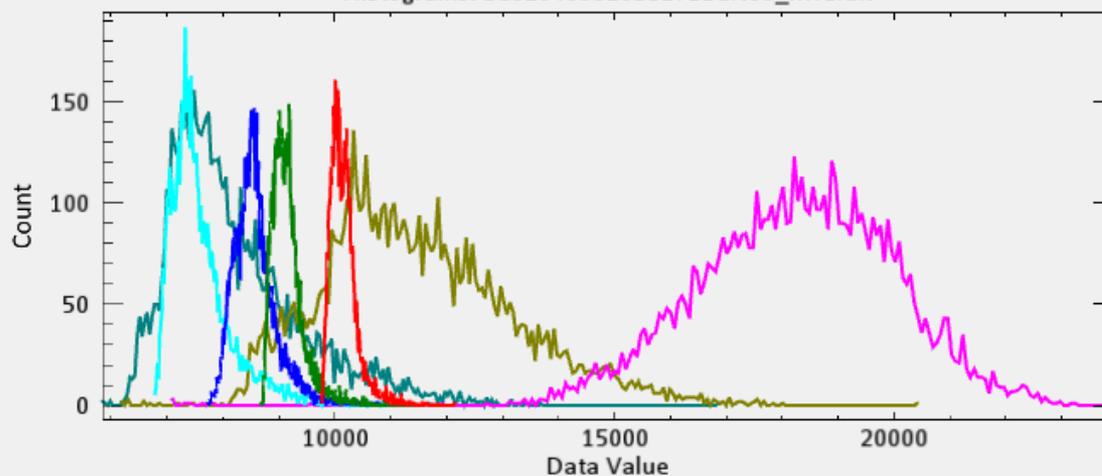
- Histogram: Band 1
- Histogram: Band 2
- Histogram: Band 3
- Histogram: Band 4
- Histogram: Band 5
- Histogram: Band 6
- Histogram: Band 7

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               |



# Burned Area Indexes

| Índices | Designação                             | Referência               |
|---------|--|--------------------------|
| NDVI    | Normalized Difference Vegetation Index | Rouse et al., 1974       |
| GEMI    | Global Environmental Monitoring Index  | Pinty & Verstraete, 1992 |
| BAI     | Burned Area Index                      | Martín et al., 1998      |
| BAIMS   |  | Martín et al., 2005      |
| BAIML   |  |                          |
| NBRS    | Normalized Burn Ratio                  | Key & Benson, 1999       |
| NBRL    |  |                          |
| MIRBI   | Mid Infrared Burned Index              | Trigg & Flasse, 2001     |

NDVI

$$\frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}$$

GEMI

$$\frac{\eta(1-0.25\eta) - (\rho_R - 0.125)}{(1-\rho_R)} \eta = \frac{2(\rho_{NIR}^2 - \rho_R^2) + 1.5\rho_{NIR} + 0.5\rho_R}{(\rho_R + \rho_{NIR} + 0.5)}$$

BAI

$$\frac{1}{(\rho_{NIR} - \rho_{cNIR})^2 + (\rho_R - \rho_{cR})^2}$$

NBRS

$$\frac{\rho_{NIR} - \rho_{SSWIR}}{\rho_{NIR} + \rho_{SSWIR}}$$

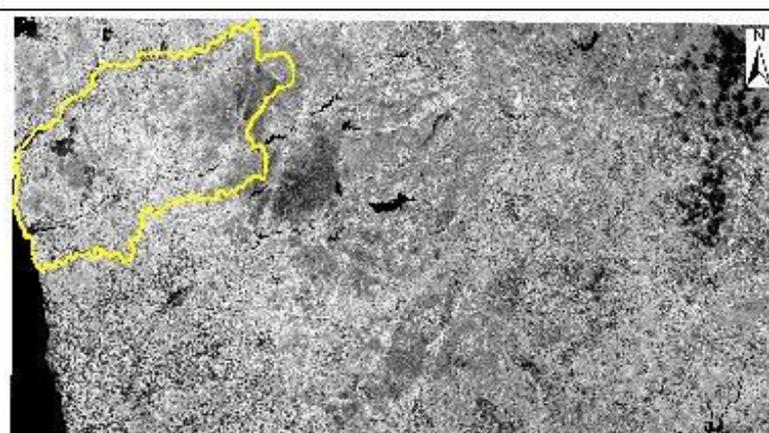
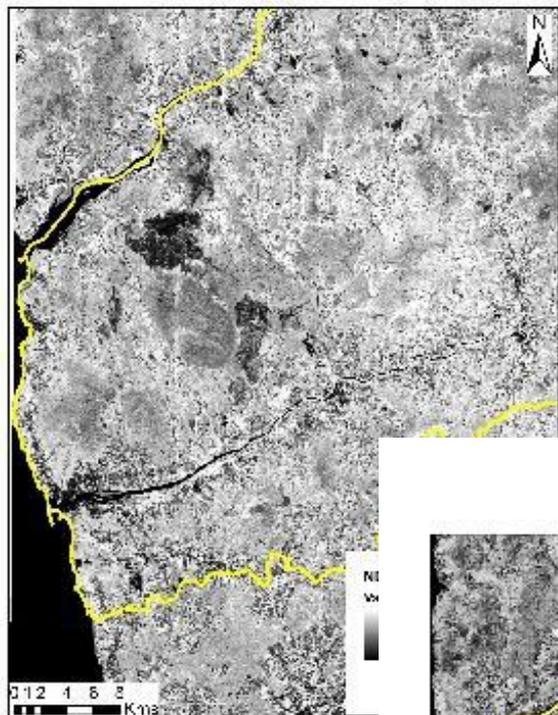
BAIMS

$$\frac{1}{(\rho_{NIR} - \rho_{cNIR})^2 + (\rho_{SSWIR} - \rho_{cSSWIR})^2}$$

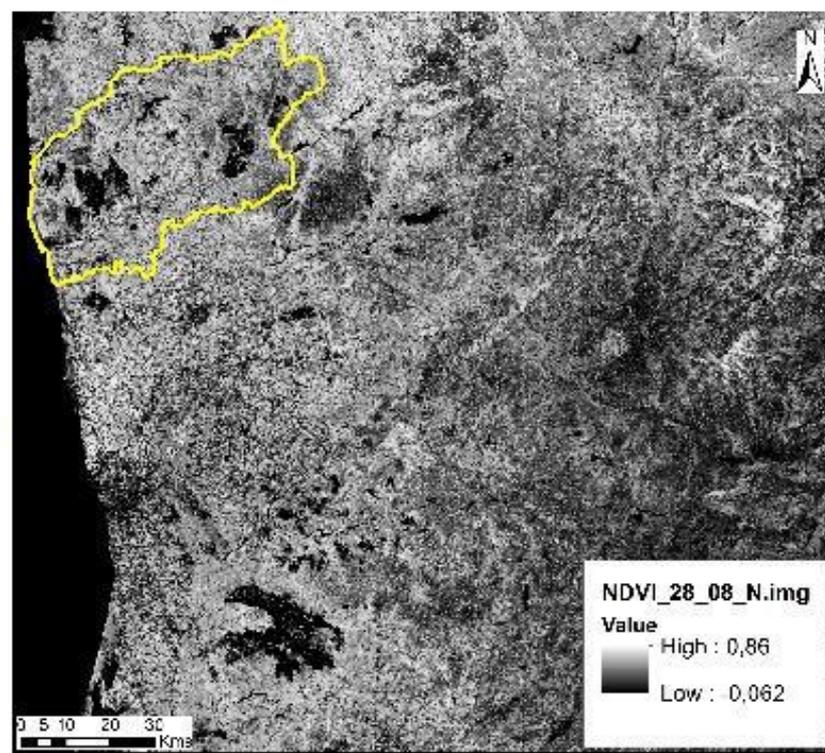
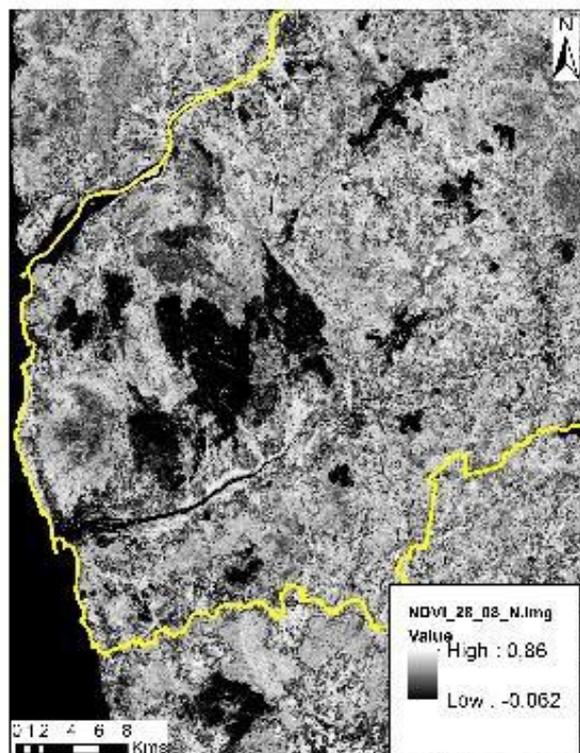
NBRL

$$\frac{\rho_{NIR} - \rho_{LSWIR}}{\rho_{NIR} + \rho_{LSWIR}}$$

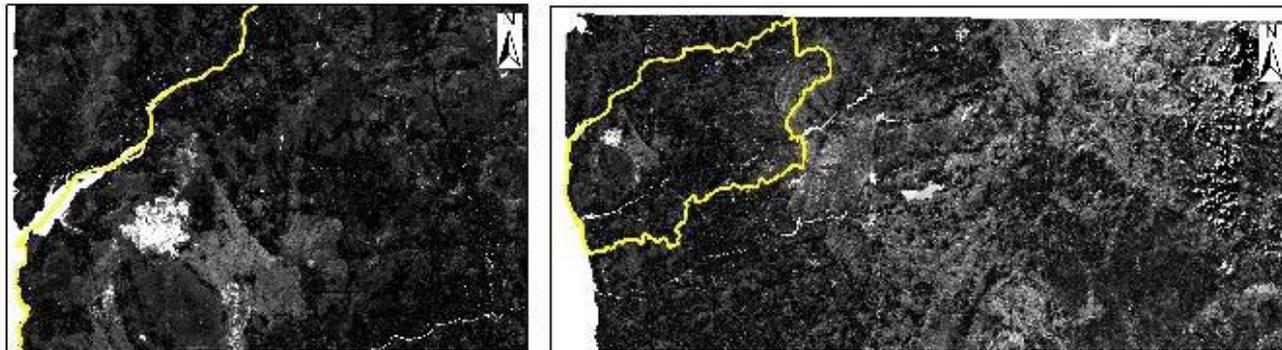
Indice NDVI 30-04-2016



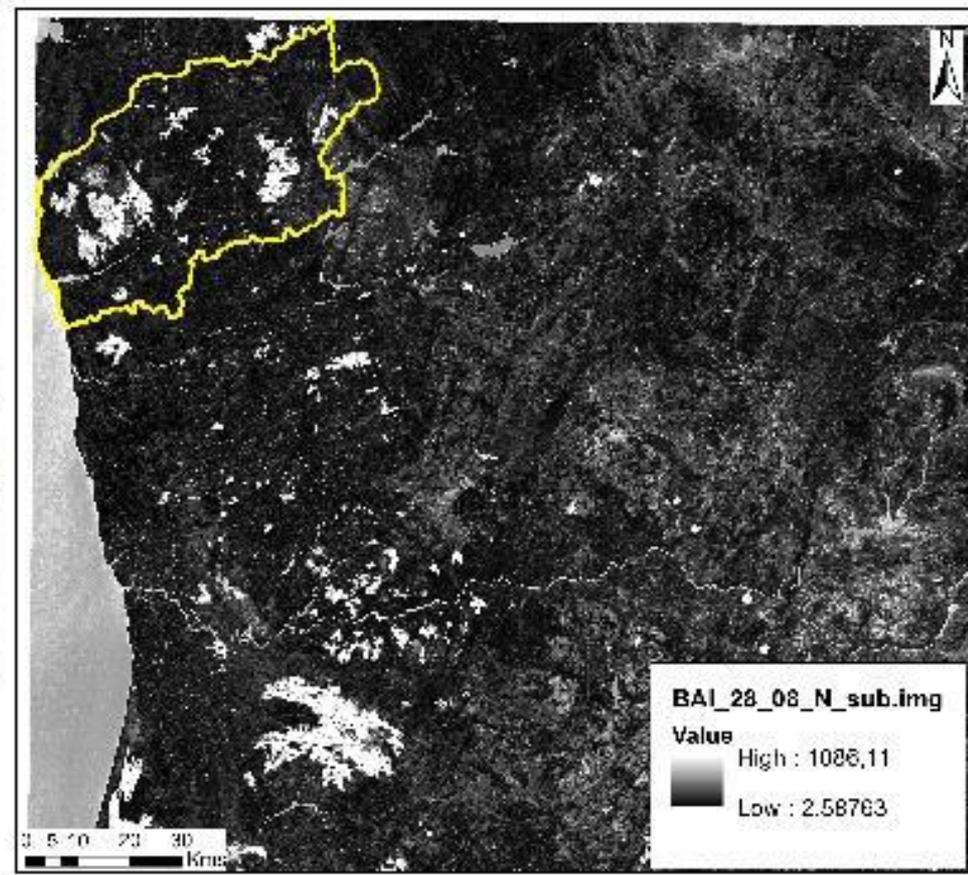
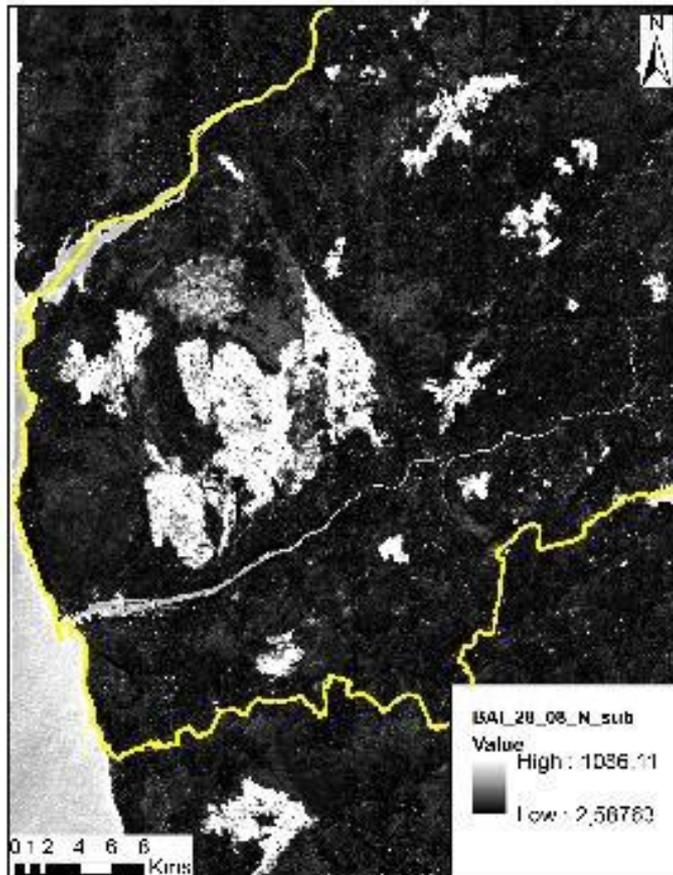
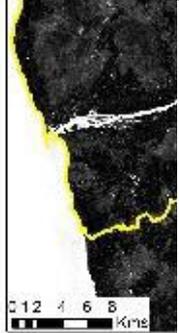
Indice NDVI 28-08-2016



