



Φsat-2, ESA's groundbreaking cubesat scheduled for launch in June, will now include two new AI-driven apps destined to demonstrate a crucial role in future environmental monitoring from space. The apps, which focus on marine pollution and wildfires, were the winning entries in ESA's OrbitalAI Challenge.



— Φsat-2 gets two new AI apps

AI is already established as a vital tool in Earth observation, helping to sift through terabytes of satellite data to provide useful insight for scientists, policy makers and commercial operators.

But while most AI processing of information is carried out on the ground once the data have been downloaded, there are significant advantages to be had from integrating AI capabilities on the satellite.

The tiny Φsat-2 satellite couples a multispectral camera with a powerful AI computer that allows dedicated apps to run onboard. This means that, rather than downlinking all the raw imagery data, only the essential information processed by the app is transmitted back to Earth, giving tangible benefits in data transmission efficiency and rapid decision-making.

Four apps had already been selected for the mission and are being pre-loaded on to the satellite. They carry out tasks such as cloud removal from the camera's imagery, emergency-response street map generation, and detecting and classifying marine vessels.

Capítulo 3 – Classificação de Imagem

- 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



Radiative Transfer Model

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.

Radiative Transfer Model

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:

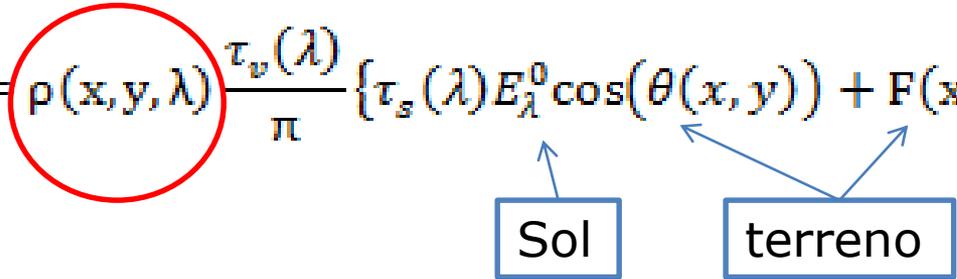
$$\rho_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot d^2}{E_{SUN_{\lambda}} \cos \theta_S}$$

Refletância Topo da atmosfera

Equação simplificada da equação anterior.

Solar radiance at sensor

Como podemos usar a Deteção Remota para reconhecer diferentes ocupações do solo?

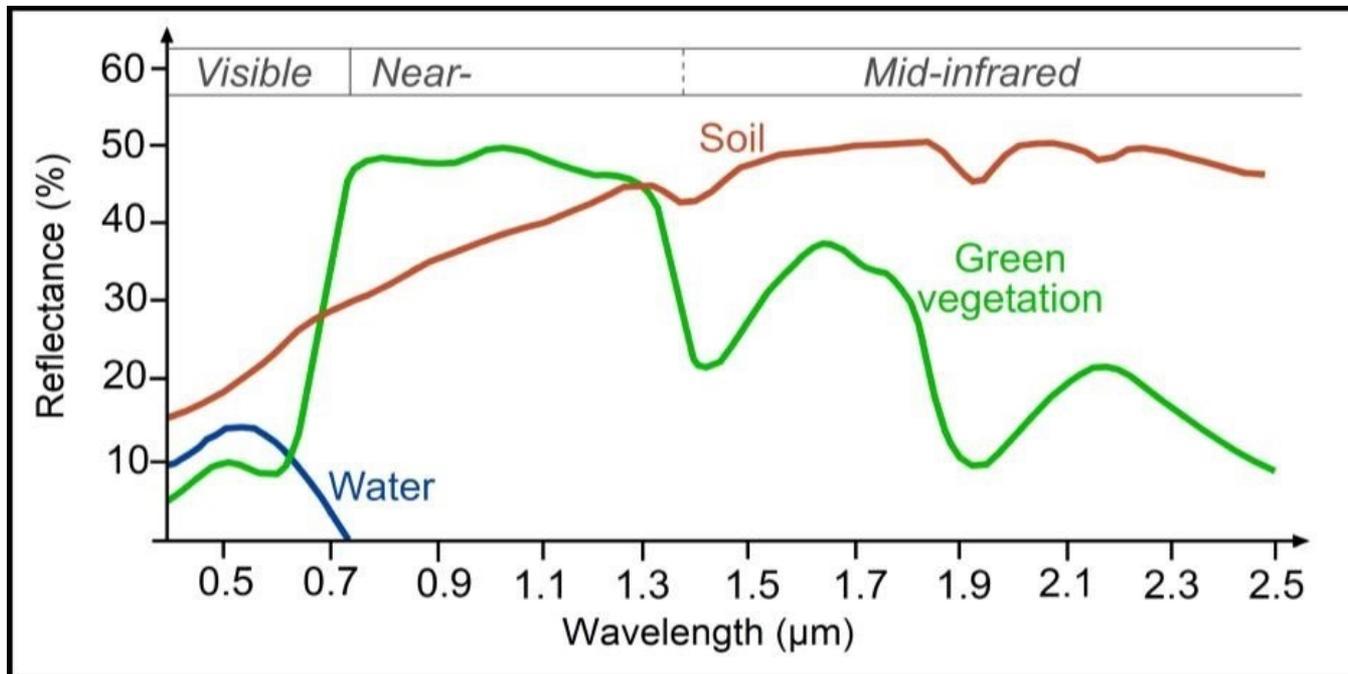
$$L_{\lambda}^s(x, y) = \rho(x, y, \lambda) \frac{\tau_v(\lambda)}{\pi} \left\{ \tau_s(\lambda) E_{\lambda}^0 \cos(\theta(x, y)) + F(x, y) \cdot E_{\lambda}^d \right\} + L_{\lambda}^{sp}(x, y)$$


(Radiative transfer model, RTM)

Esta equação tem solução em ordem à reflectância do píxel (ρ) se cada objecto na superfície tiver uma única assinatura espectral e distinta de todos os outros objectos.

Assinatura Espetral

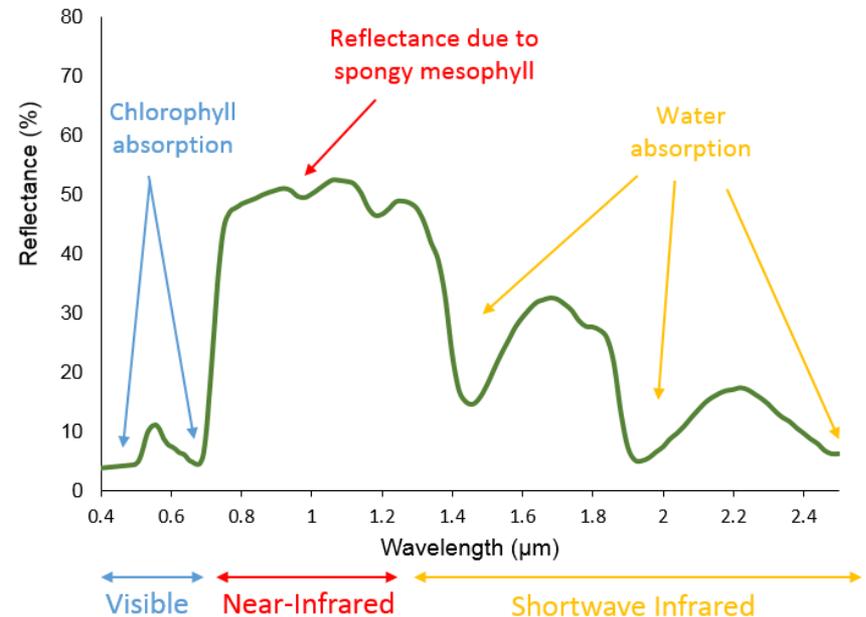
These differences in reflectance make it possible to identify different earth surface features or materials by analysing their spectral reflectance signatures. **Spectral reflectance curves** graph the spectral reflectance of objects as a function of wavelengths.



Assinatura Espetral - Vegetação

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

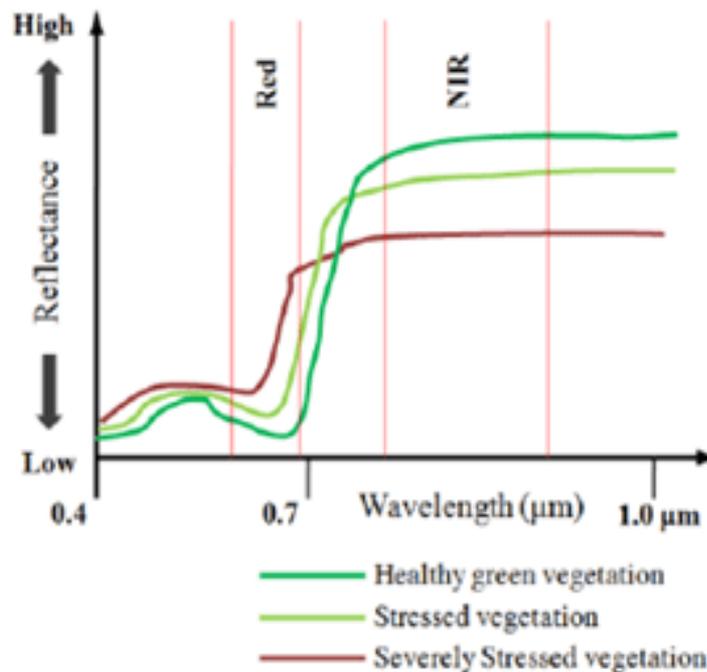
If reflectance is to be measured in both visible and infrared region then the curve will be very high in infrared region compared to visible range in a **healthy vegetation** leaf.