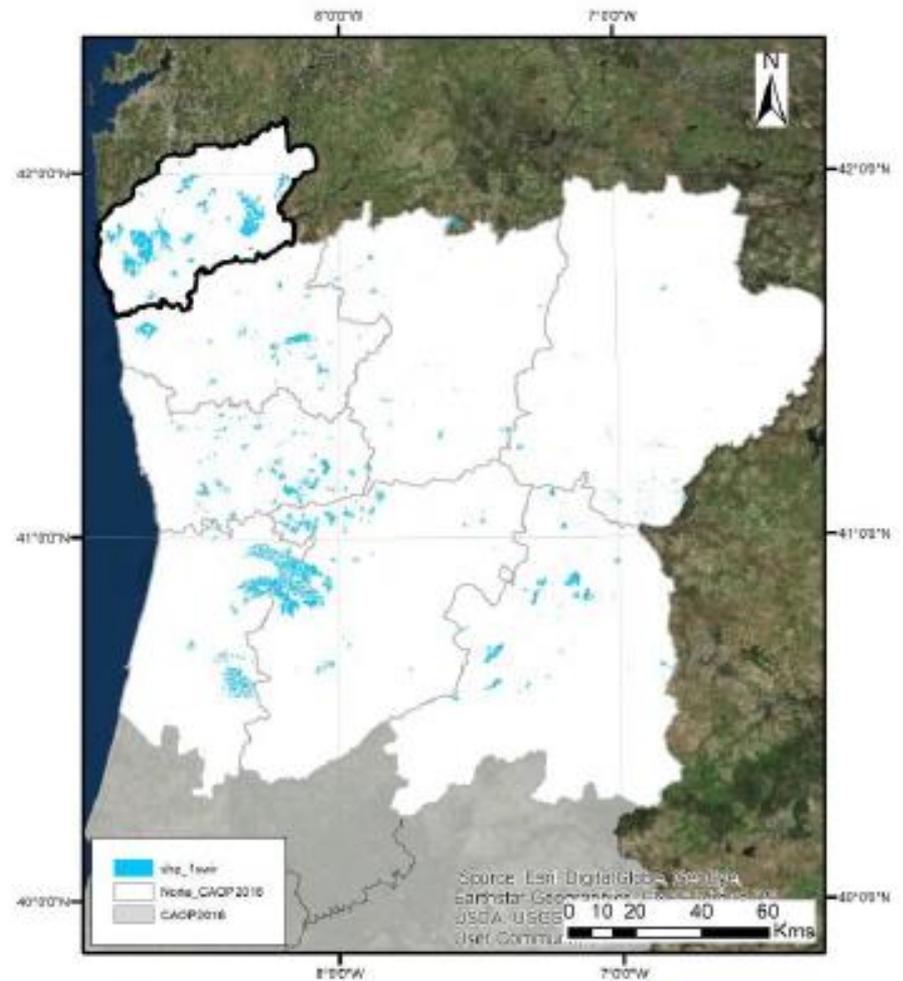
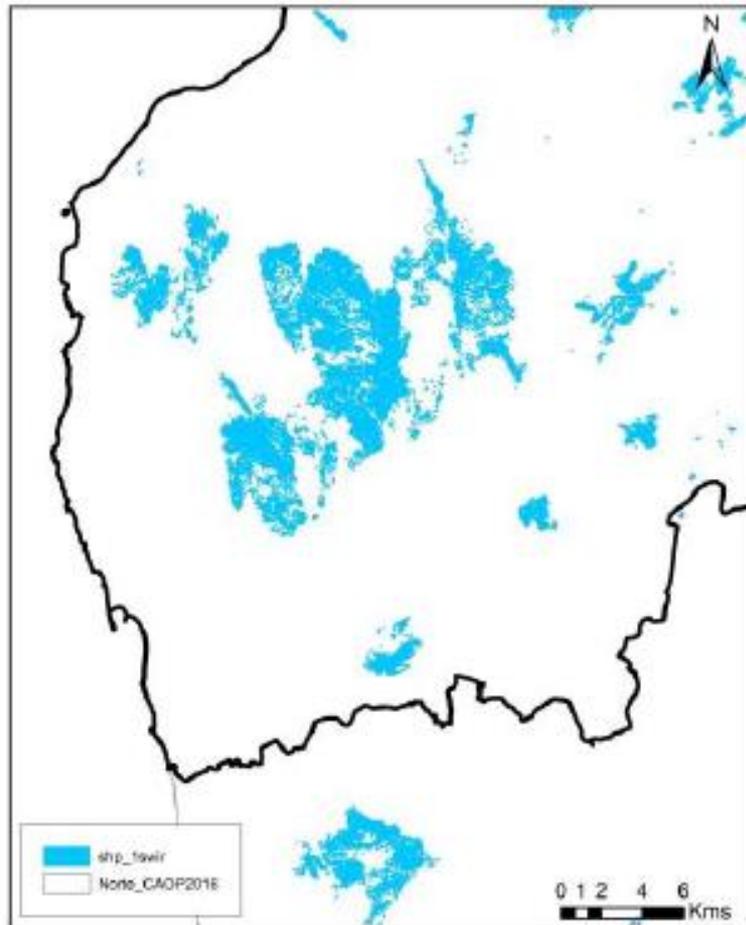
Indice BAI 30-04-2016



Indice BAI 28-08-2016



## Áreas ardidas calculadas (VIS+NIR+1SWIR), 2016



## Cartografia da área ardida em 2017 – Pinhal de Leiria

---



*Figura 2- Imagem SENTINEL-2 de 5 de outubro*

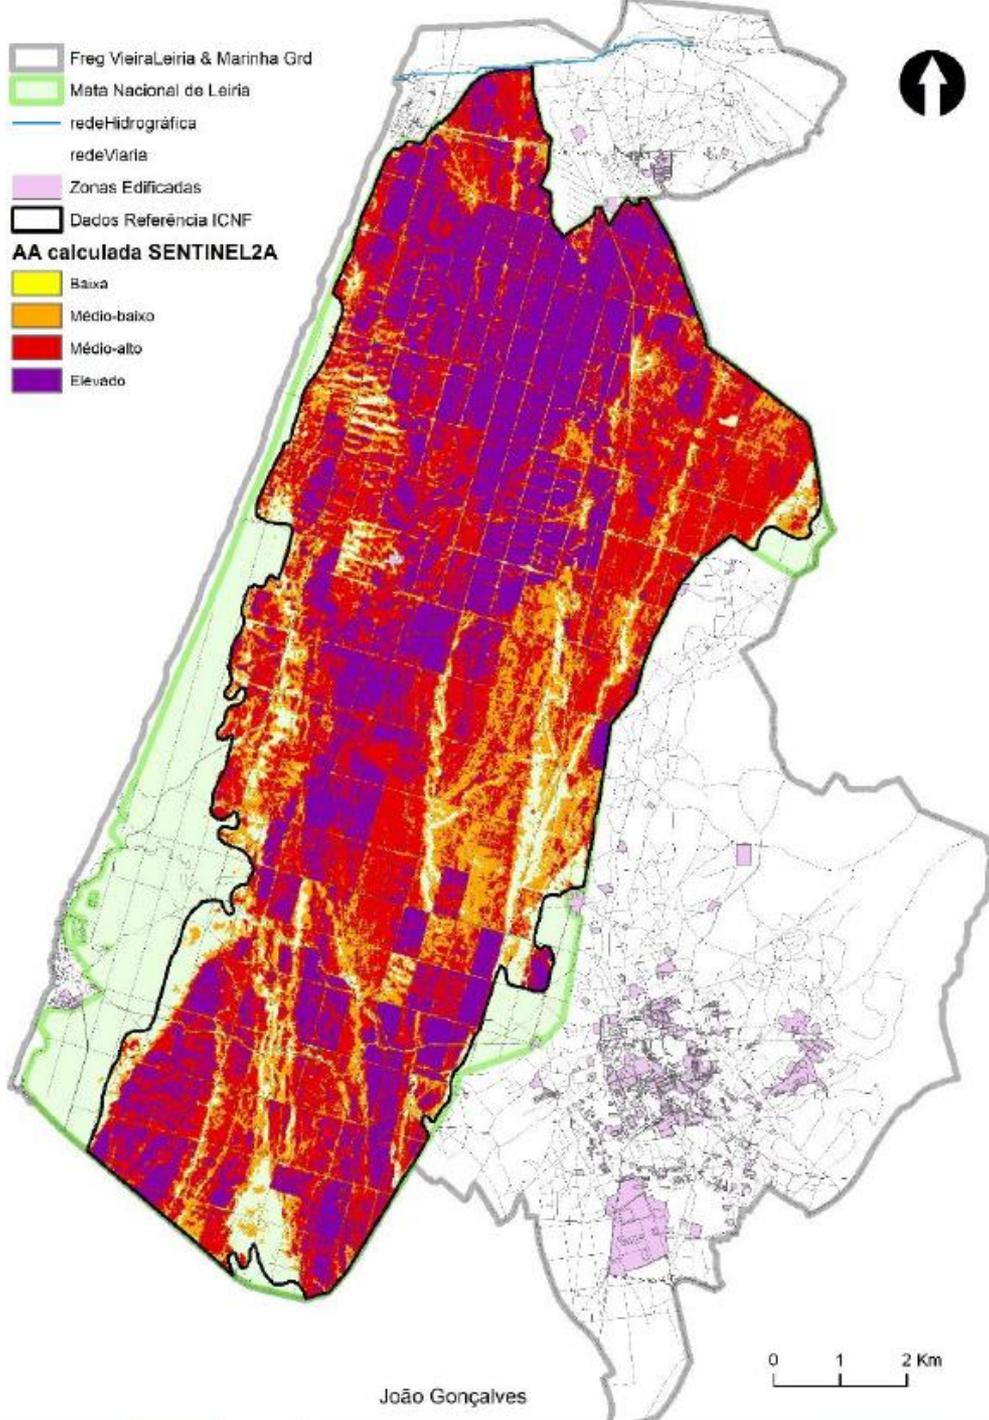


*Figura 3 - Imagem SENTINEL-2 de 22 de outubro*

-  Freg VieiraLeiria & Marinha Grd
-  Mata Nacional de Leiria
-  redeHidrográfrica
-  redeViaría
-  Zonas Edificadas
-  Dados Referência ICNF

**AA calculada SENTINEL2A**

-  Baixa
-  Médio-baixo
-  Médio-alto
-  Elevado



The European Space Agency is organising the **8th Advanced Training Course on Land Remote Sensing** which will be held at the **University of Leicester, United Kingdom, from 10-14 September 2018.**

The course is organised by ESA in cooperation with the National Centre for Earth Observation (NCEO) and the University of Leicester.

The training course aims at:

Training the next generation of scientists on remote sensing of land surfaces and processes;

Explaining the theoretical principles, processing algorithms, data products and their use in applications;

Introducing tools and methods for the exploitation of EO satellite data, in particular the Sentinels;

Stimulating and supporting the exploitation of ESA and non-ESA EO data for land remote sensing science and applications.

Postgraduate-level, Ph.D. students, post-doctoral research scientists and users from Europe and Canada interested in land remote sensing and its applications are welcome to apply to the 5-day course. Research scientists and students from all other countries are also welcome to apply subject to availability of spaces.

**Further information** about the course **and the application form** are available on line @ <http://eoscience.esa.int/landtraining2018>

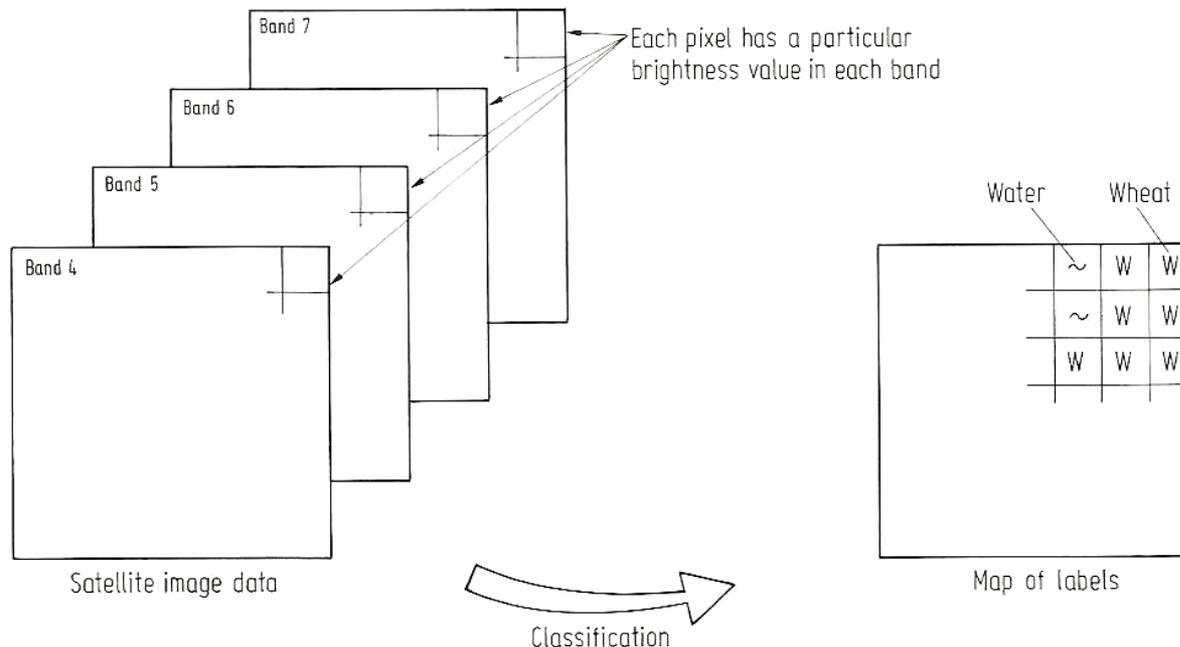
**The deadline for applications is 8 June 2018.**

# 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

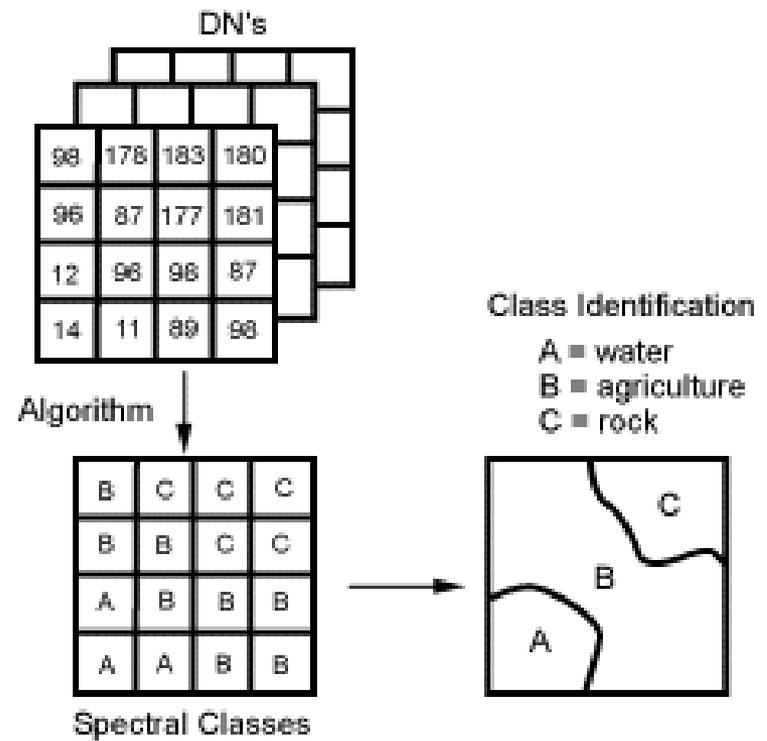
ISOData  
K-Means  
Redes Neuronais

# Unsupervised methods

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

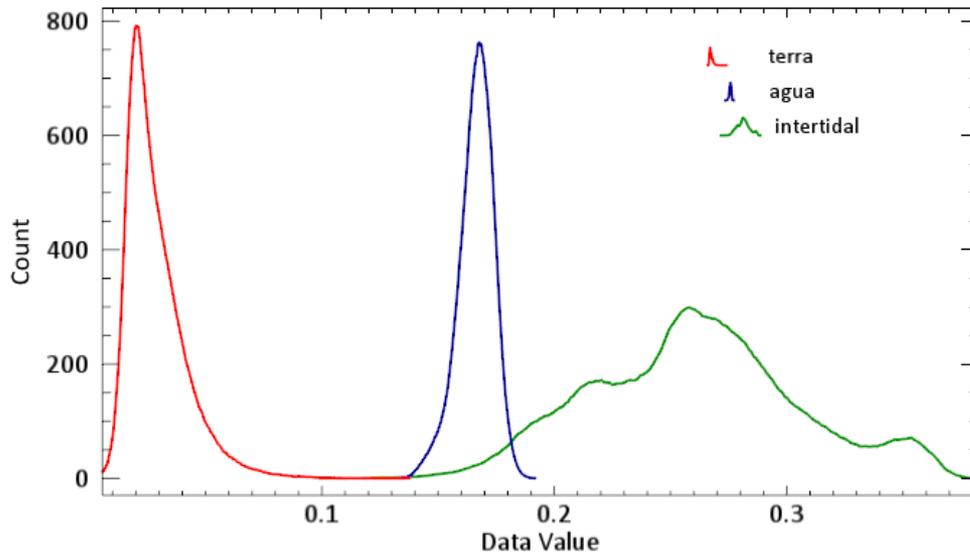
Este método baseia-se em algoritmos que analisam todos os pixéis e formam conjuntos de pixéis (os chamados *cluster* ou padrão) apenas olhando ao valores dos pixéis.

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

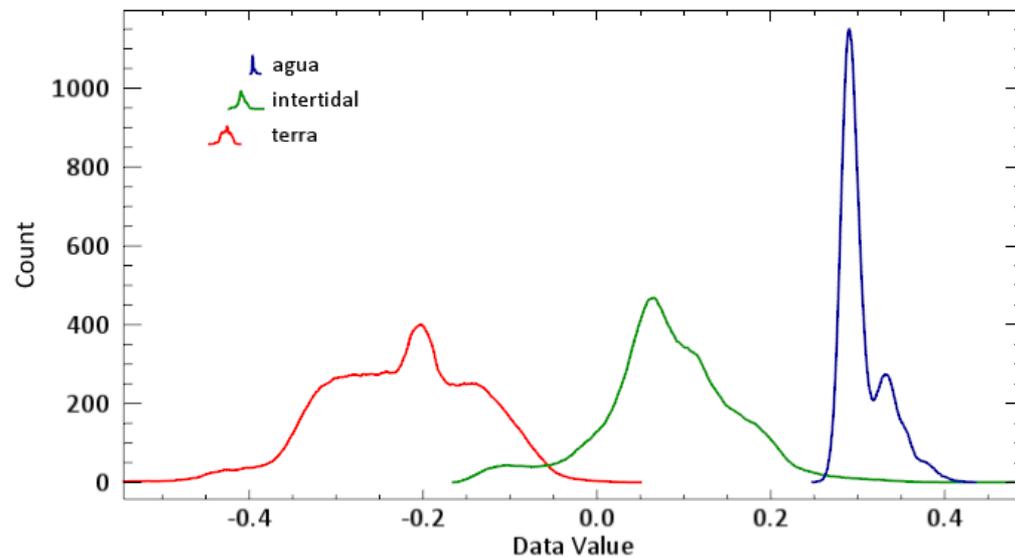


Band 1

**Two bands / 3 classes**

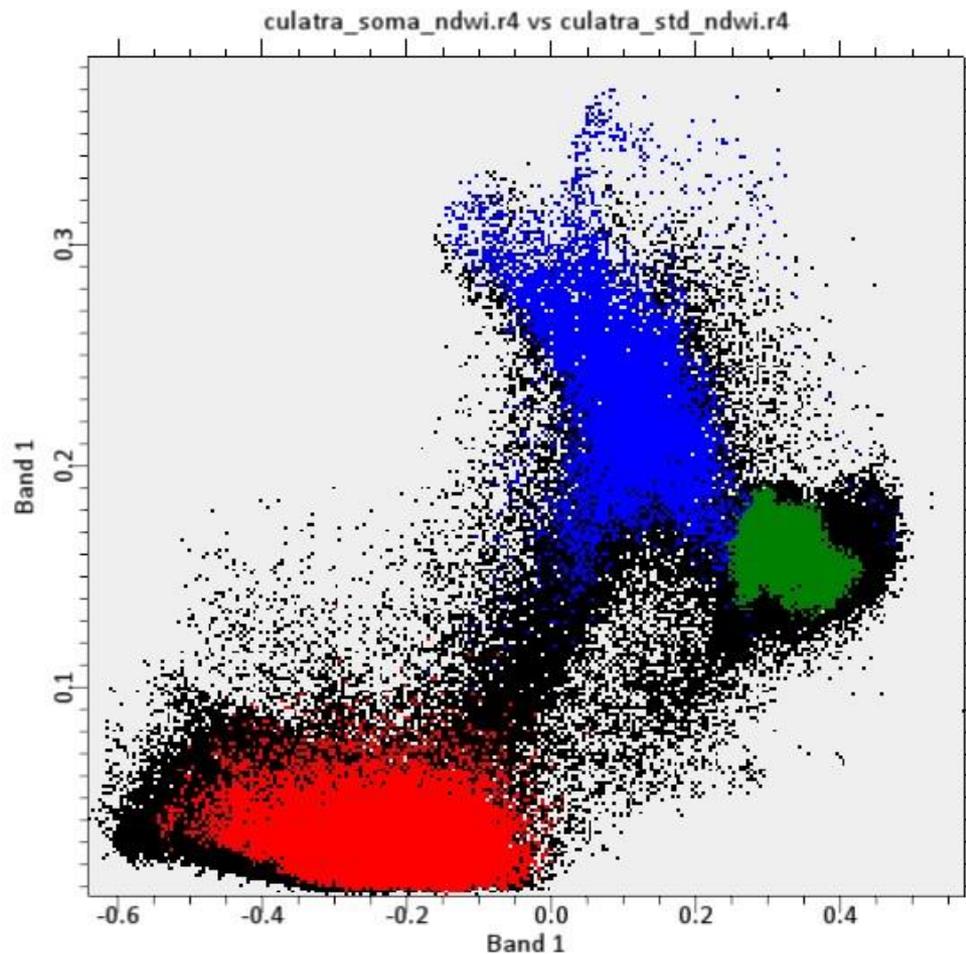
Band 2

NDWI temporal mean



# 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.

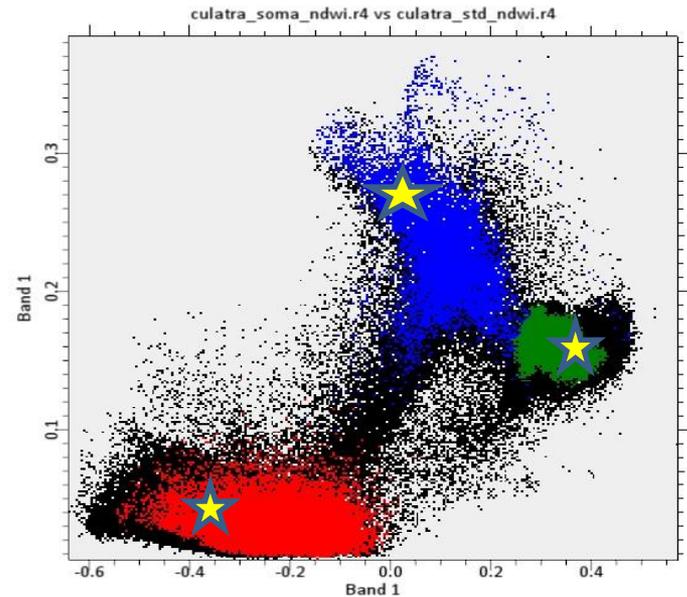
Cada iteração recalcula a média e reclassifica os pixels relativamente à nova média

Todos os pixels 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

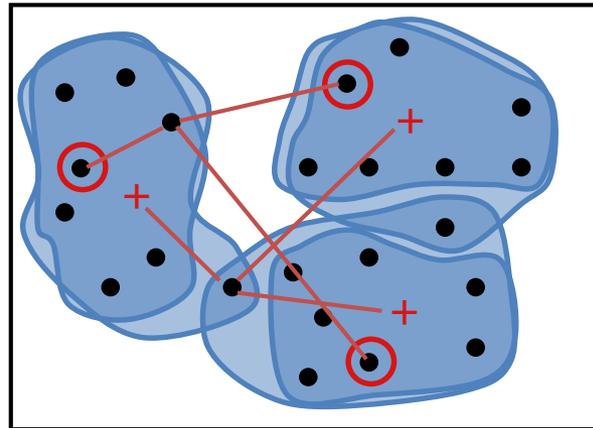


**Centróide** = centro de gravidade do cluster

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

# Algoritmo K-means

Exemplo K = 3



2ª Iteração

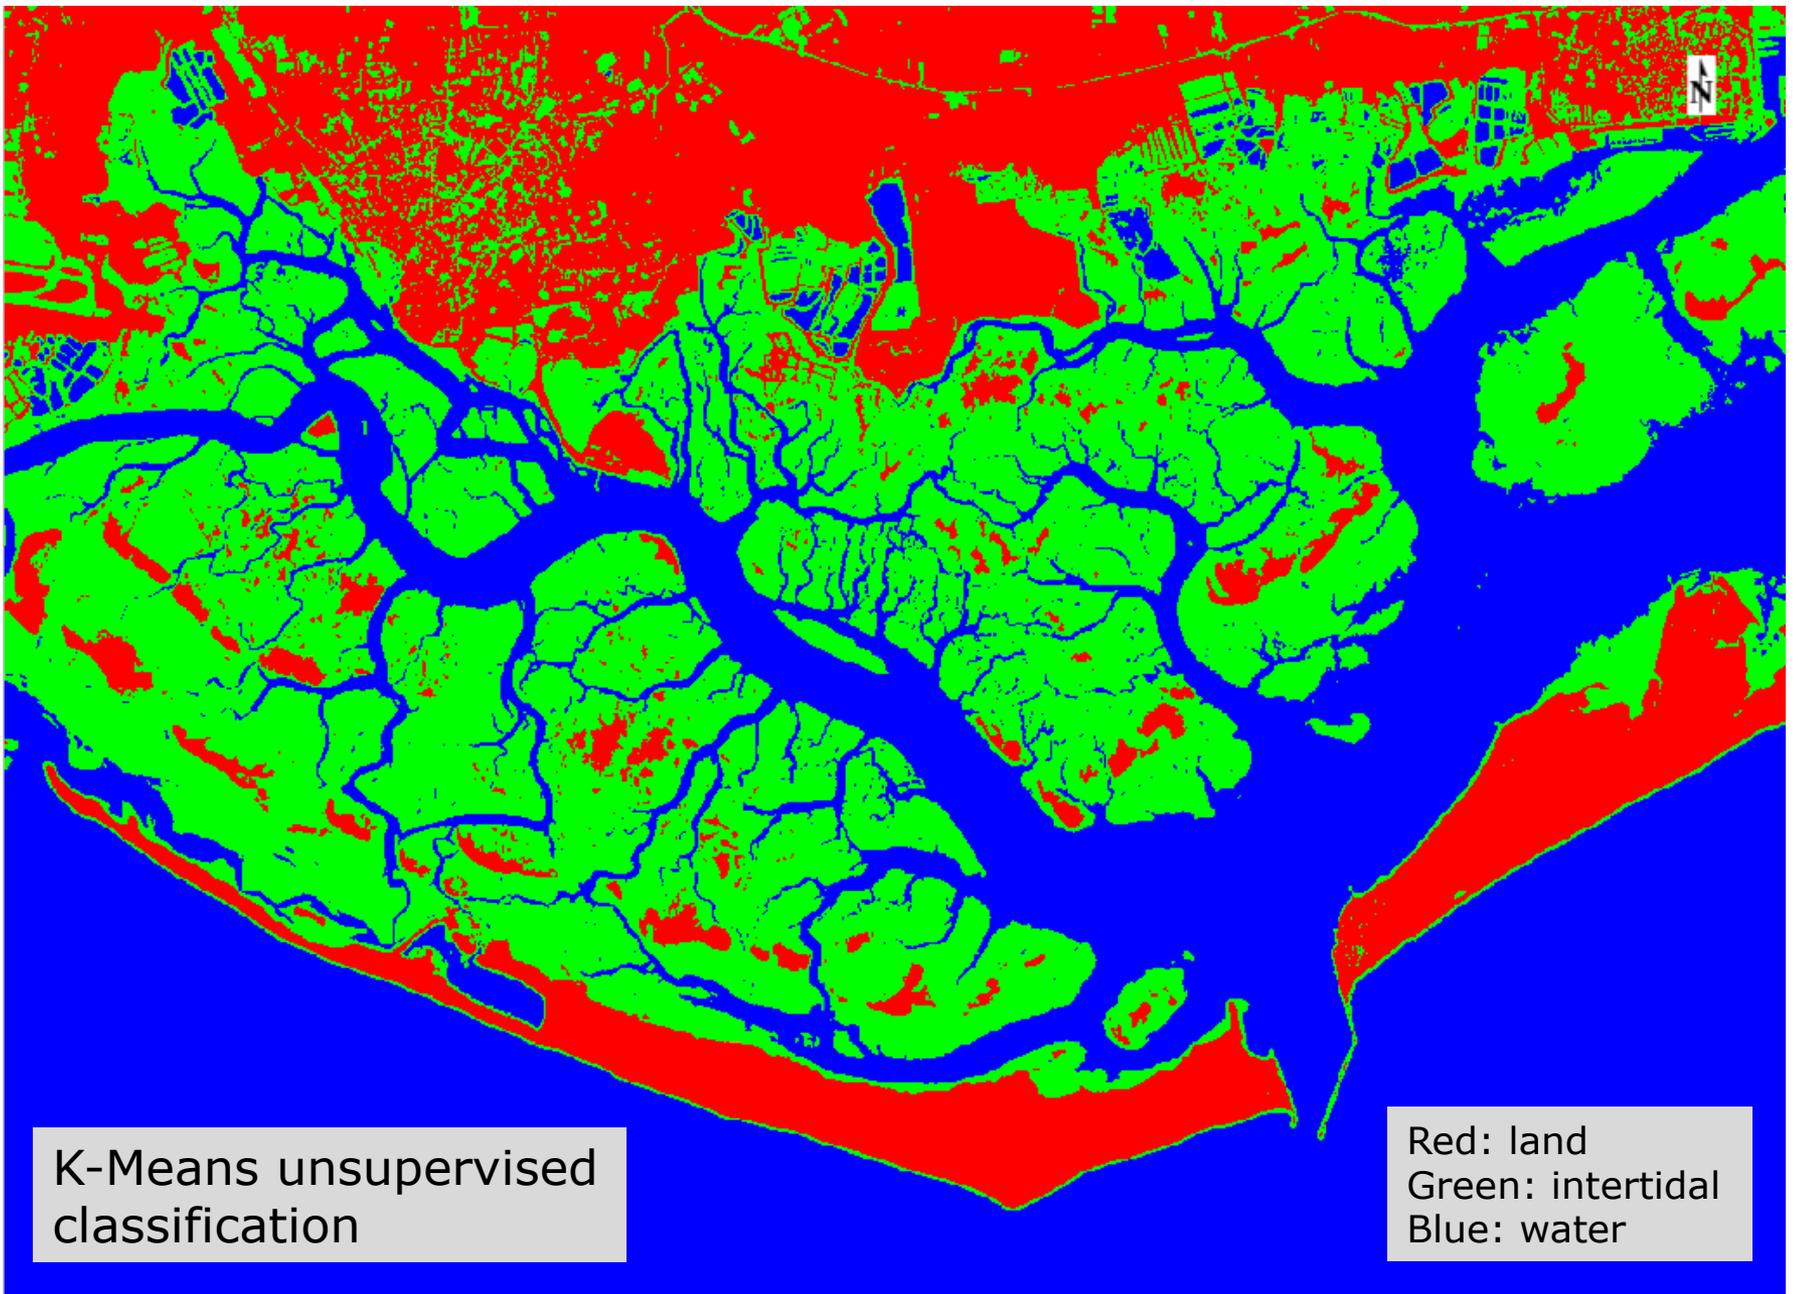




The image shows a grayscale aerial photograph of a river delta with a complex network of channels. A dialog box titled "K-Means Parameters" is overlaid on the image. The dialog box contains the following fields and controls:

- Number of Classes: 3
- Change Threshold % (0-100): 5.00
- Maximum Iterations: 1
- Maximum Stdev From Mean: [empty text box]
- Maximum Distance Error: [empty text box]
- Output Result to:  File  Memory
- Enter Output Filename: Choose
- Output File Path: J:\LinhaAgua\culatra\_ndwi\culatra\_k-means.img
- Buttons: OK, Cancel, Help