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

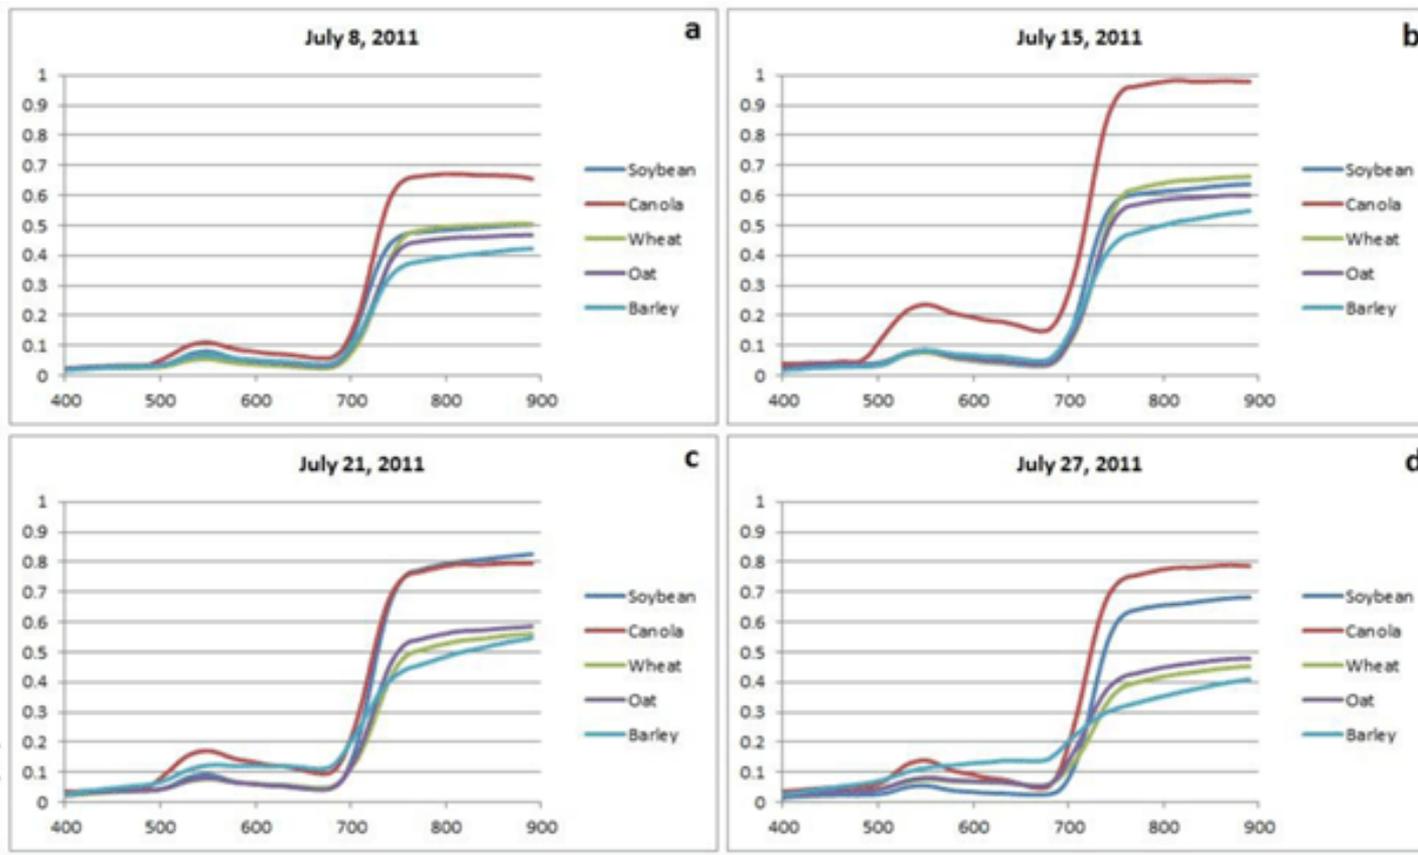
Assinatura Espetral - Vegetação

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.



Assinatura Espetral - Vegetação

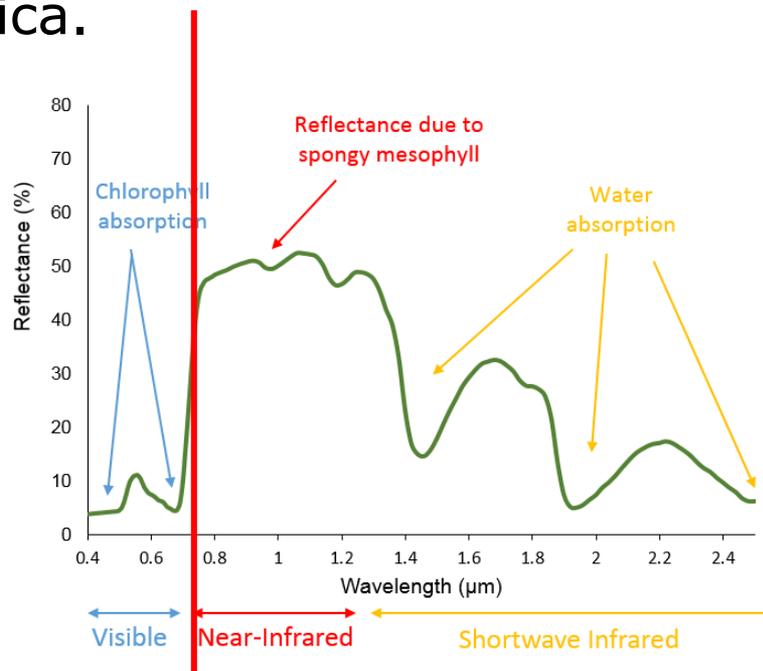
Spectral signatures for **different crops** organized by number of days after planting.



Wheat-trigo
Barley- cevada
Oat= aveia

Vegetation Index

Os índices de vegetação, baseiam-se no facto que a vegetação “verde” interagir de forma característica com a radiação eletromagnética.



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

Índice razão.