Parametros  
k-means





Ciências  
ULisboa

# K-Means unsupervised classification



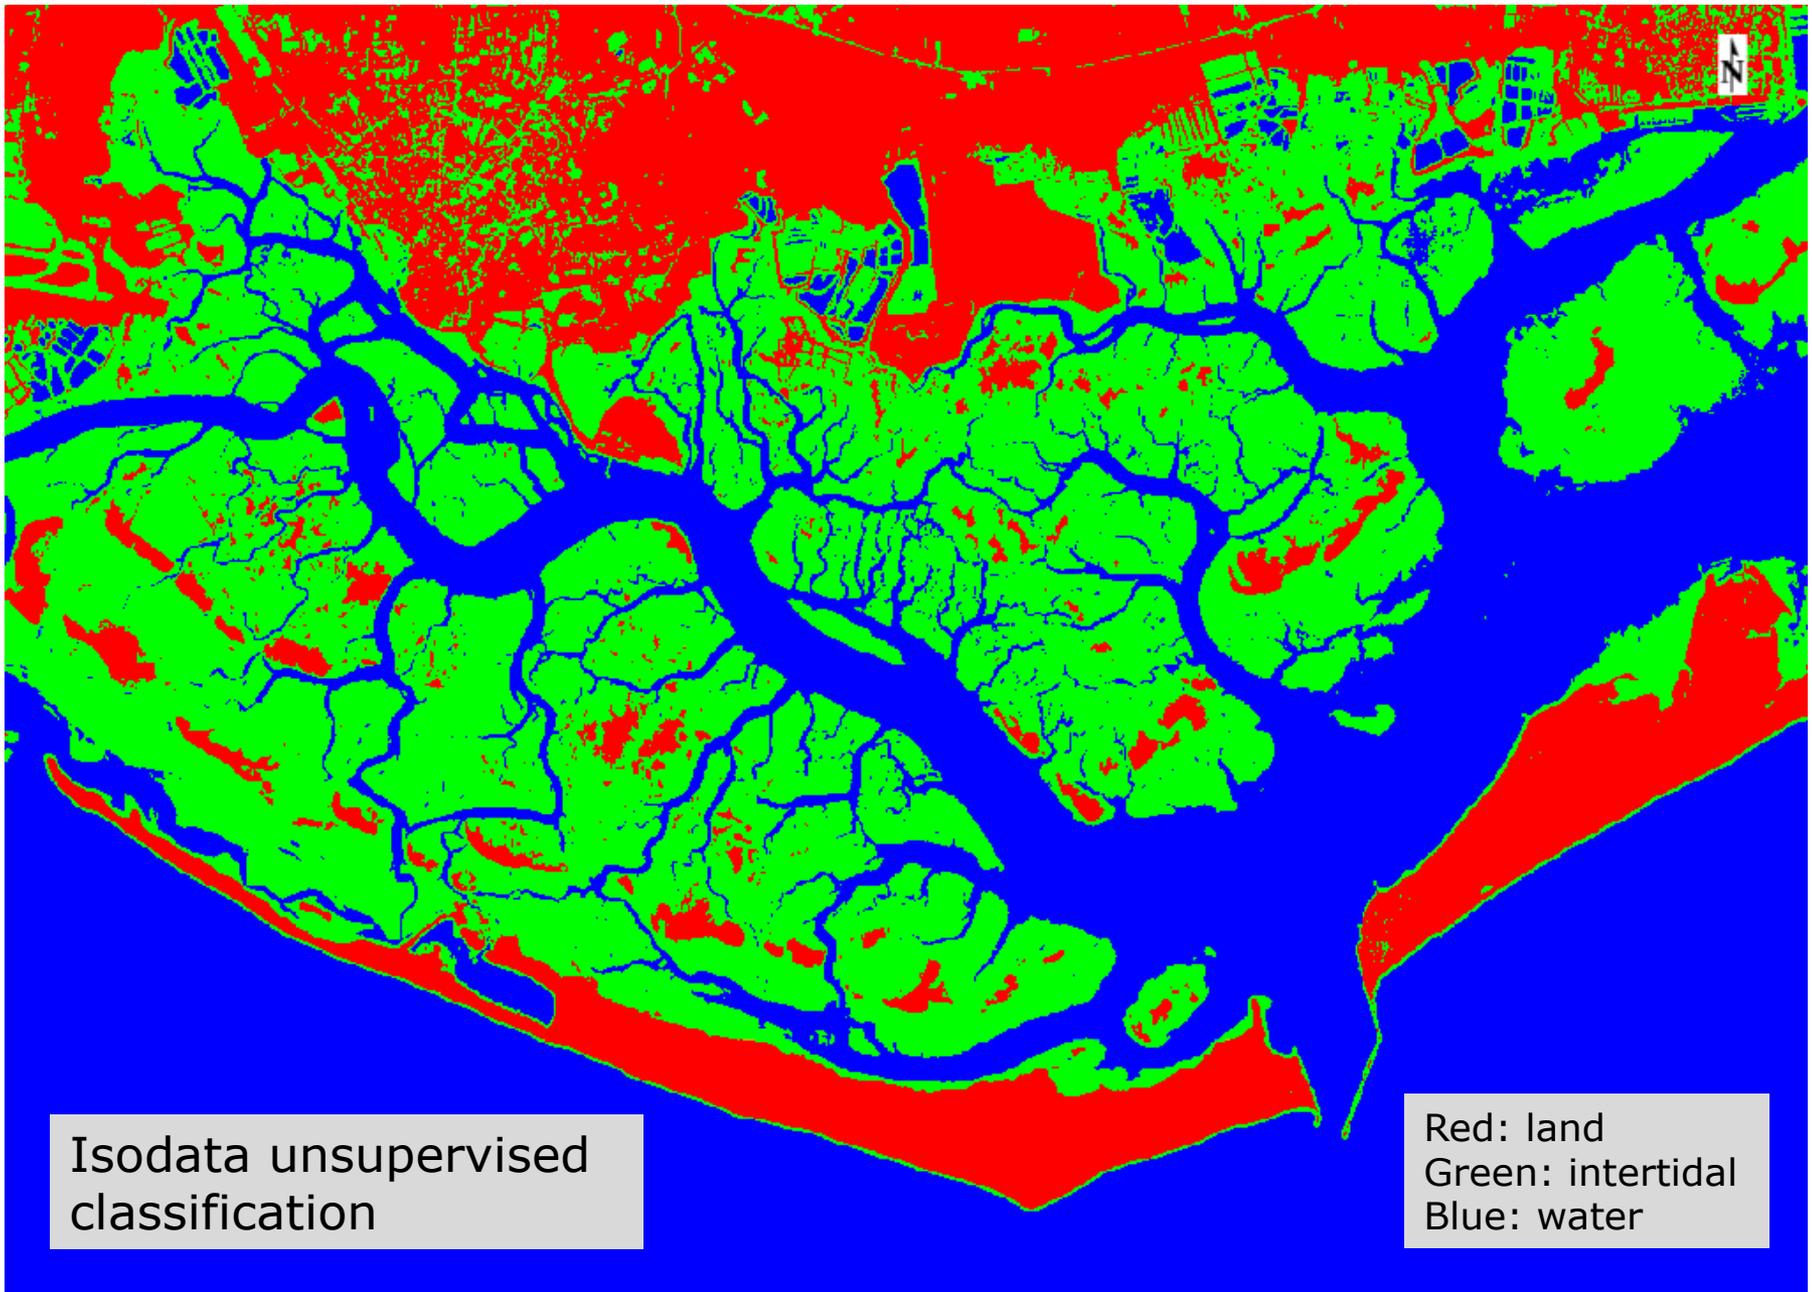
# Unsupervised classification: ISODATA

---

**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

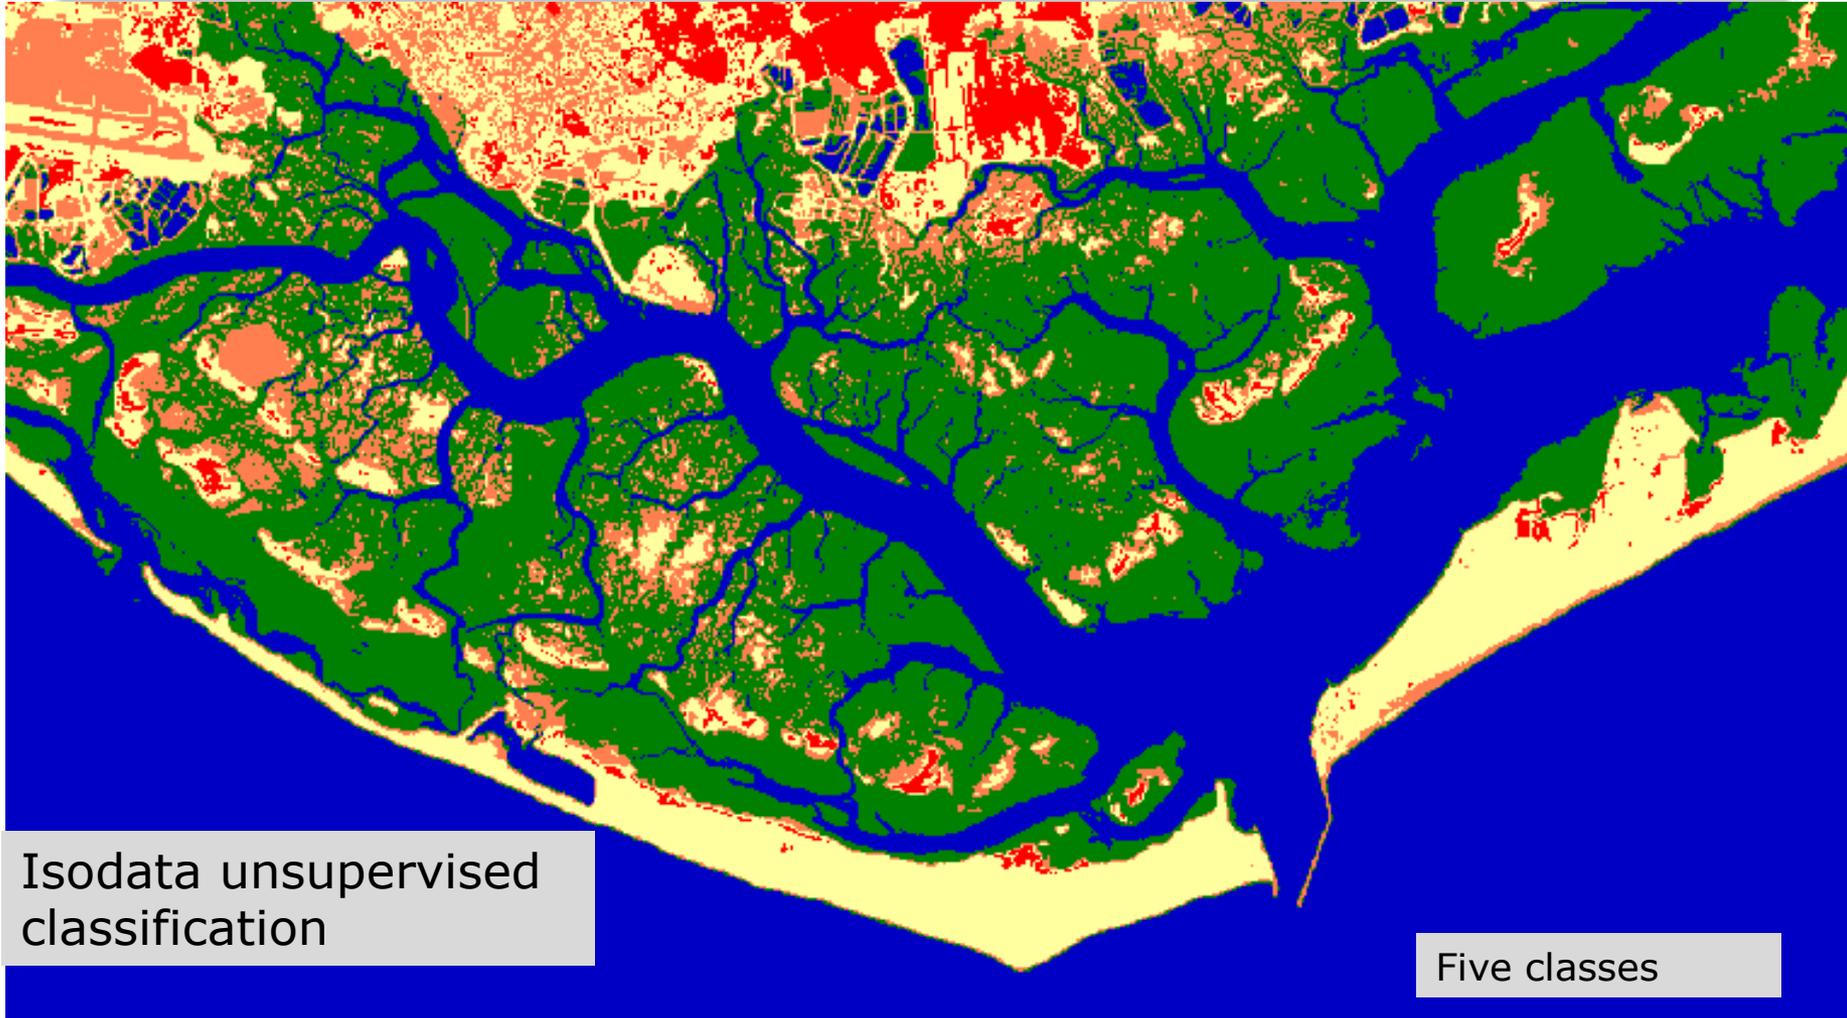
---





Ciências  
ULisboa

# ISODATA unsupervised classification



## 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  $\Sigma$  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:

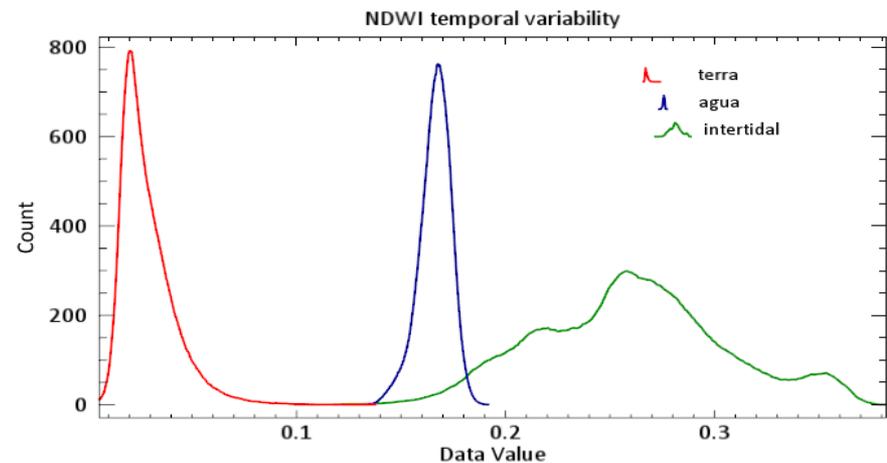
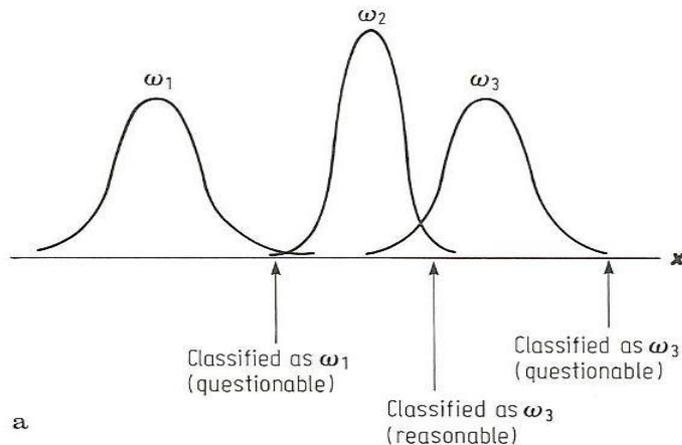
$$g_i(x) = \ln p(w_i) - \frac{1}{2} \ln \left| \Sigma_i \right| - \frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i)$$

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:

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

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 com significativo para a classe espectral  $w_i$ . Neste caso, uma classificação é aceitável se:

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

Ou, equivalentemente:

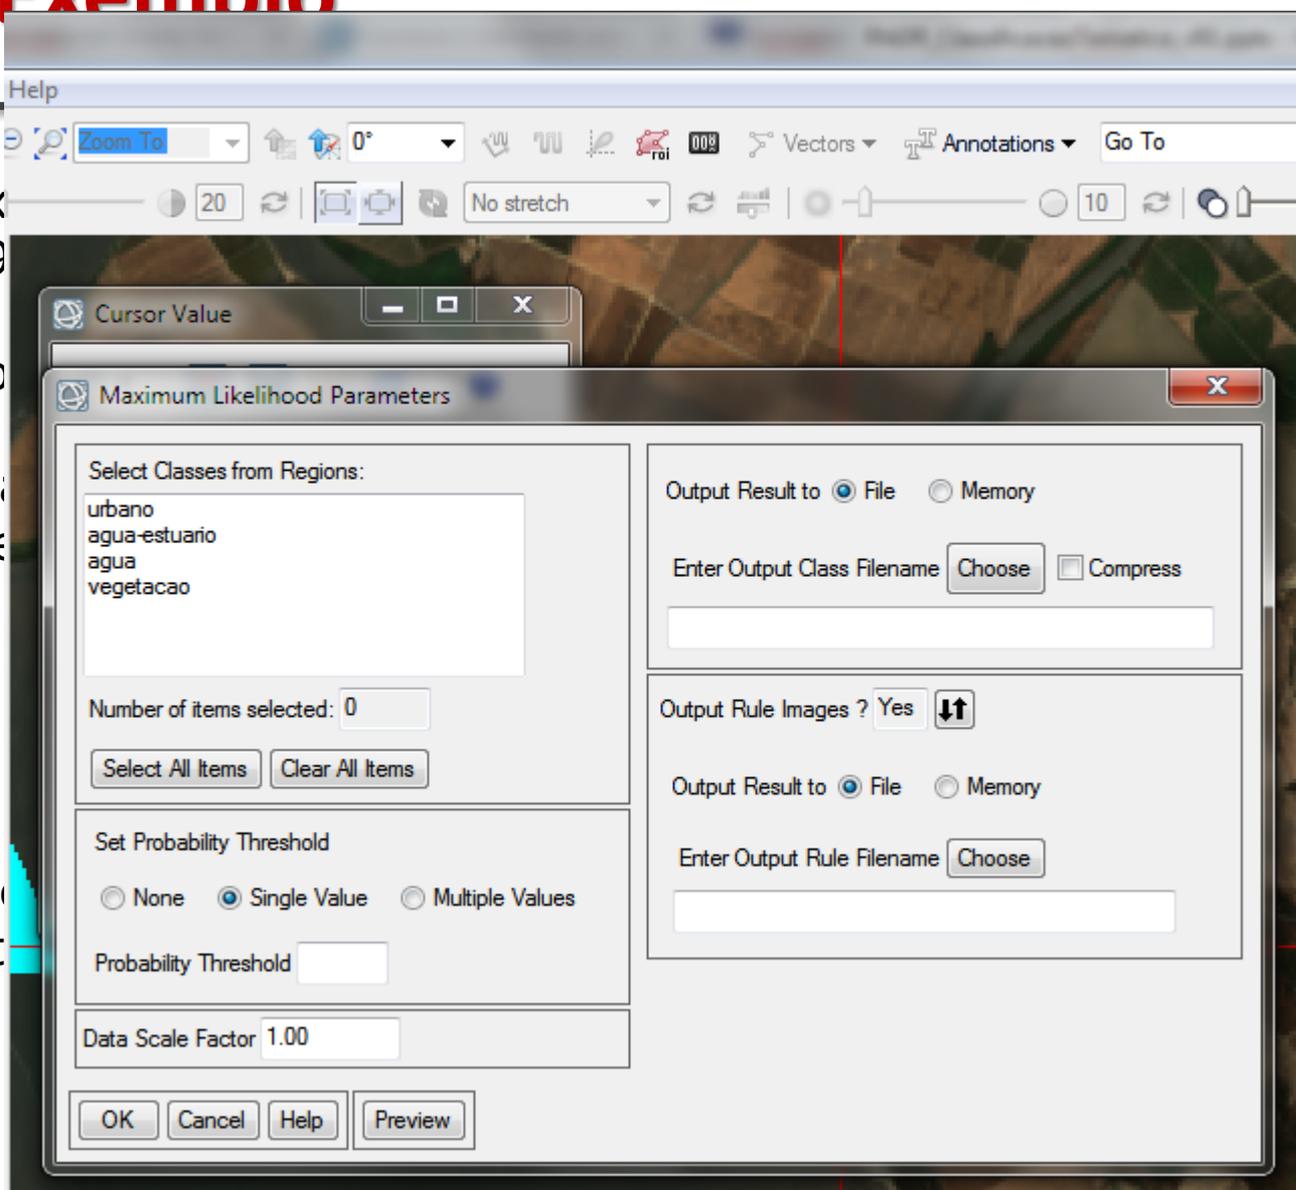
$$(x - m_i)^t \Sigma_i^{-1} (x - m_i) < \underbrace{-2T_i + 2 \ln p(w_i) - \ln \left| \Sigma_i \right|}_{\sim \chi^2}$$

# Exemplo

Como ex  
tal que 9  
ou seja,  
rejeitado

Da tabel  
liberdade

Que pod  
e da dist



das  
dos,

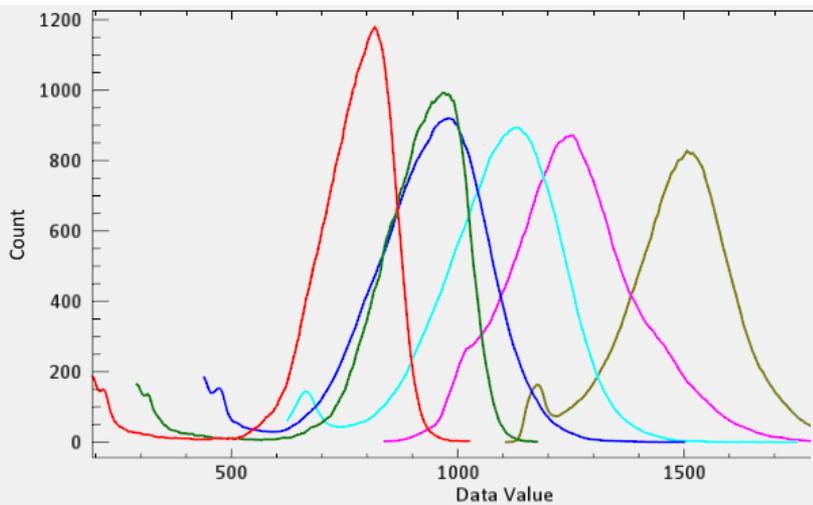
ral i



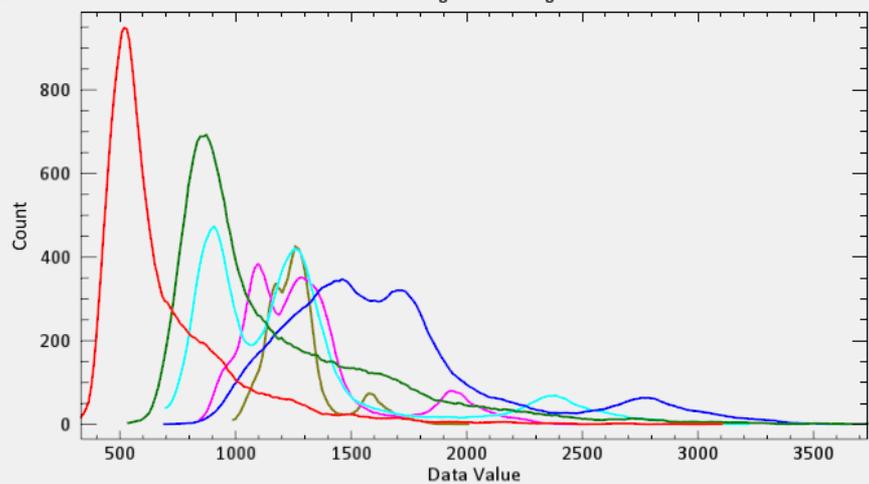
Ciências  
ULisboa

# Maximum Likelihood Classification





x: Data Value y: Data Value



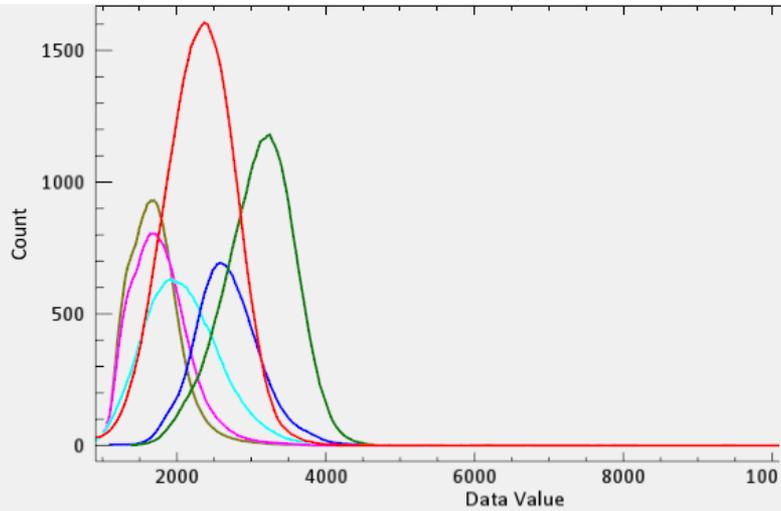
x: Data Value y: Data Value

| Water (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    |

Water

| 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    |

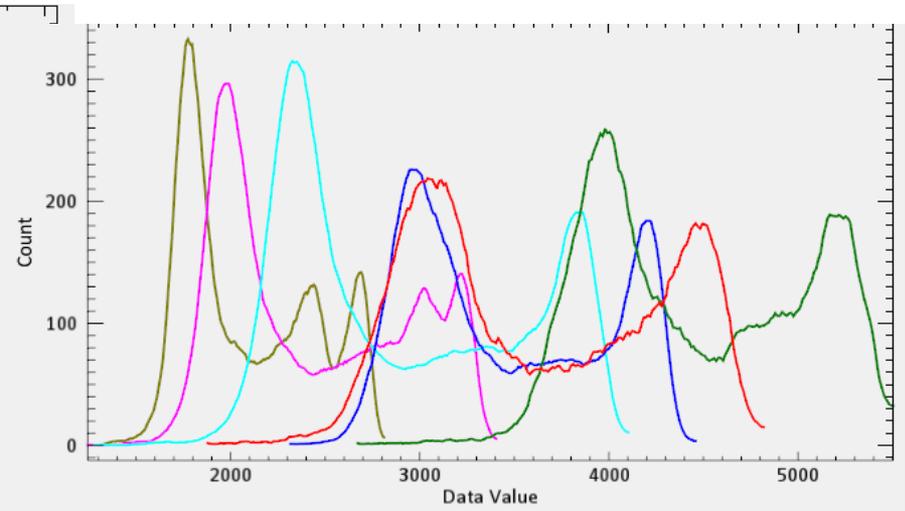
Intertidal



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)



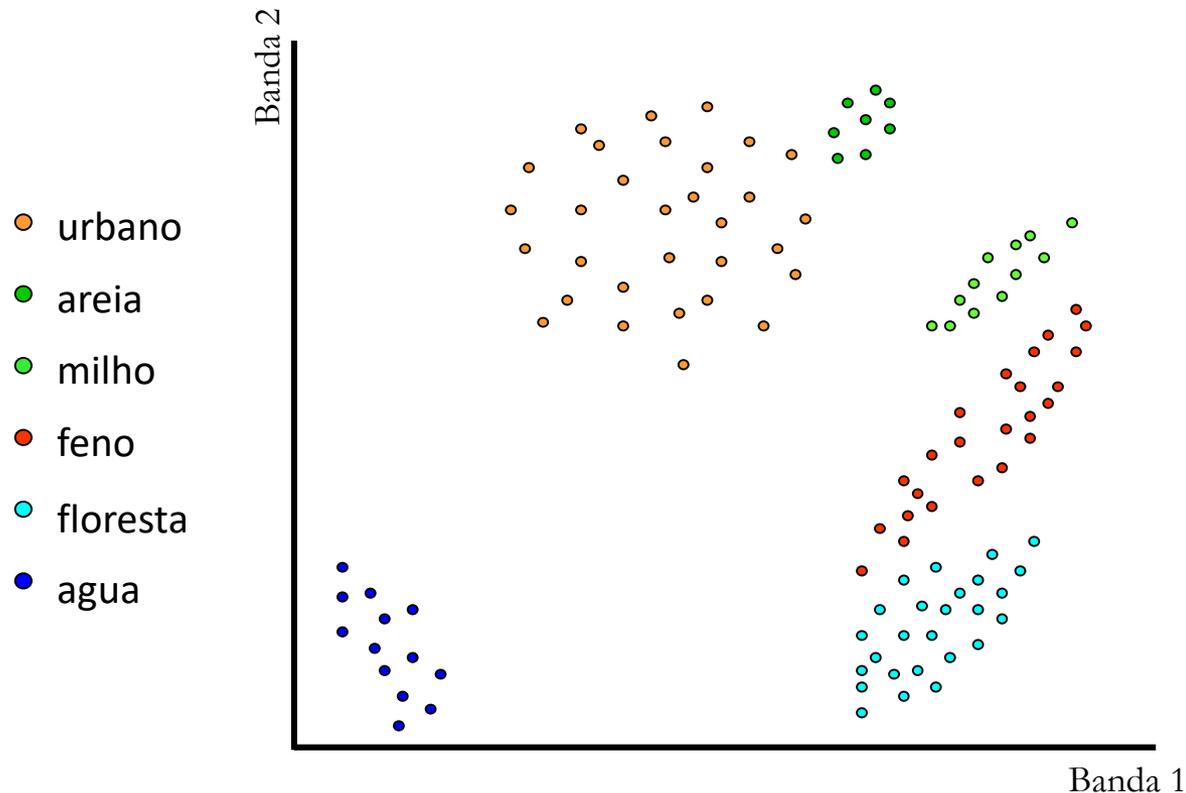
# Maximum Likelihood Classification



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

# 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.

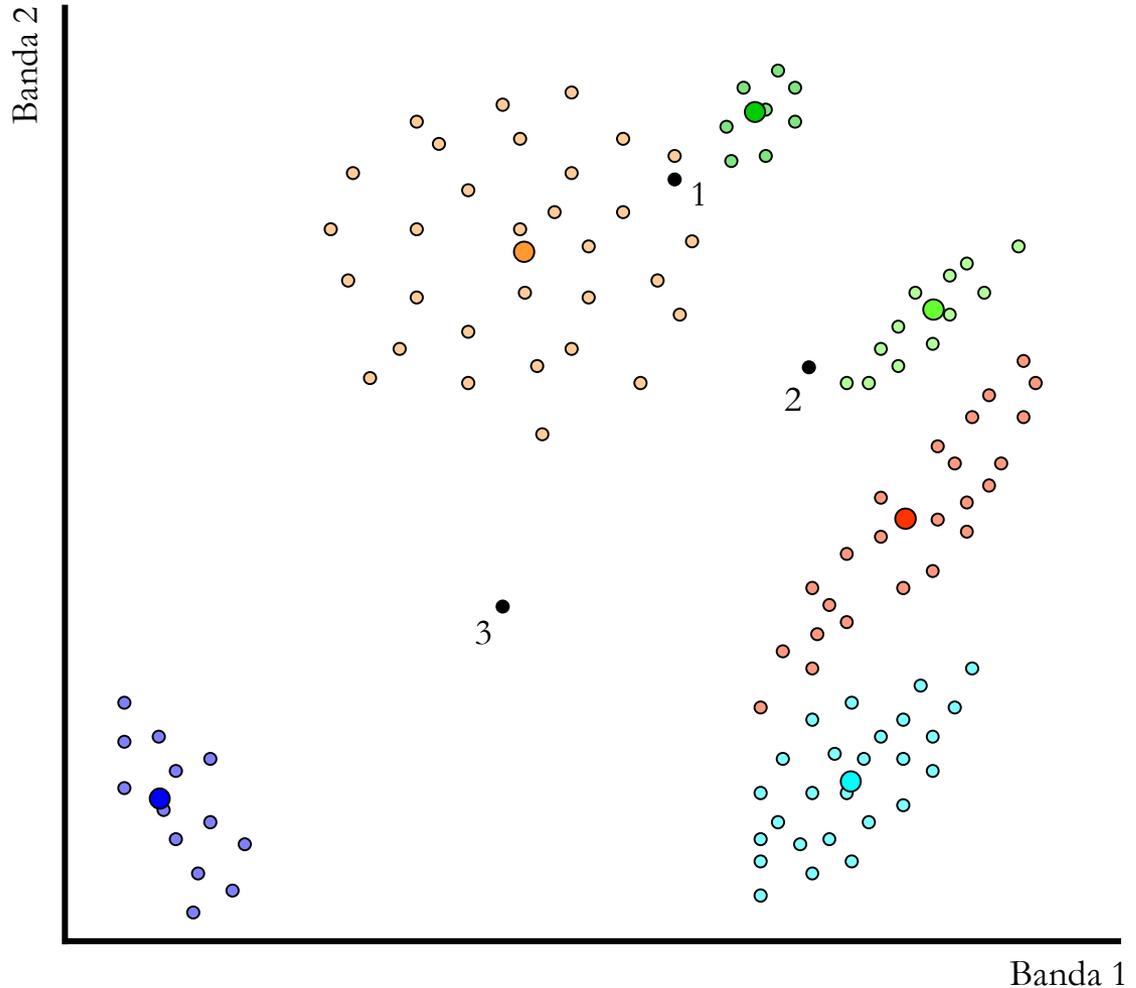


# Exemplo

Pretendem-se classificar os pontos 1,2,3

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

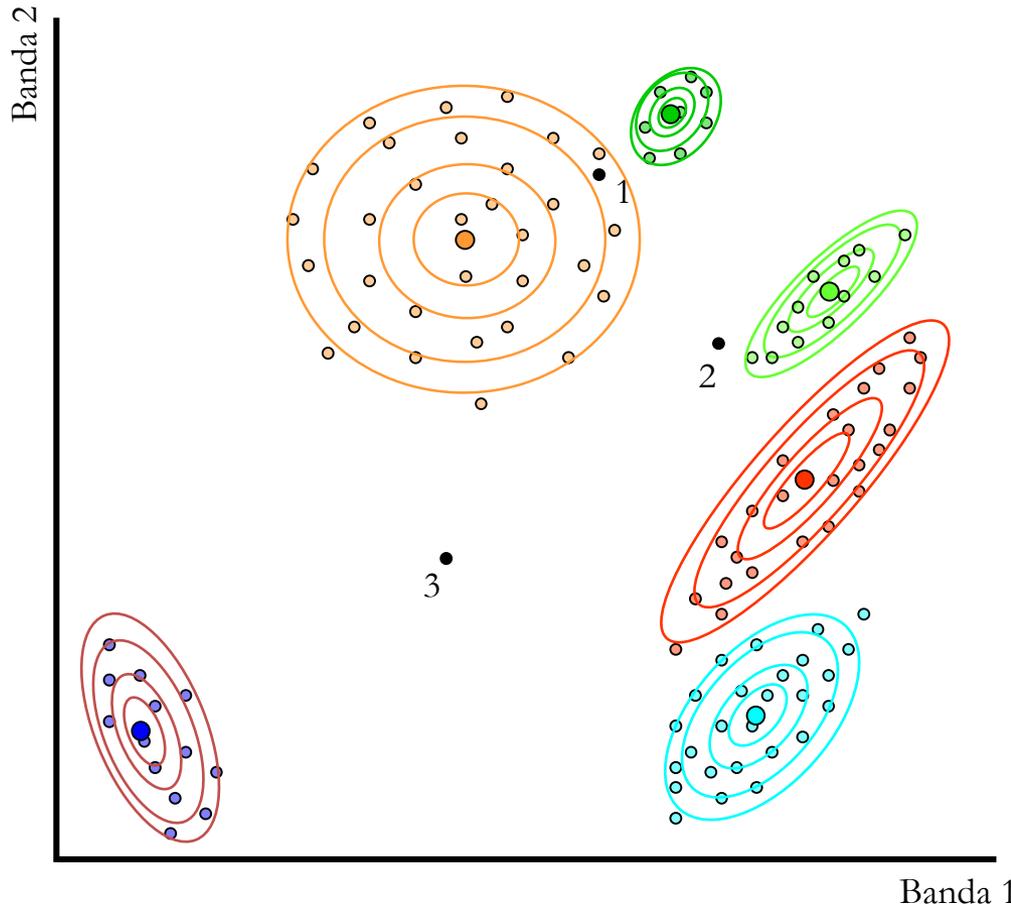
São representados os valores médios de cada classe (círculos maiores).





# Maximum Likelihood

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

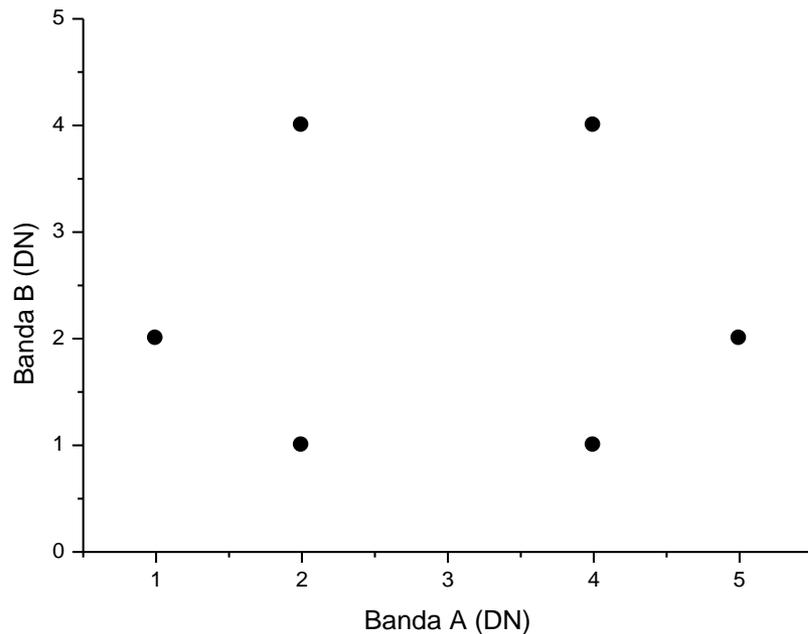


**Classificação**  
1: urbano  
2: não classificado  
3: não classificado

# Exemplo

Determine o vetor da média, a função covariância e correlação

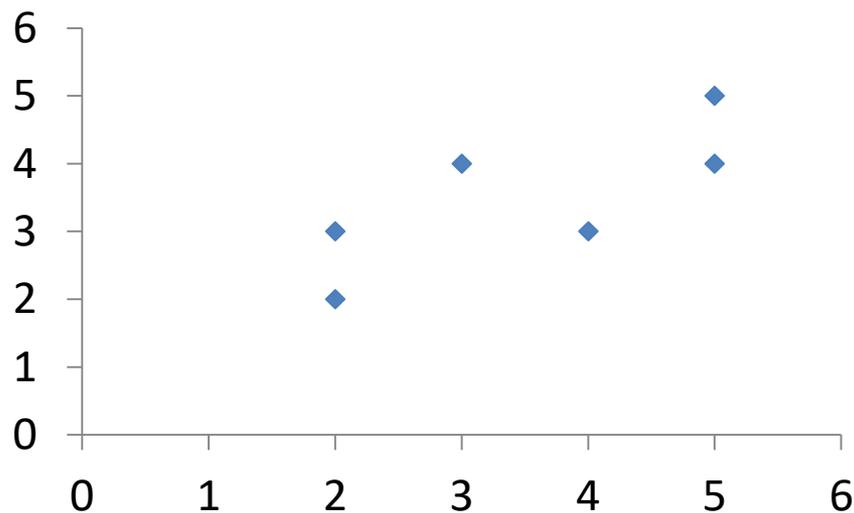
Conjunto de pixels de uma classe



| Banda A | Banda B |
|---------|---------|
| 1       | 2       |
| 2       | 1       |
| 4       | 1       |
| 5       | 2       |
| 4       | 4       |
| 2       | 4       |

# Exemplo

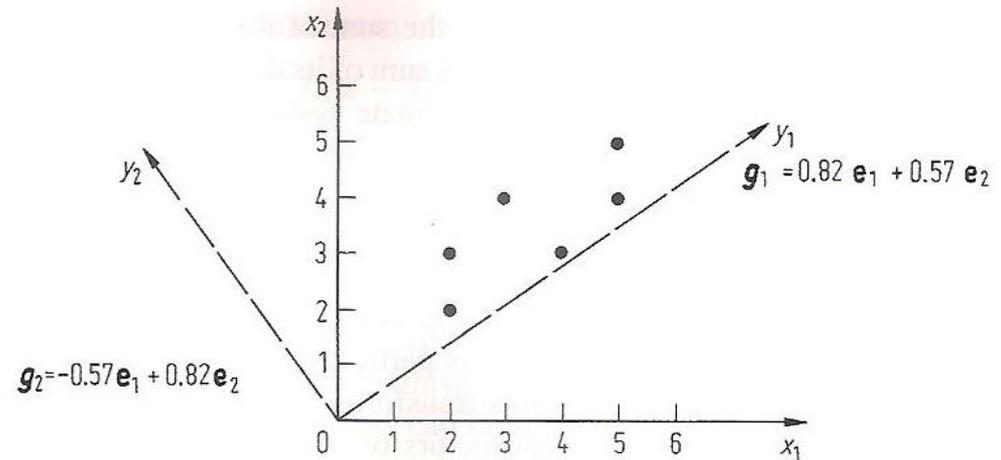
Determine o vetor da média, a função covariância e correlação



| Banda A | Banda B |
|---------|---------|
| 2       | 2       |
| 2       | 3       |
| 4       | 3       |
| 3       | 4       |
| 5       | 4       |
| 5       | 5       |

# Principal Component Analysis

Principal components transformation to ask whether there is a new co-ordinate system in the multispectral vector space in which the data can be represented without correlation



Such that the covariance matrix  
In the new co-ordinate system  
is diagonal

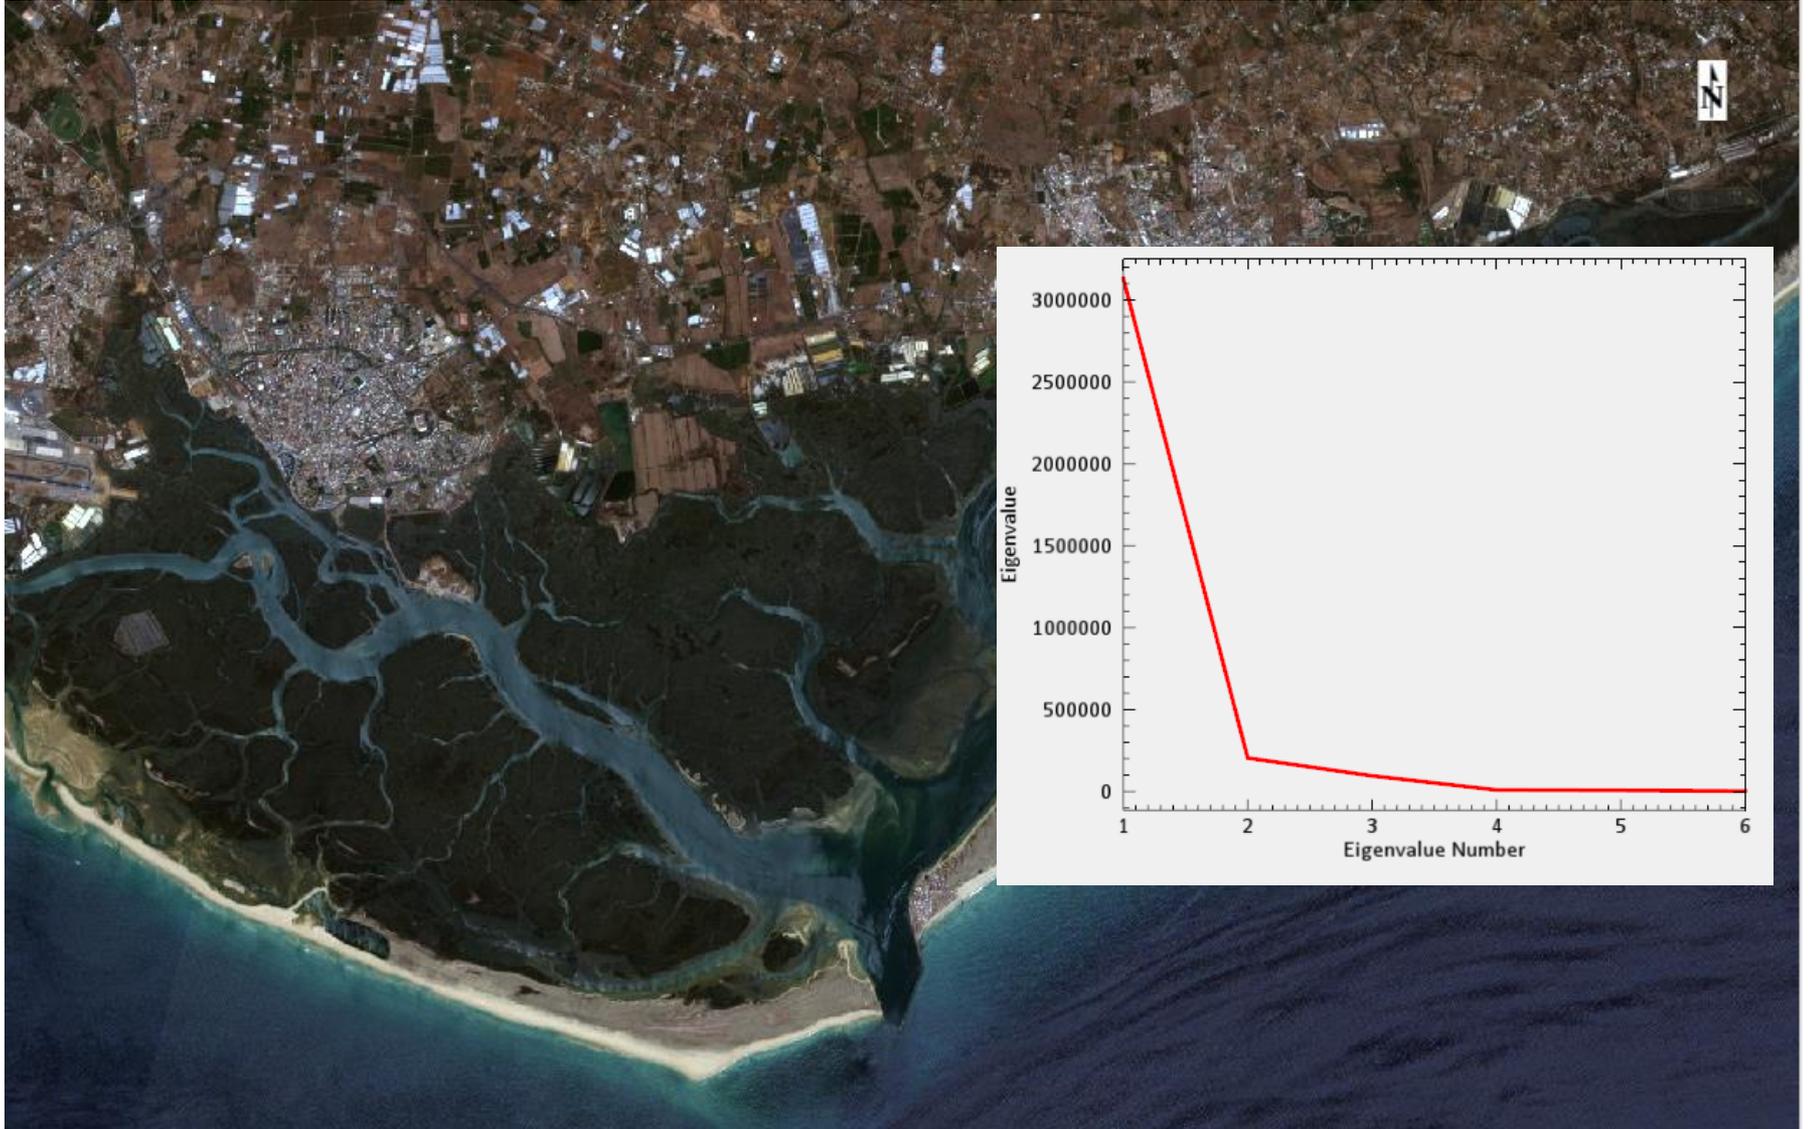
The first component has the  
highest variance

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



Ciências  
ULisboa

# Principal Component Analysis



| Covariance  | Band 1    | Band 2     | Band 3     | Band 4    | Band 5    | Band 6   |
|-------------|-----------|------------|------------|-----------|-----------|----------|
| Band 1      | 645691.44 | 930803.34  | 693518.09  | 367901.03 | 189958.23 | 68789.16 |
| Band 2      | 930803.34 | 1400221.81 | 1077793.04 | 507496.42 | 247773.77 | 65426.15 |
| Band 3      | 693518.09 | 1077793.04 | 951322.85  | 388313.17 | 198829.56 | 44198.87 |
| Band 4      | 367901.03 | 507496.42  | 388313.17  | 276040.37 | 166294.51 | 87132.20 |
| Band 5      | 189958.23 | 247773.77  | 198829.56  | 166294.51 | 118690.59 | 72128.56 |
| Band 6      | 68789.16  | 65426.15   | 44198.87   | 87132.20  | 72128.56  | 58909.17 |
|             |           |            |            |           |           |          |
| Correlation | Band 1    | Band 2     | Band 3     | Band 4    | Band 5    | Band 6   |
| Band 1      | 1.00      | 0.98       | 0.88       | 0.87      | 0.69      | 0.35     |
| Band 2      | 0.98      | 1.00       | 0.93       | 0.82      | 0.61      | 0.23     |
| Band 3      | 0.88      | 0.93       | 1.00       | 0.76      | 0.59      | 0.19     |
| Band 4      | 0.87      | 0.82       | 0.76       | 1.00      | 0.92      | 0.68     |
| Band 5      | 0.69      | 0.61       | 0.59       | 0.92      | 1.00      | 0.86     |
| Band 6      | 0.35      | 0.23       | 0.19       | 0.68      | 0.86      | 1.00     |