$$I_1 = \frac{\text{Red}}{\text{Near Infra Red}}$$

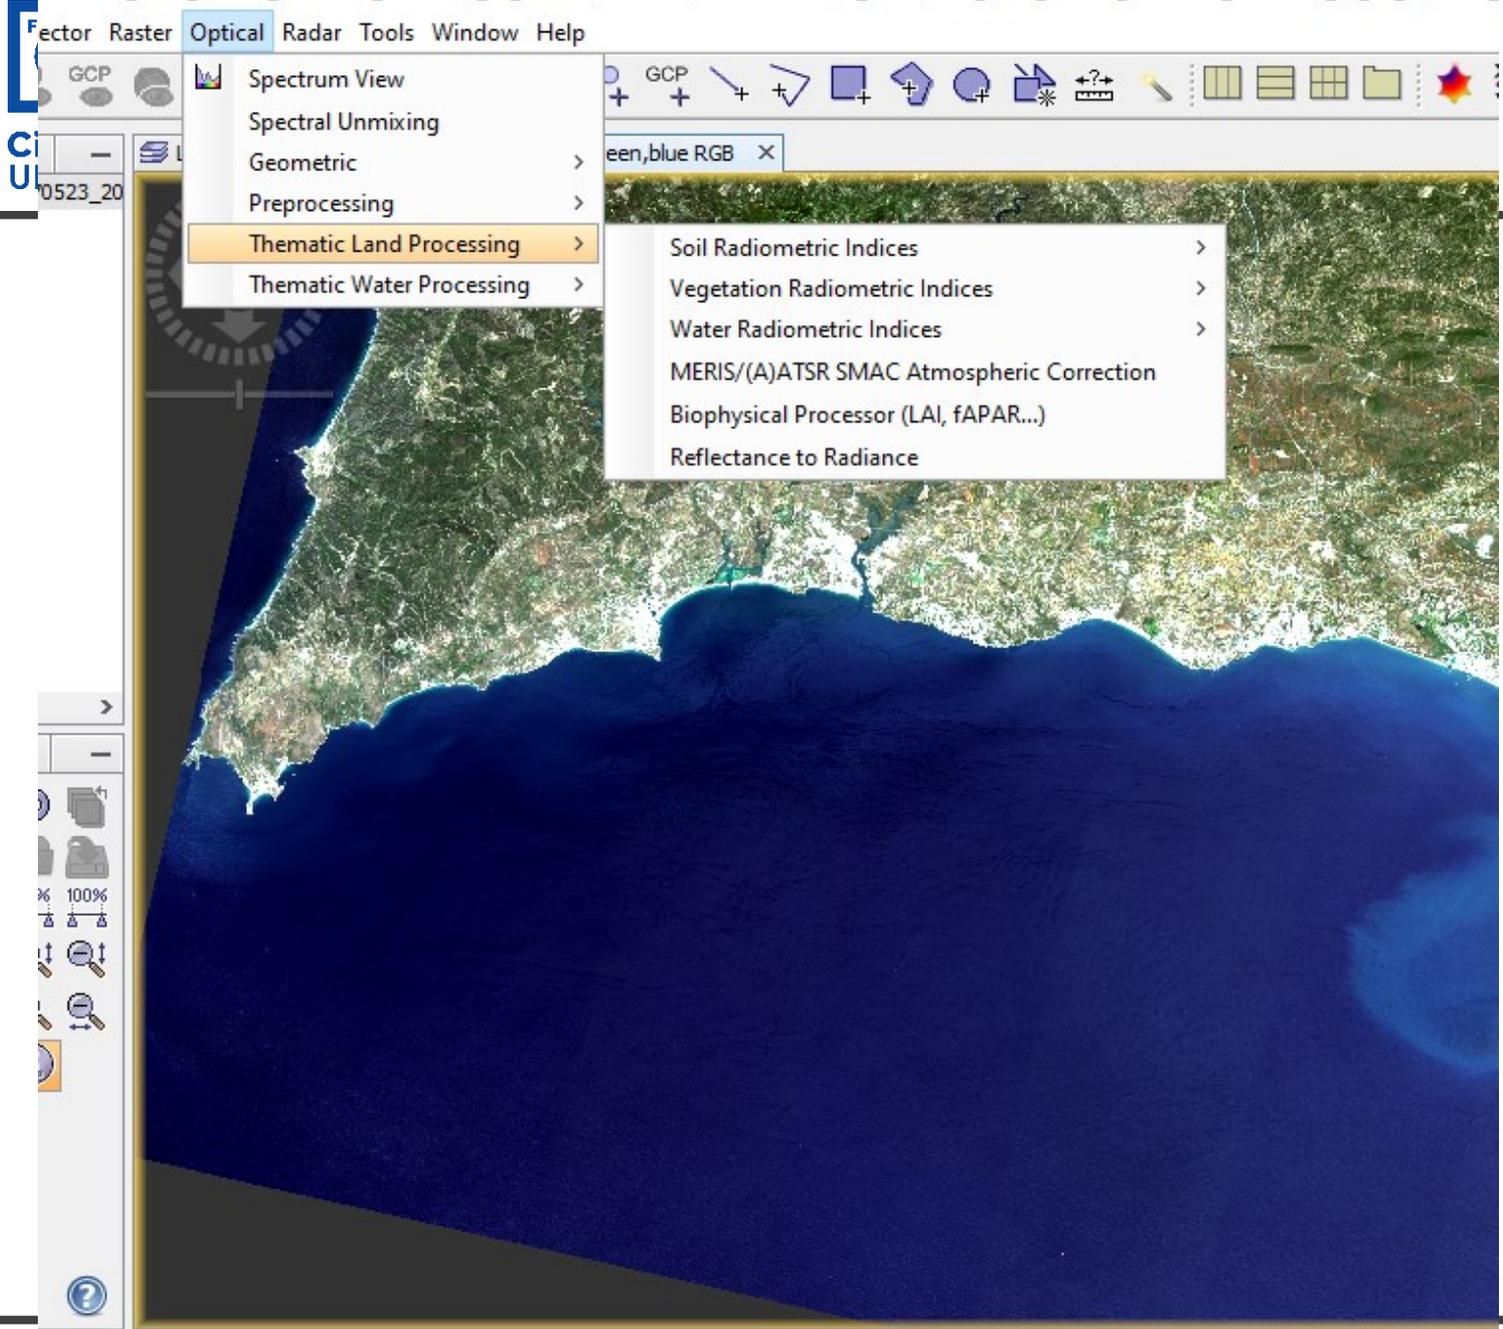
Índice de vegetação normalizado NDVI

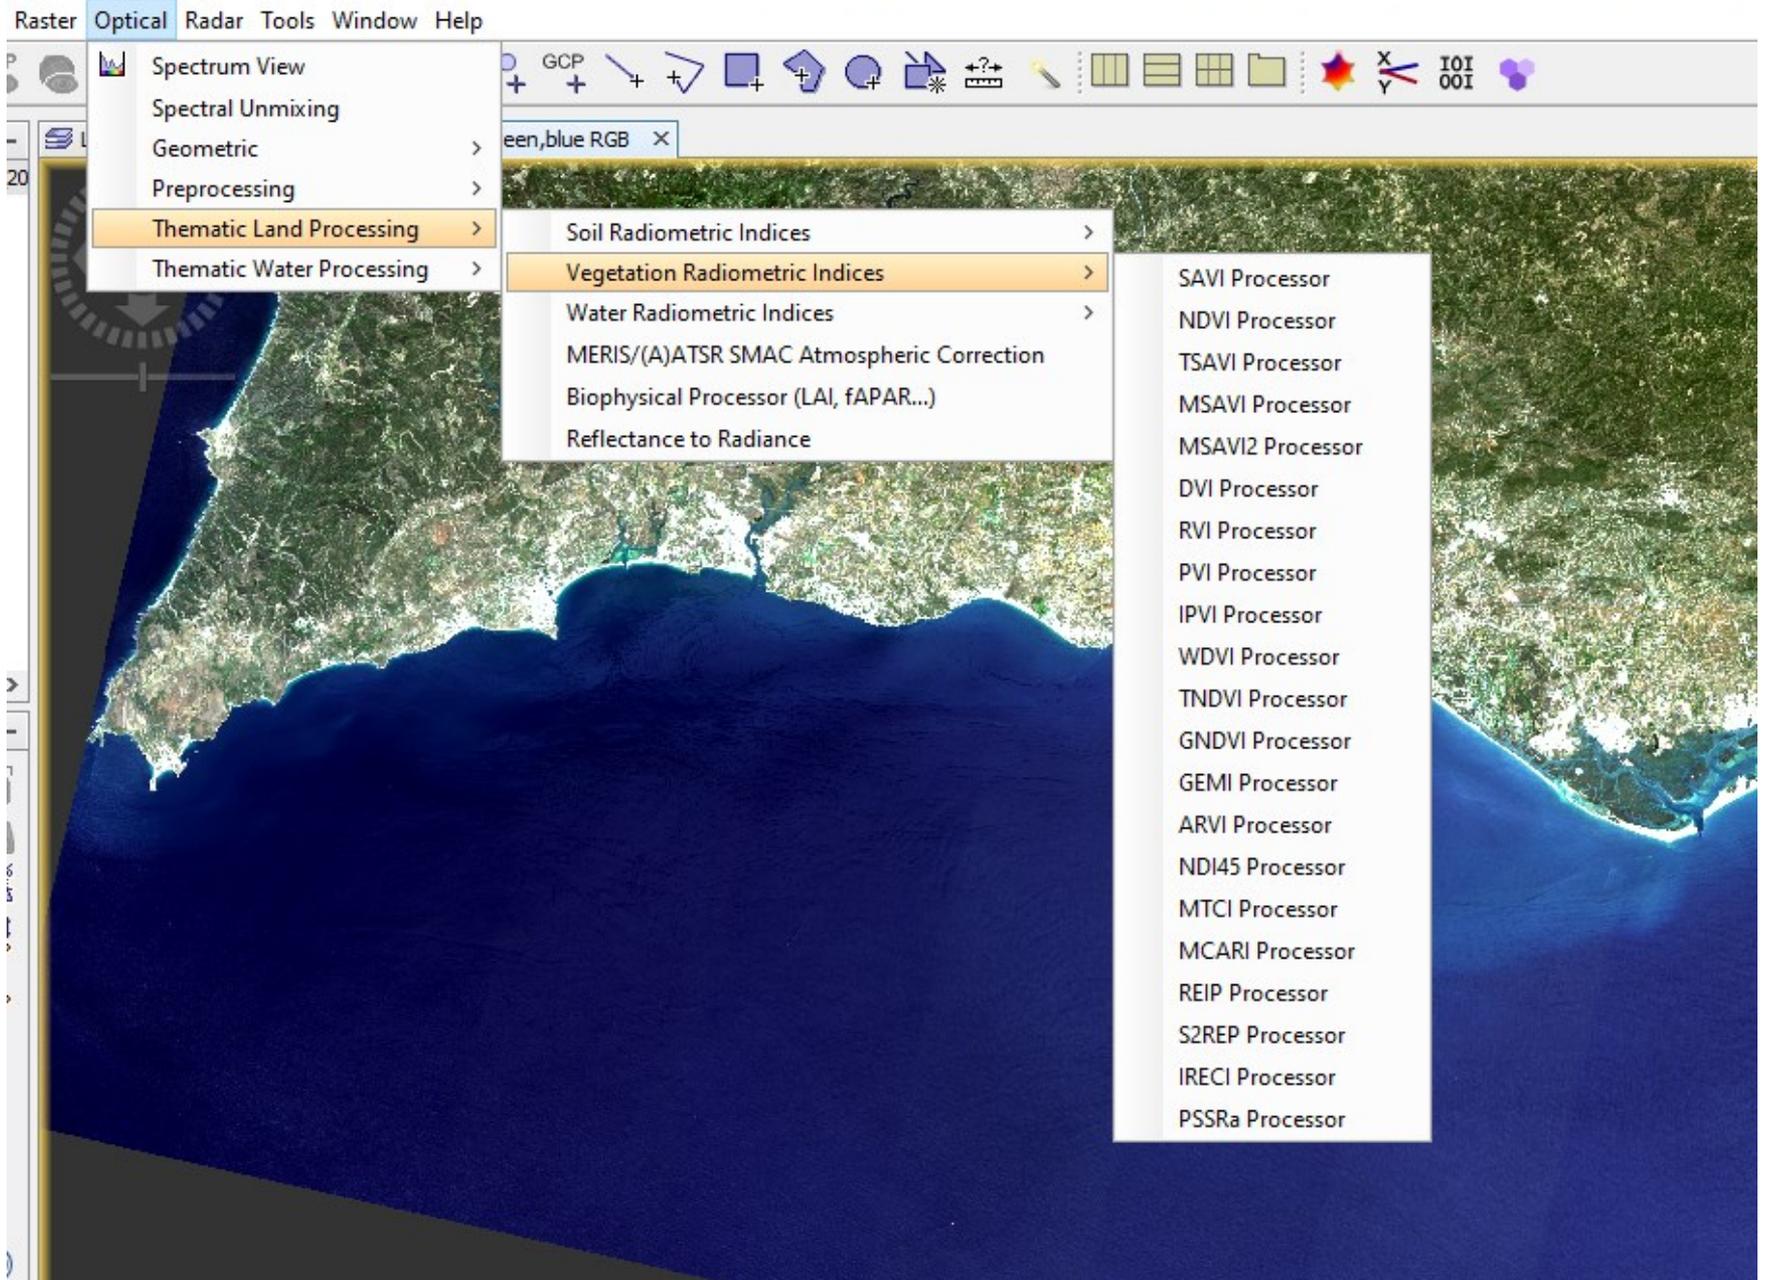
Normalized Difference Vegetation Index

$$\text{NDVI} = \frac{\text{Near Infra Red} - \text{Red}}{\text{Near Infra Red} + \text{Red}}$$

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.