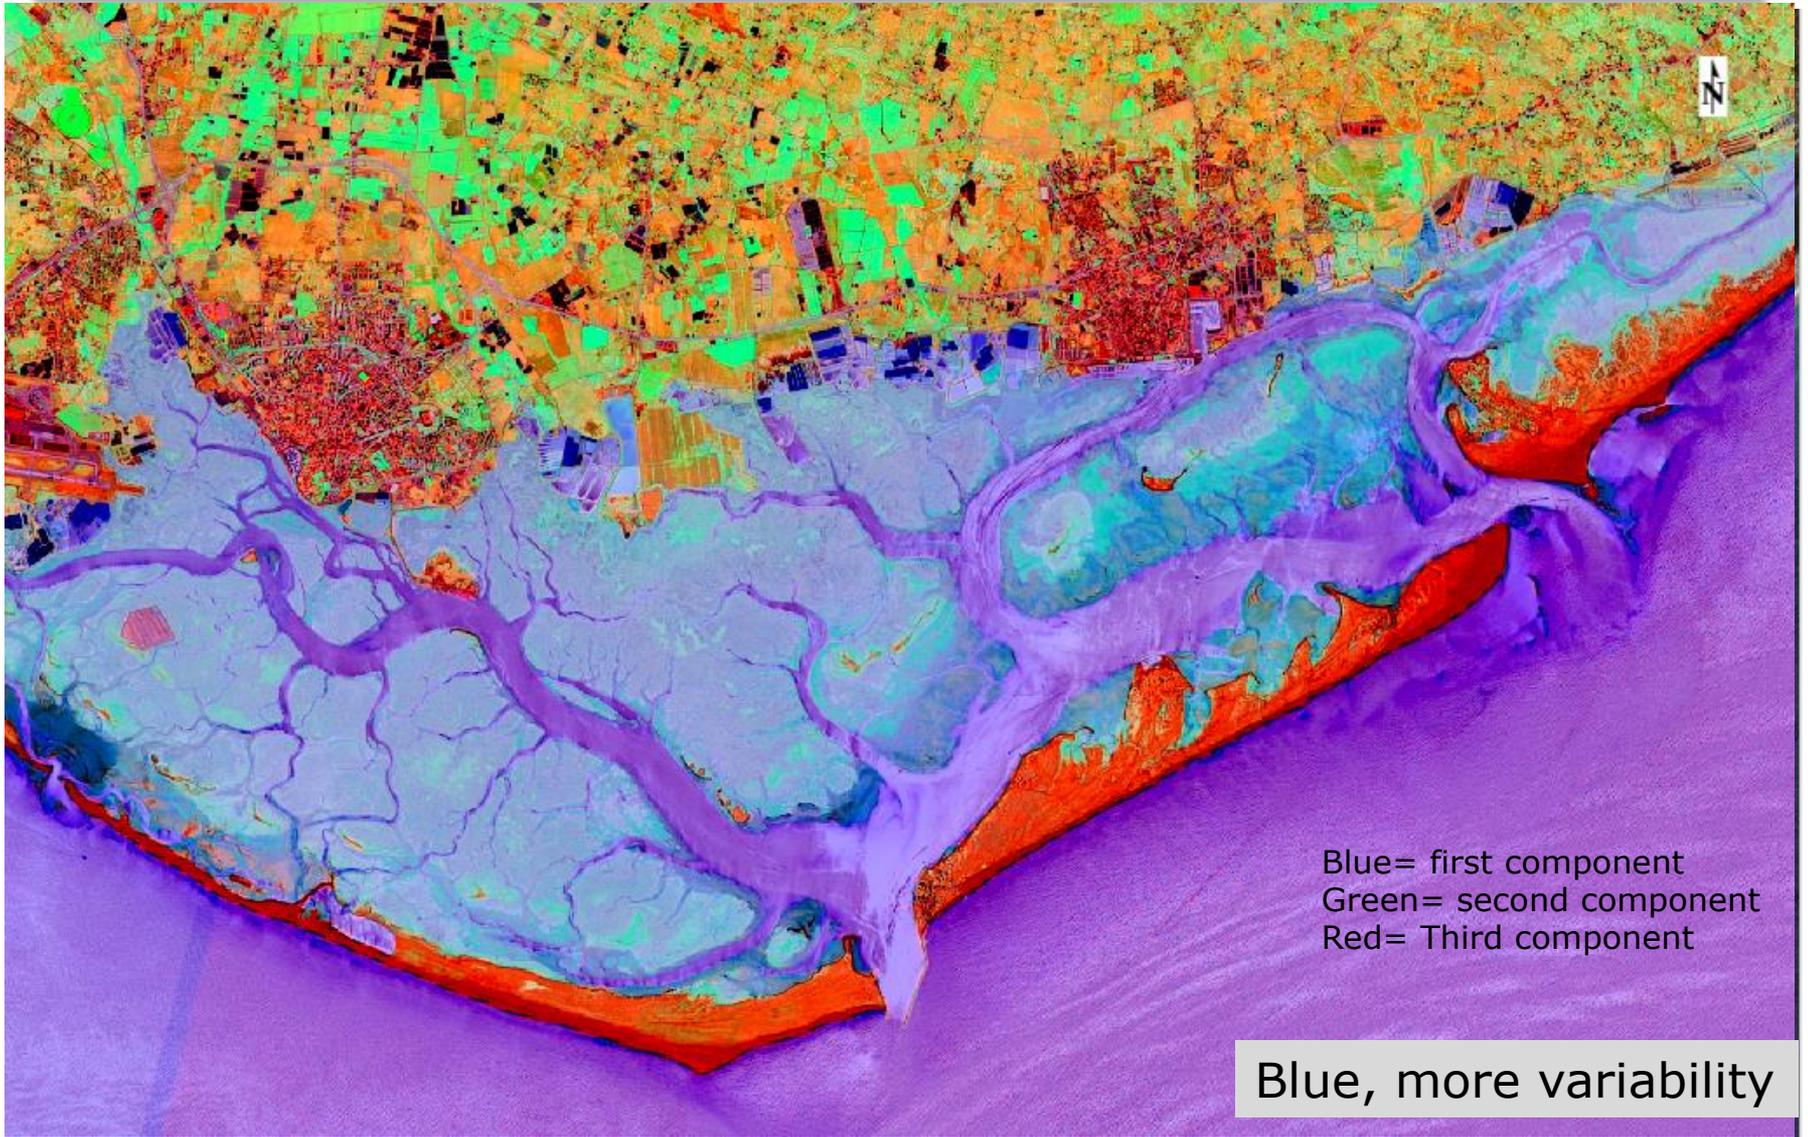
## PCA image

| Covariance  | Band 1     | Band 2    | Band 3   | Band 4  | Band 5  | Band 6  |
|-------------|------------|-----------|----------|---------|---------|---------|
| Band 1      | 3131671.66 | -0.00     | -0.00    | -0.00   | 0.00    | -0.00   |
| Band 2      | -0.00      | 204630.61 | -0.00    | 0.00    | 0.00    | 0.00    |
| Band 3      | -0.00      | -0.00     | 95688.10 | 0.00    | -0.00   | 0.00    |
| Band 4      | -0.00      | 0.00      | 0.00     | 9428.17 | -0.00   | -0.00   |
| Band 5      | 0.00       | 0.00      | -0.00    | -0.00   | 6729.97 | -0.00   |
| Band 6      | -0.00      | 0.00      | 0.00     | -0.00   | -0.00   | 2727.73 |
|             |            |           |          |         |         |         |
| Correlation | Band 1     | Band 2    | Band 3   | Band 4  | Band 5  | Band 6  |
| Band 1      | 1.00       | -0.00     | -0.00    | -0.00   | 0.00    | -0.00   |
| Band 2      | -0.00      | 1.00      | -0.00    | 0.00    | 0.00    | 0.00    |
| Band 3      | -0.00      | -0.00     | 1.00     | 0.00    | -0.00   | 0.00    |
| Band 4      | -0.00      | 0.00      | 0.00     | 1.00    | -0.00   | -0.00   |
| Band 5      | 0.00       | 0.00      | -0.00    | -0.00   | 1.00    | -0.00   |
| Band 6      | -0.00      | 0.00      | 0.00     | -0.00   | -0.00   | 1.00    |



Ciências  
ULisboa

# Principal Component Analysis



# 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:

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

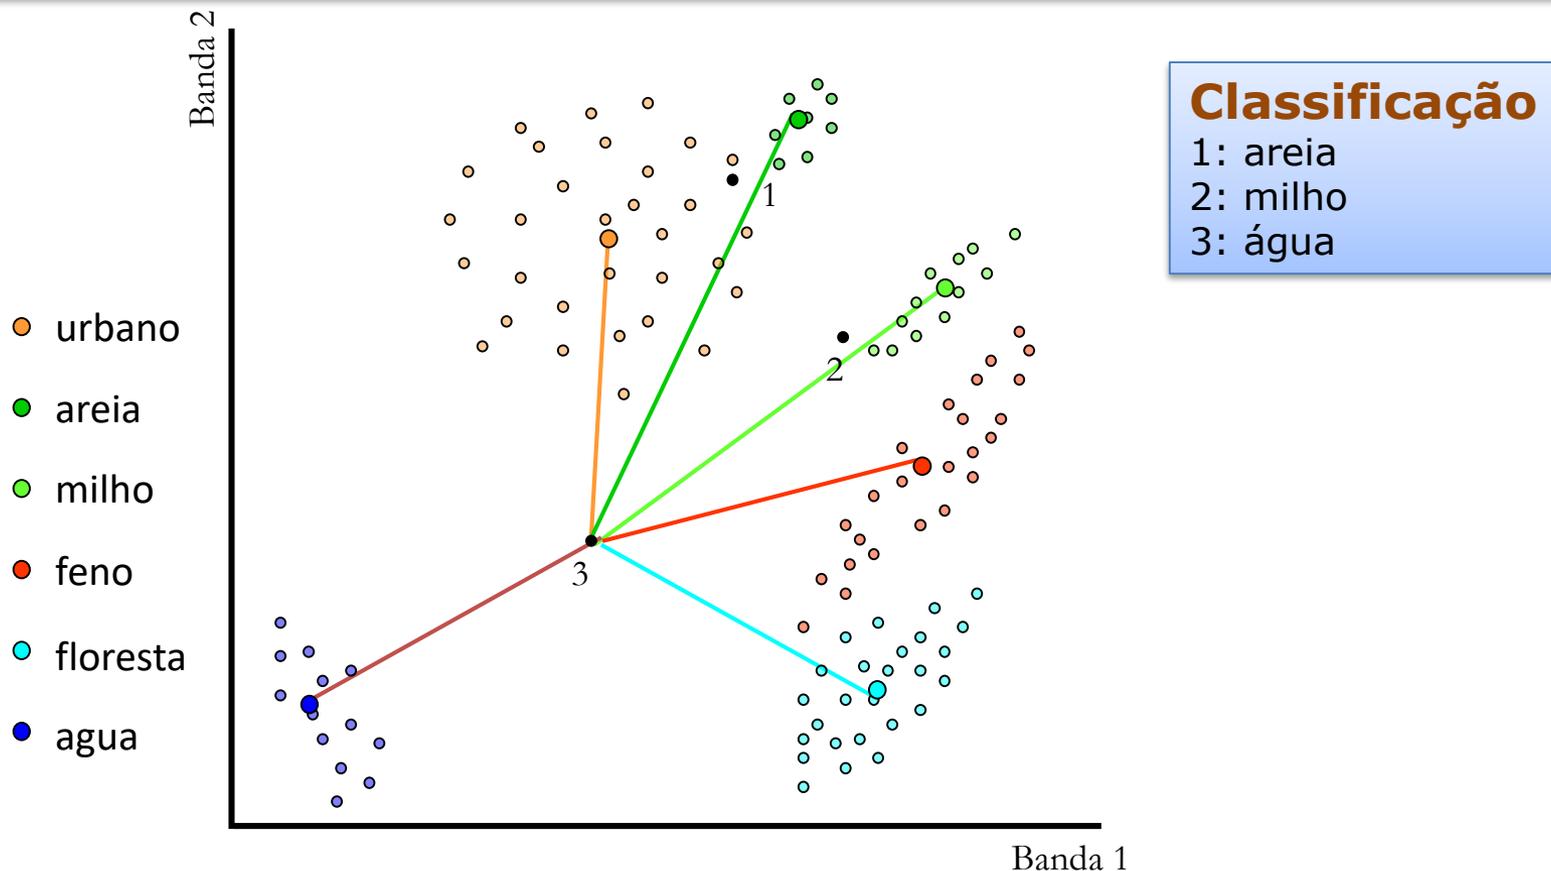
Expandindo o produto dá:

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

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

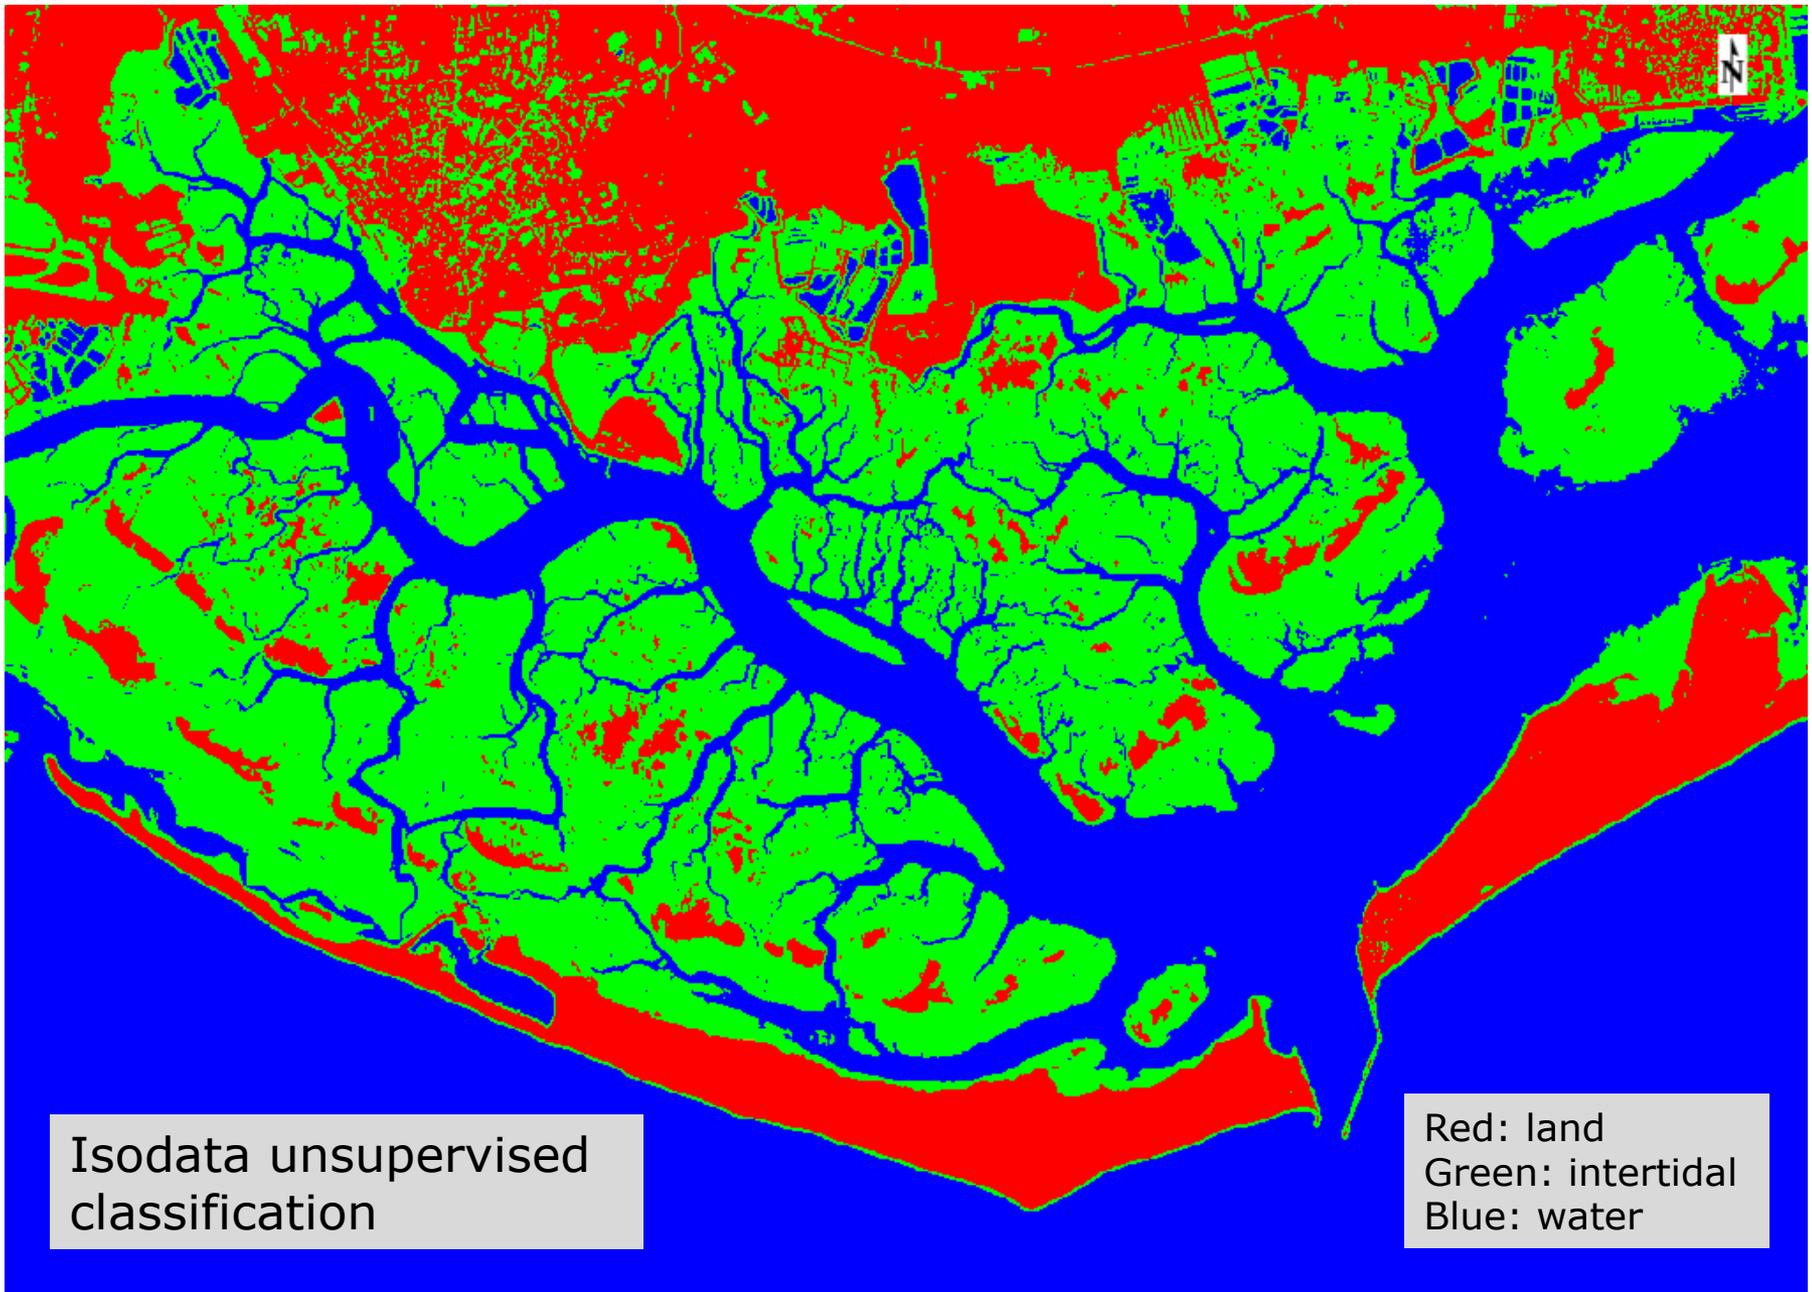




# Maximum Likelihood Classification

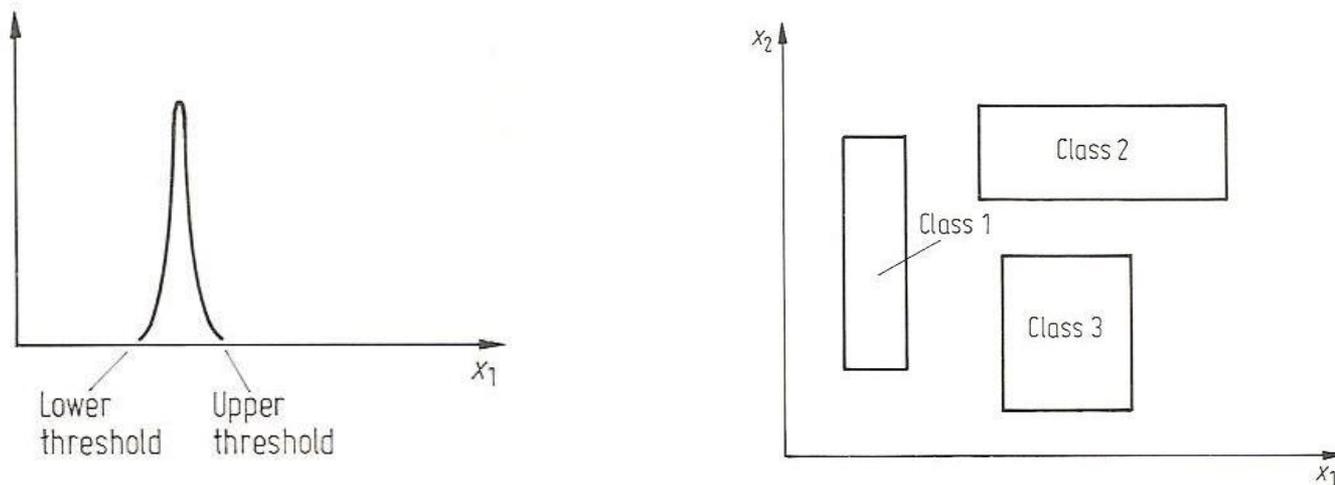


$$g_i(x) = -\ln \left| \sum_i \right| - (x - m_i)^t \Sigma_i^{-1} (x - m_i)$$



# Classificador Paralelepípedo

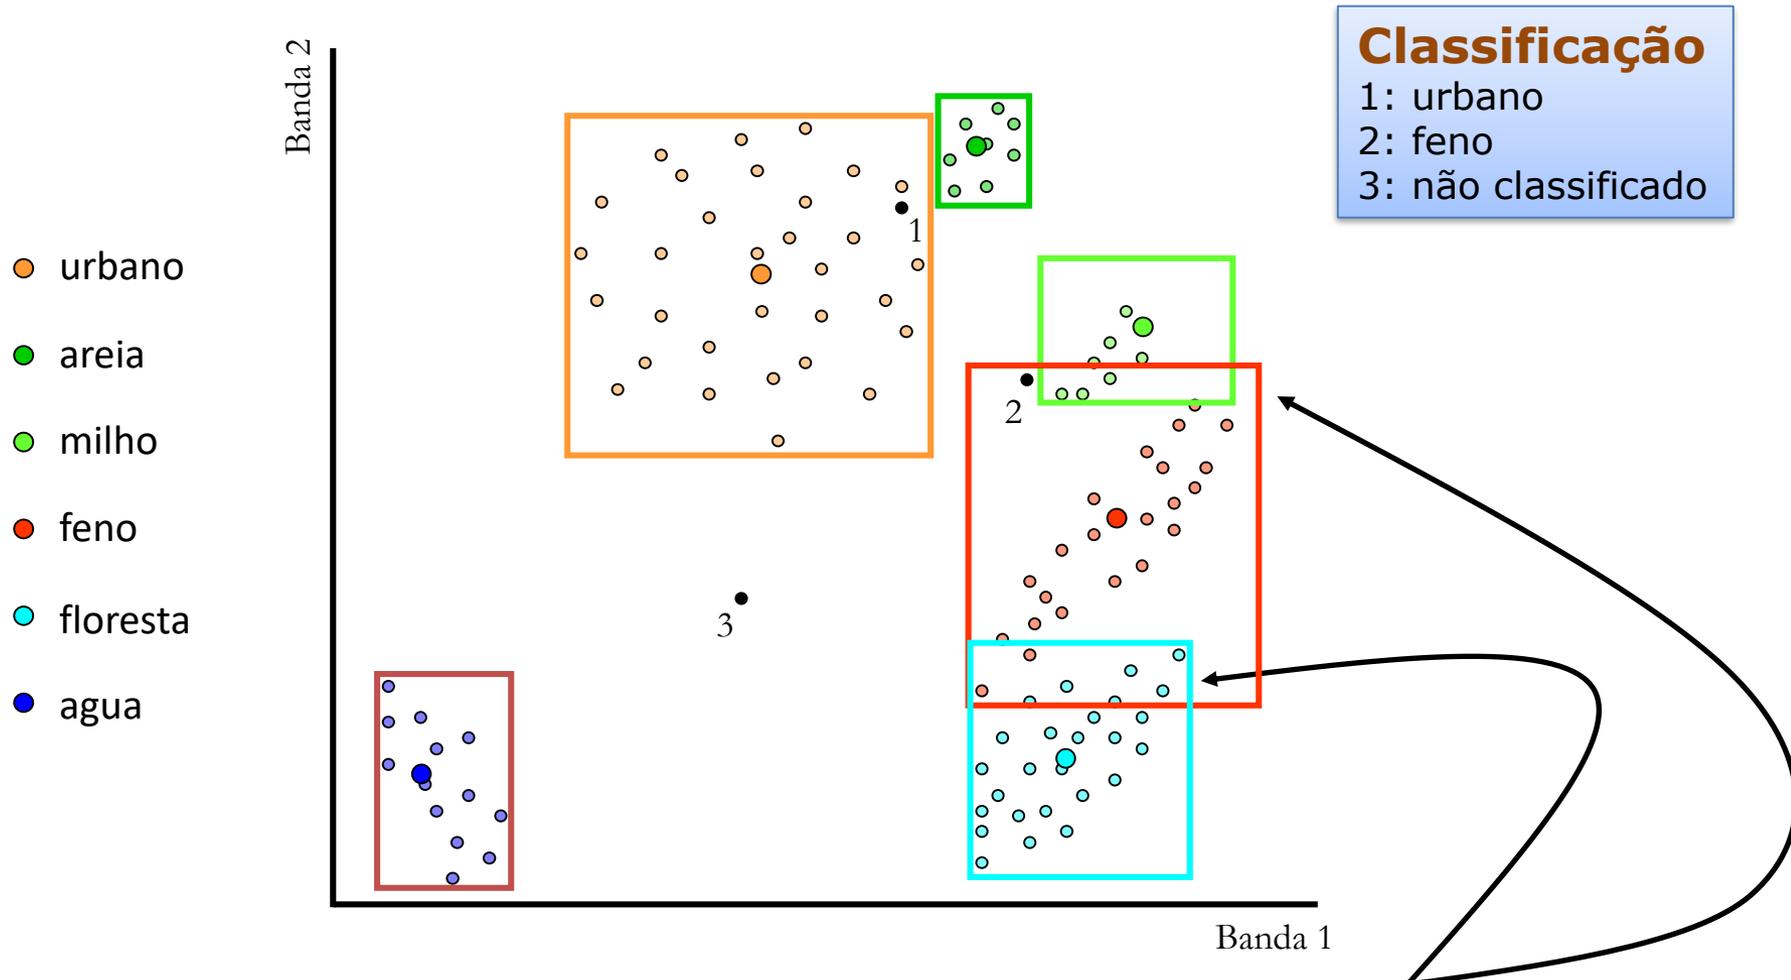
O classificador do paralelepípedo é treinado por análise dos histogramas de componentes espectrais com base nos dados treino



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  $\Sigma$  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)

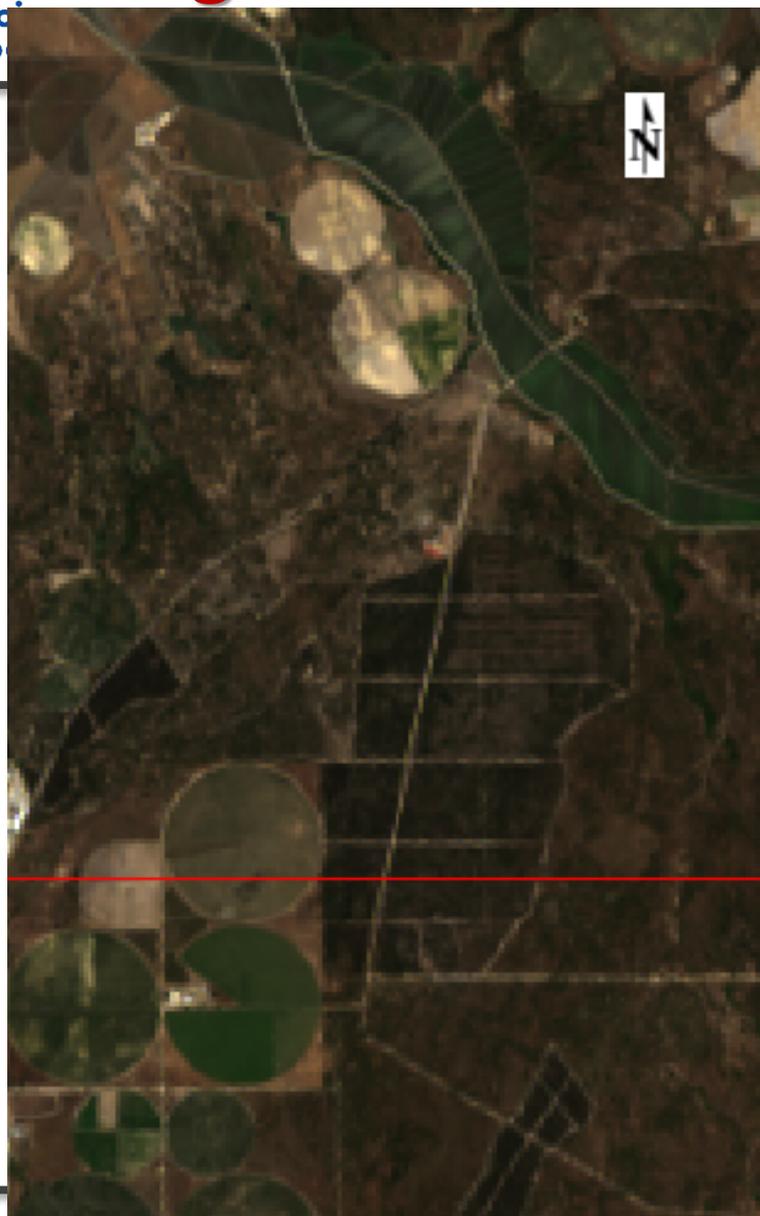
P2 (9,8)

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 → i

Classificação ↑ j

|                | 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 i-ésima mas que foram classificados pelo classificador como pertencentes à classe j-ésima.

(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 → i

|                      |                |         |                |          |    |
|----------------------|----------------|---------|----------------|----------|----|
|                      | Água           | Solo nu | Solo cultivado | Floresta |    |
| ↑<br>Classificação j | Água           | 187     | 40             | 7        | 0  |
|                      | Solo nu        | 11      | 246            | 12       | 9  |
|                      | Solo cultivado | 0       | 21             | 239      | 39 |
|                      | Floresta       | 0       | 0              | 140      | 49 |

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

A coluna  $i$ -ésima fornece o número de todos os pixéis que no mapa de referência são associados à classe  $i$ -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 → i

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

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

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

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

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

|                   |                | Classes conhecidas → i |         |                |          |      |
|-------------------|----------------|------------------------|---------|----------------|----------|------|
|                   |                | Água                   | Solo nu | Solo cultivado | Floresta |      |
| Classificação ↑ j | Água           | 187                    | 40      | 7              | 0        | 79.9 |
|                   | Solo nu        | 11                     | 246     | 12             | 9        | 88.5 |
|                   | Solo cultivado | 0                      | 21      | 239            | 39       | 79.9 |
|                   | Floresta       | 0                      | 0       | 140            | 49       | 25.9 |

Comissão

A precisão 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

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

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

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

Classificação ↑ j

Classes conhecidas → 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       |

|      |      |      |      |
|------|------|------|------|
| 94.4 | 80.1 | 60.1 | 50.5 |
|------|------|------|------|

Omissão

A precisão 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!



**Ciências**  
ULisboa

---

---