NDVI

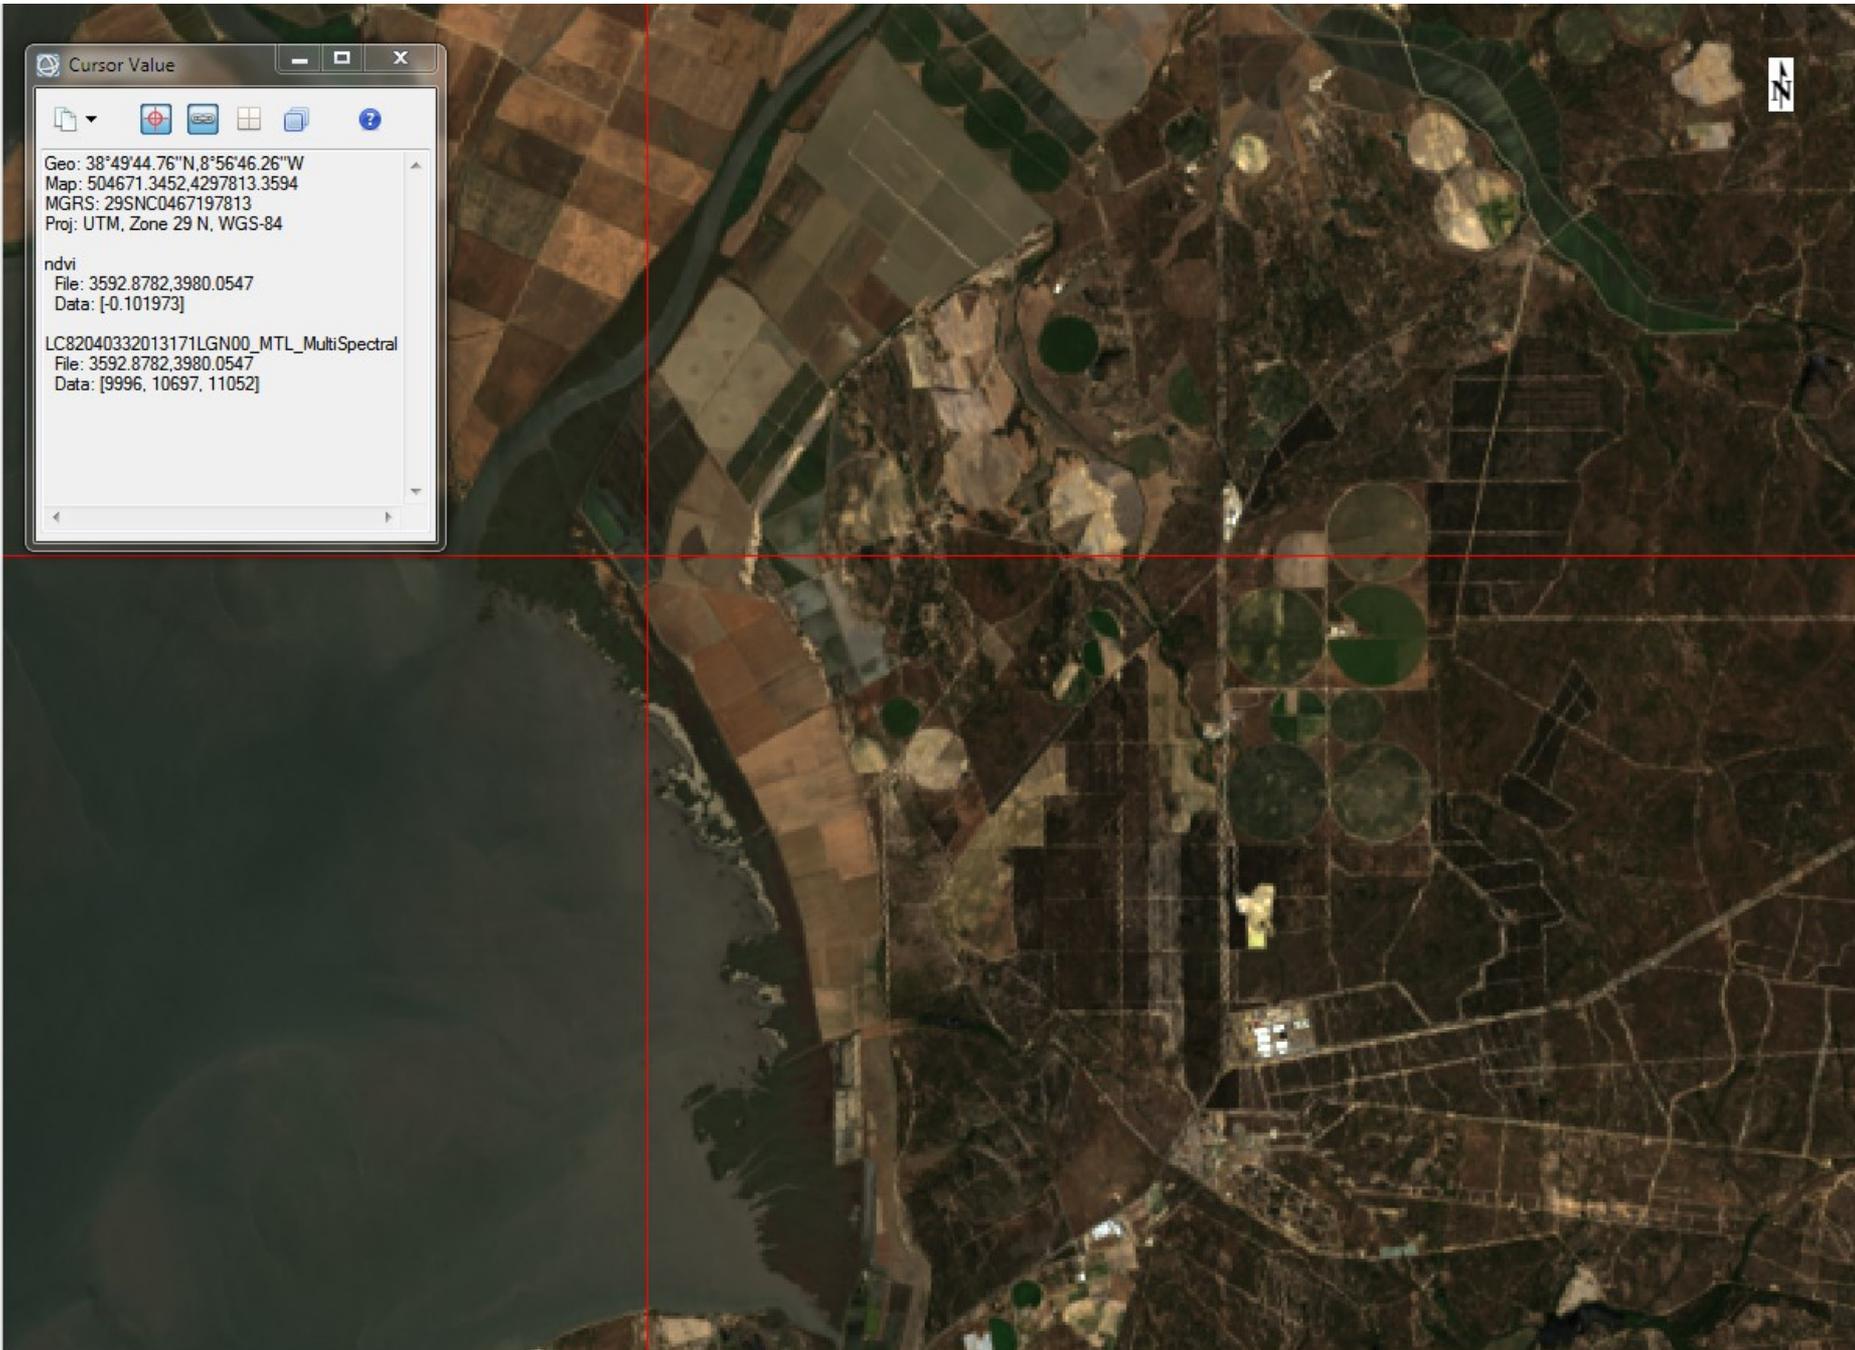
N

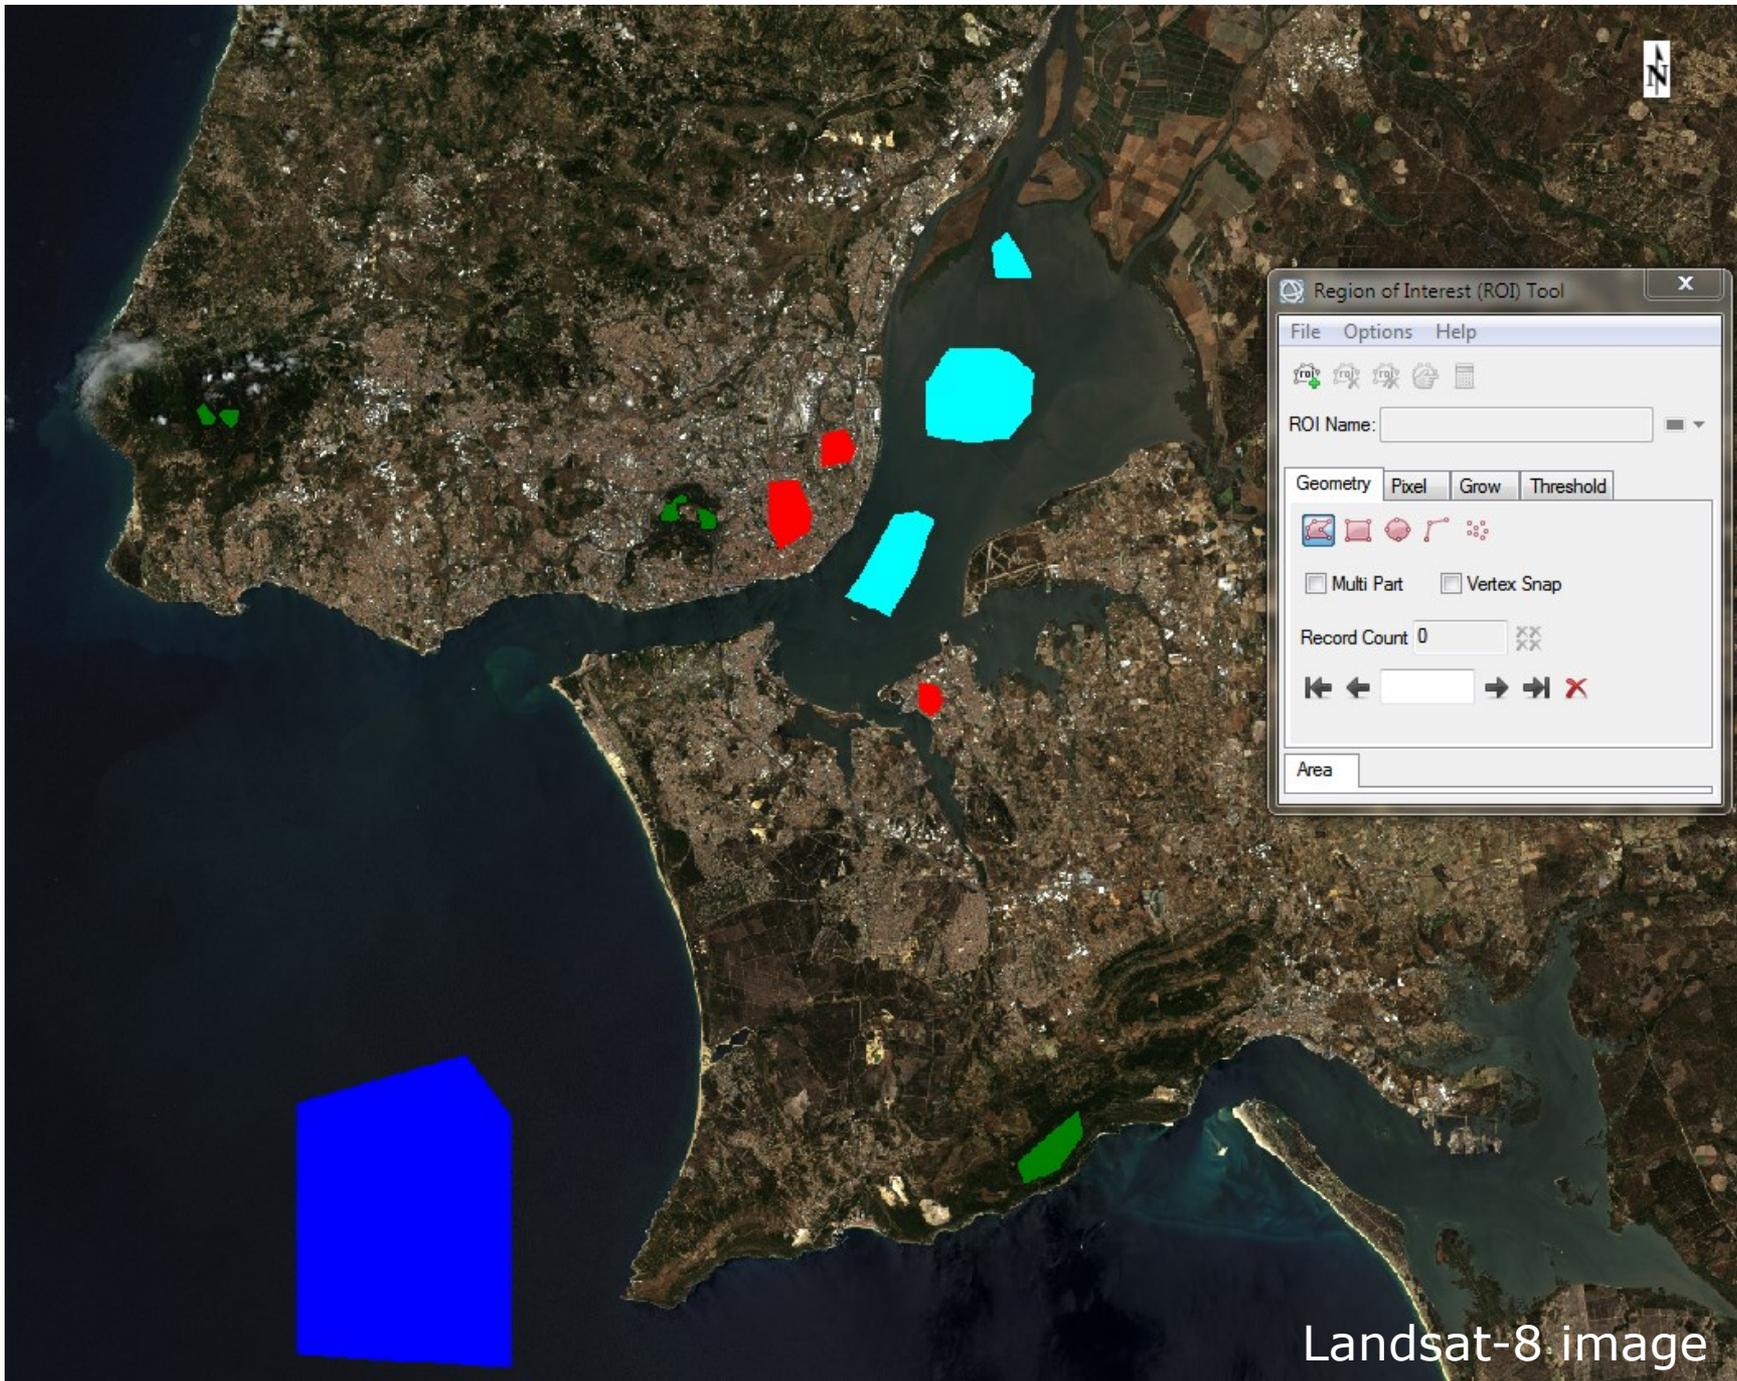
Cursor Value

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]

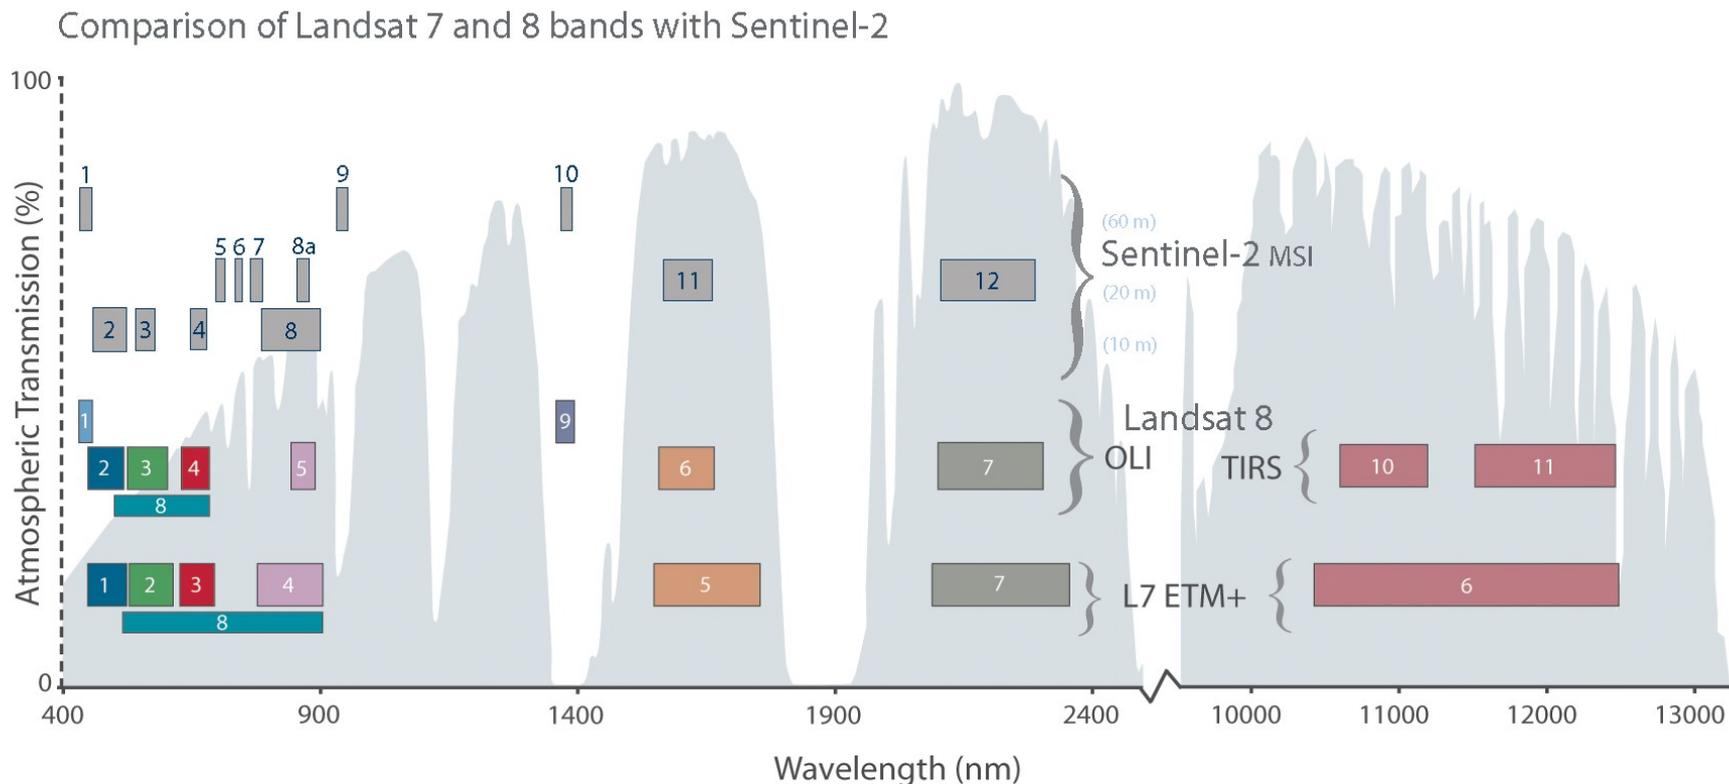
LC82040332013171LGN00_MTL_MultiSpectral
File: 3592.8782,3980.0547
Data: [9996, 10697, 11052]





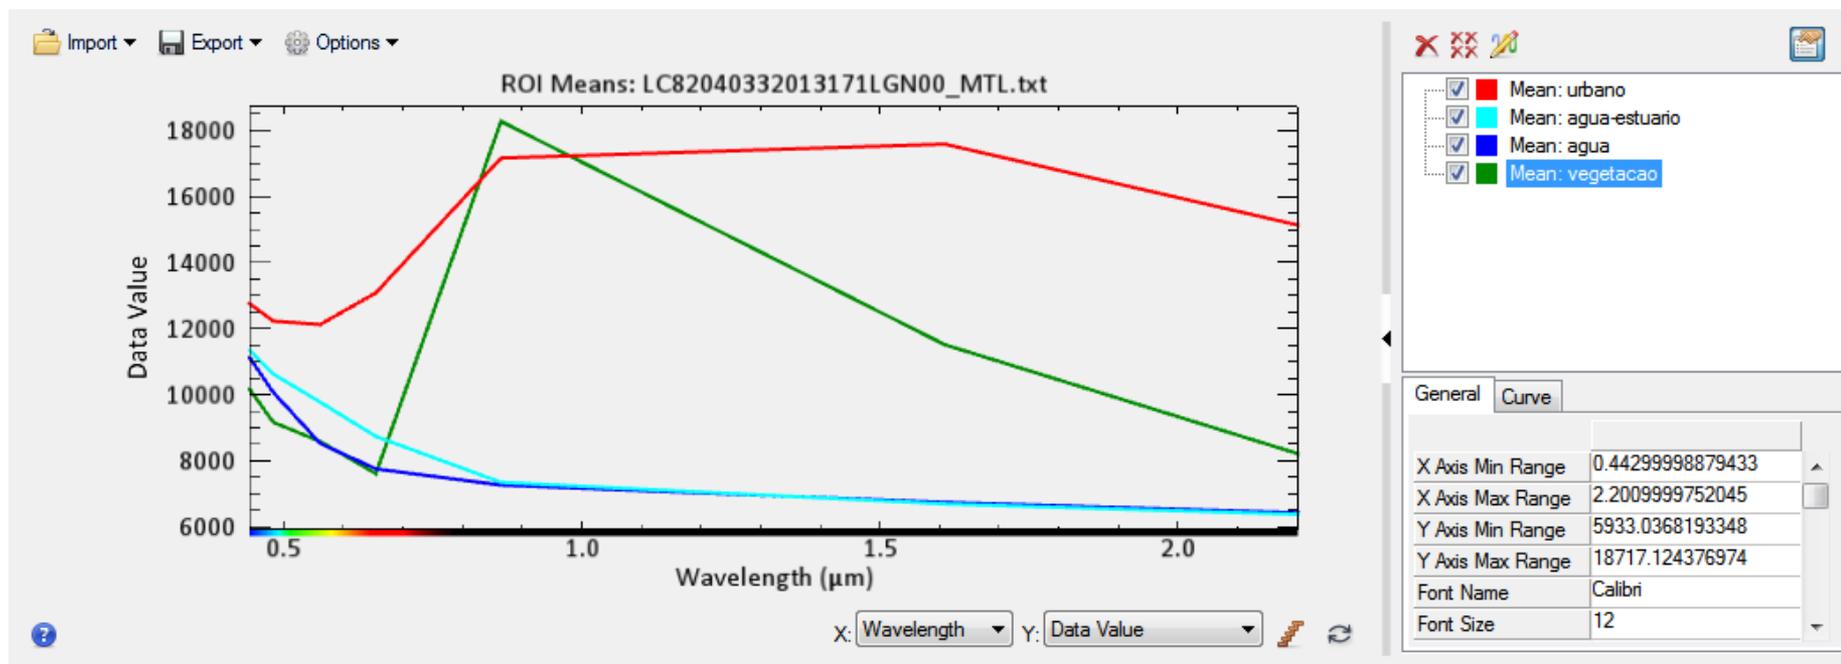
Landsat-8 image

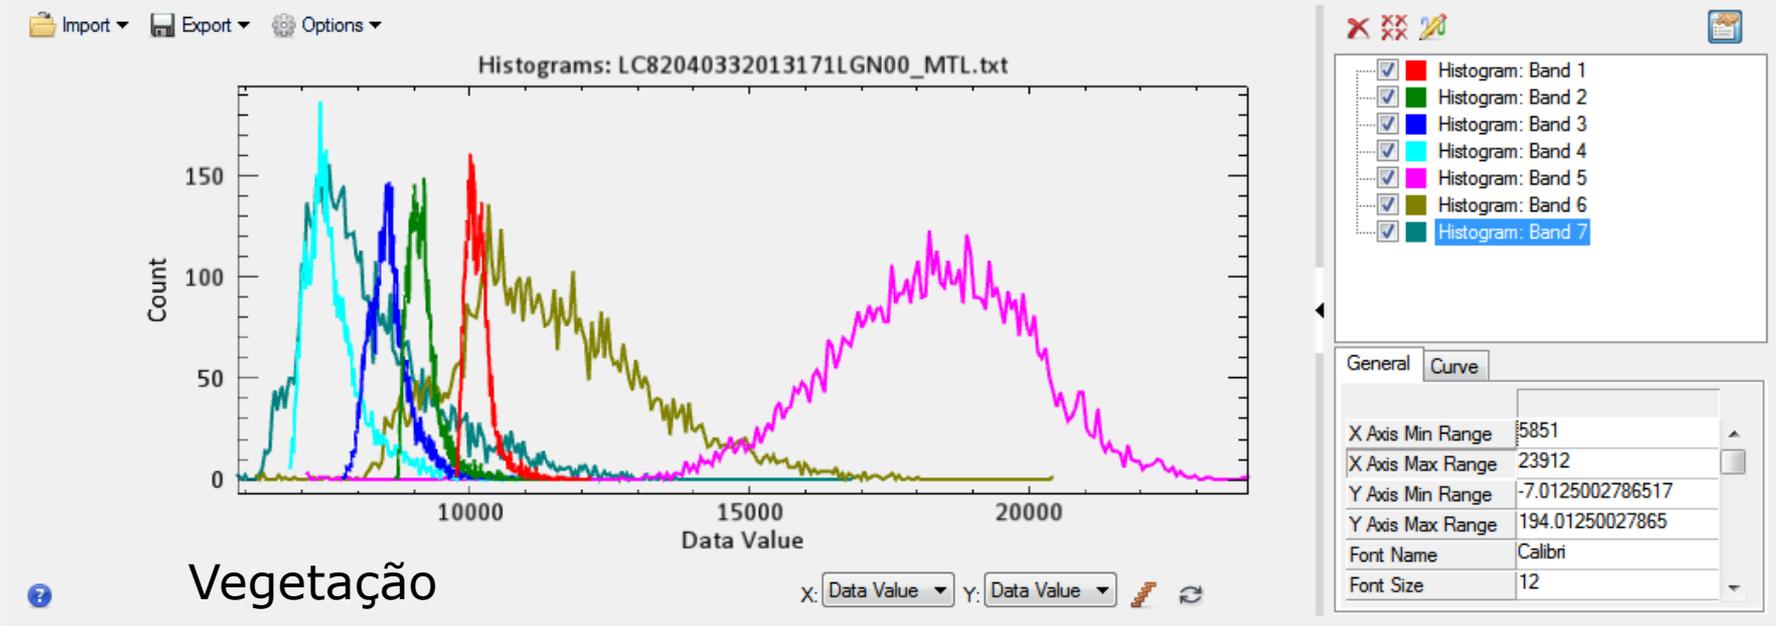
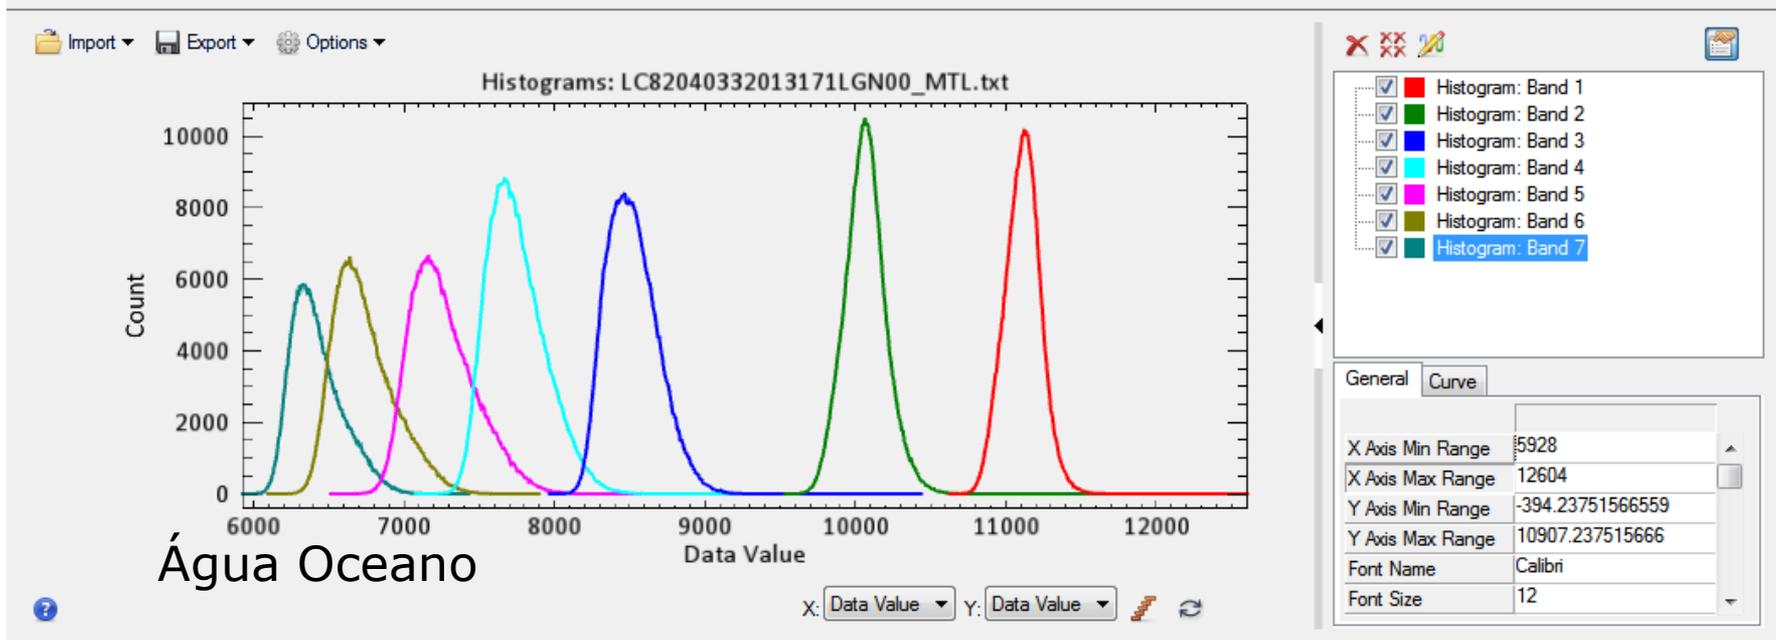
Landsat & Sentinel-2 Spectral bands



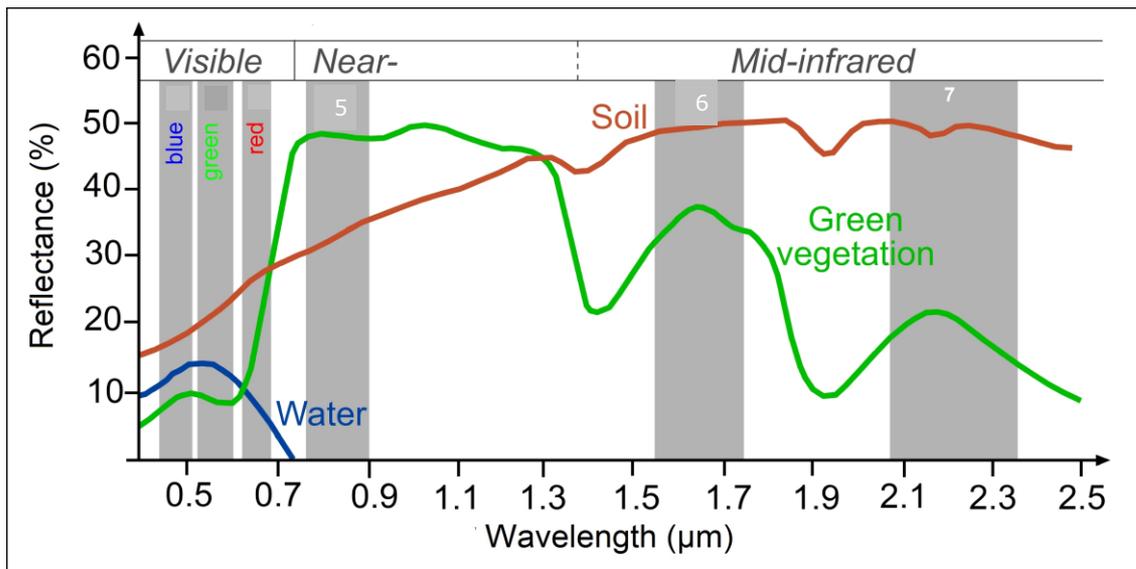


Spectral Reflectance





Índice da Água



$$NDWI = \frac{NIR - SWIR2}{NIR + SWIR2}$$

(conteúdo de água na vegetação)

(Normalized Difference Water Index)

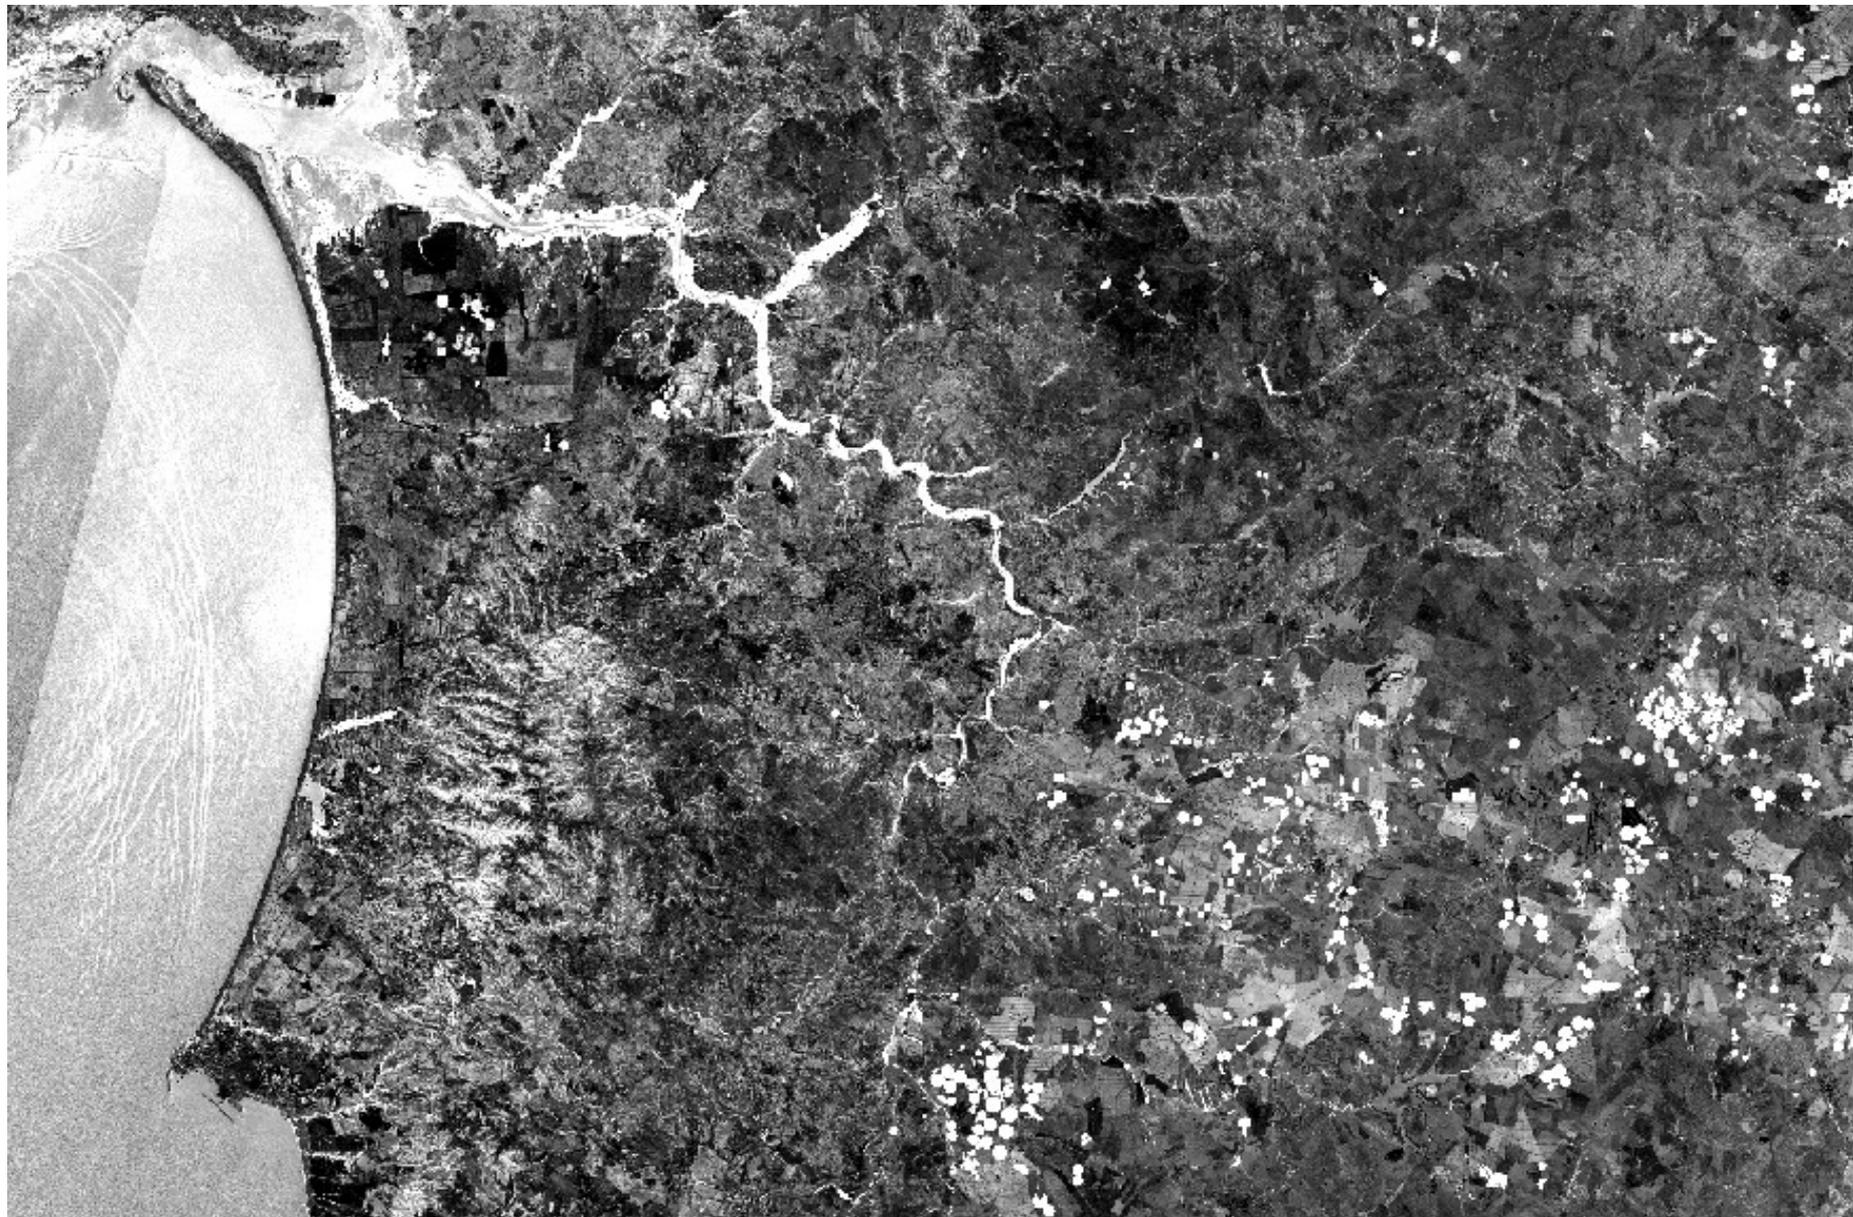
$$NDWI2 = \frac{GREEN - NIR}{GREEN + NIR}$$

Elemento Água



Sentinel-2, T29SNC, 3/8/2019

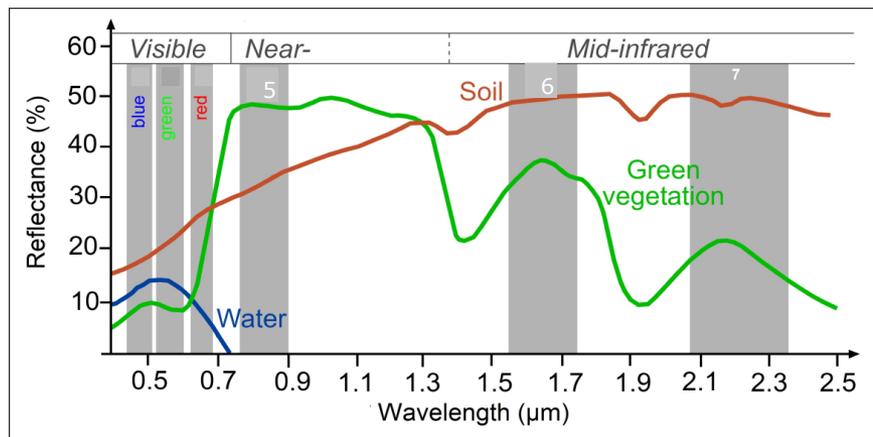
NDWI2



Sentinel-2, T29SNC, 3/8/2019

NDWI

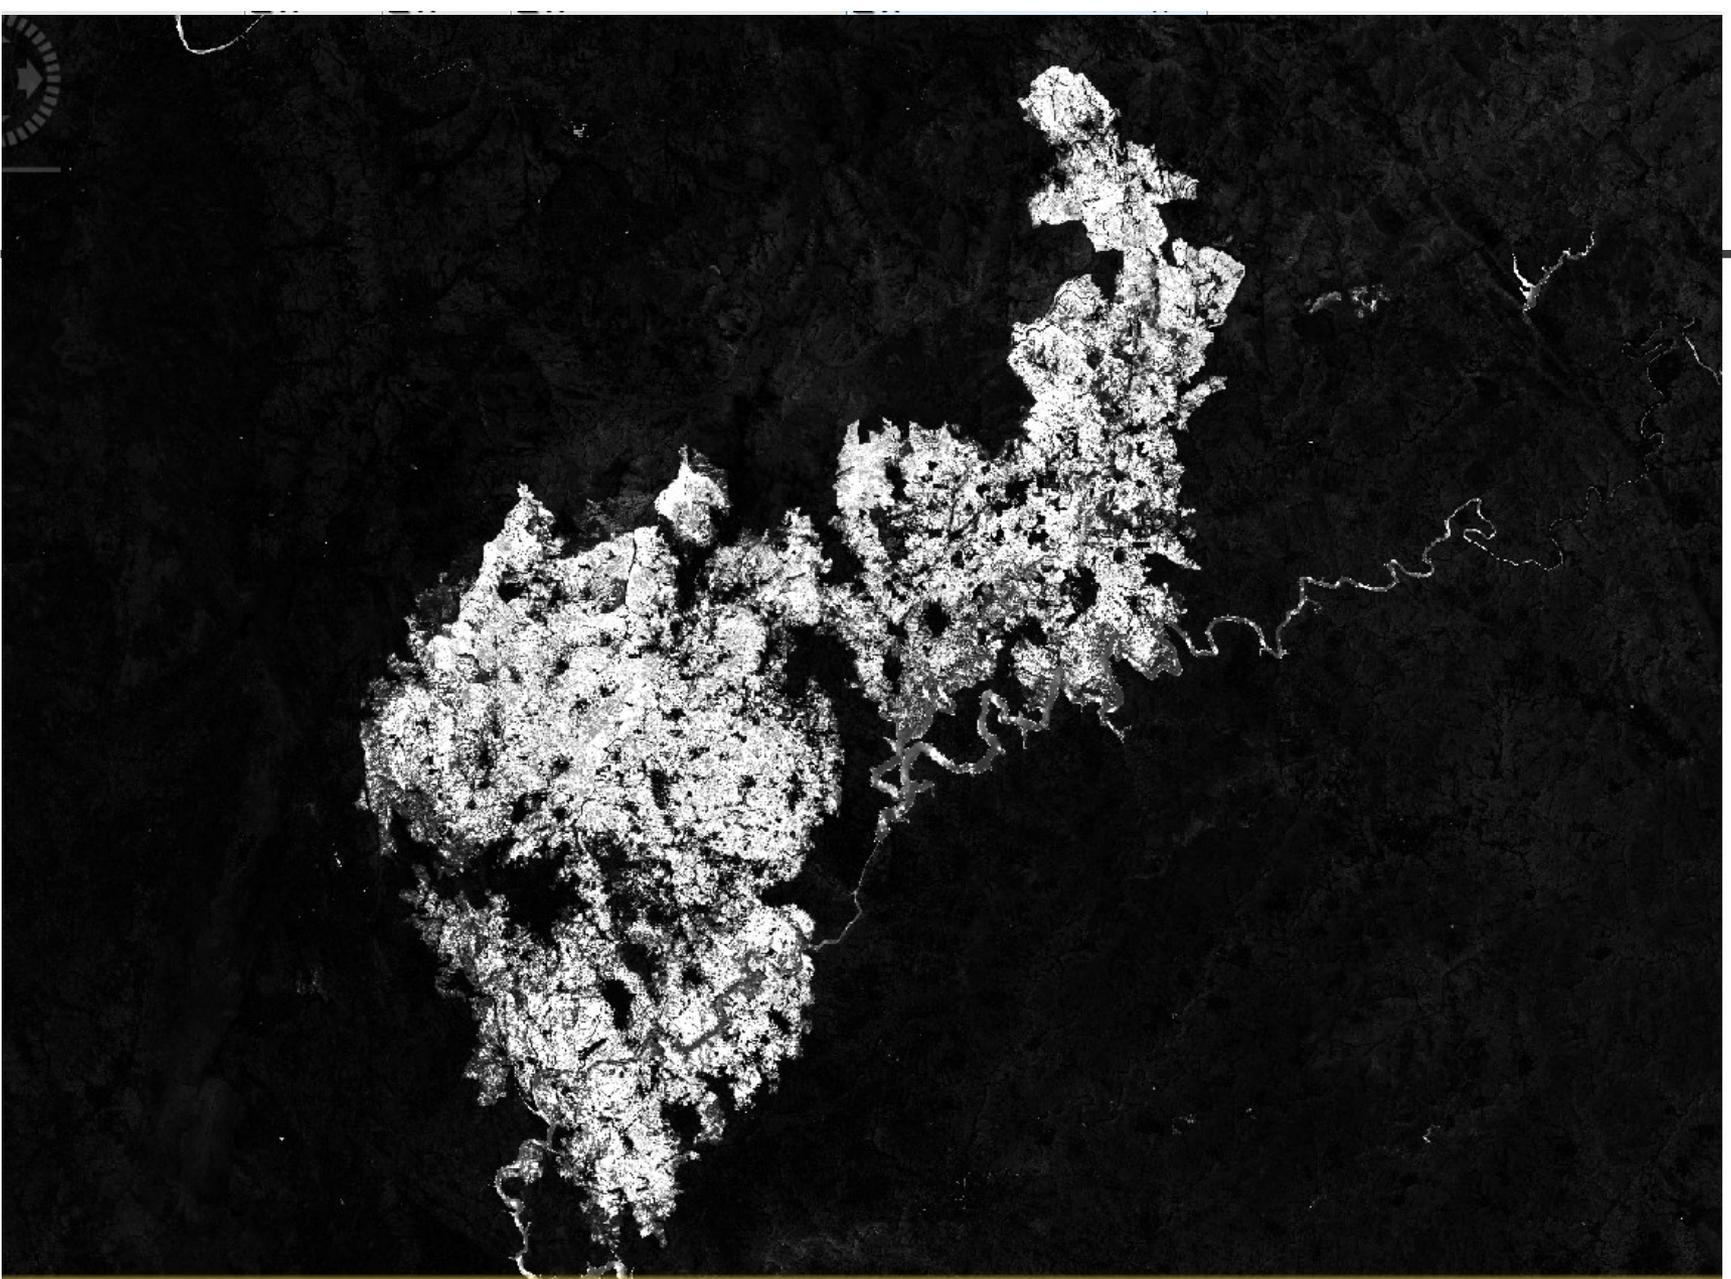
Índice de área ardida



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

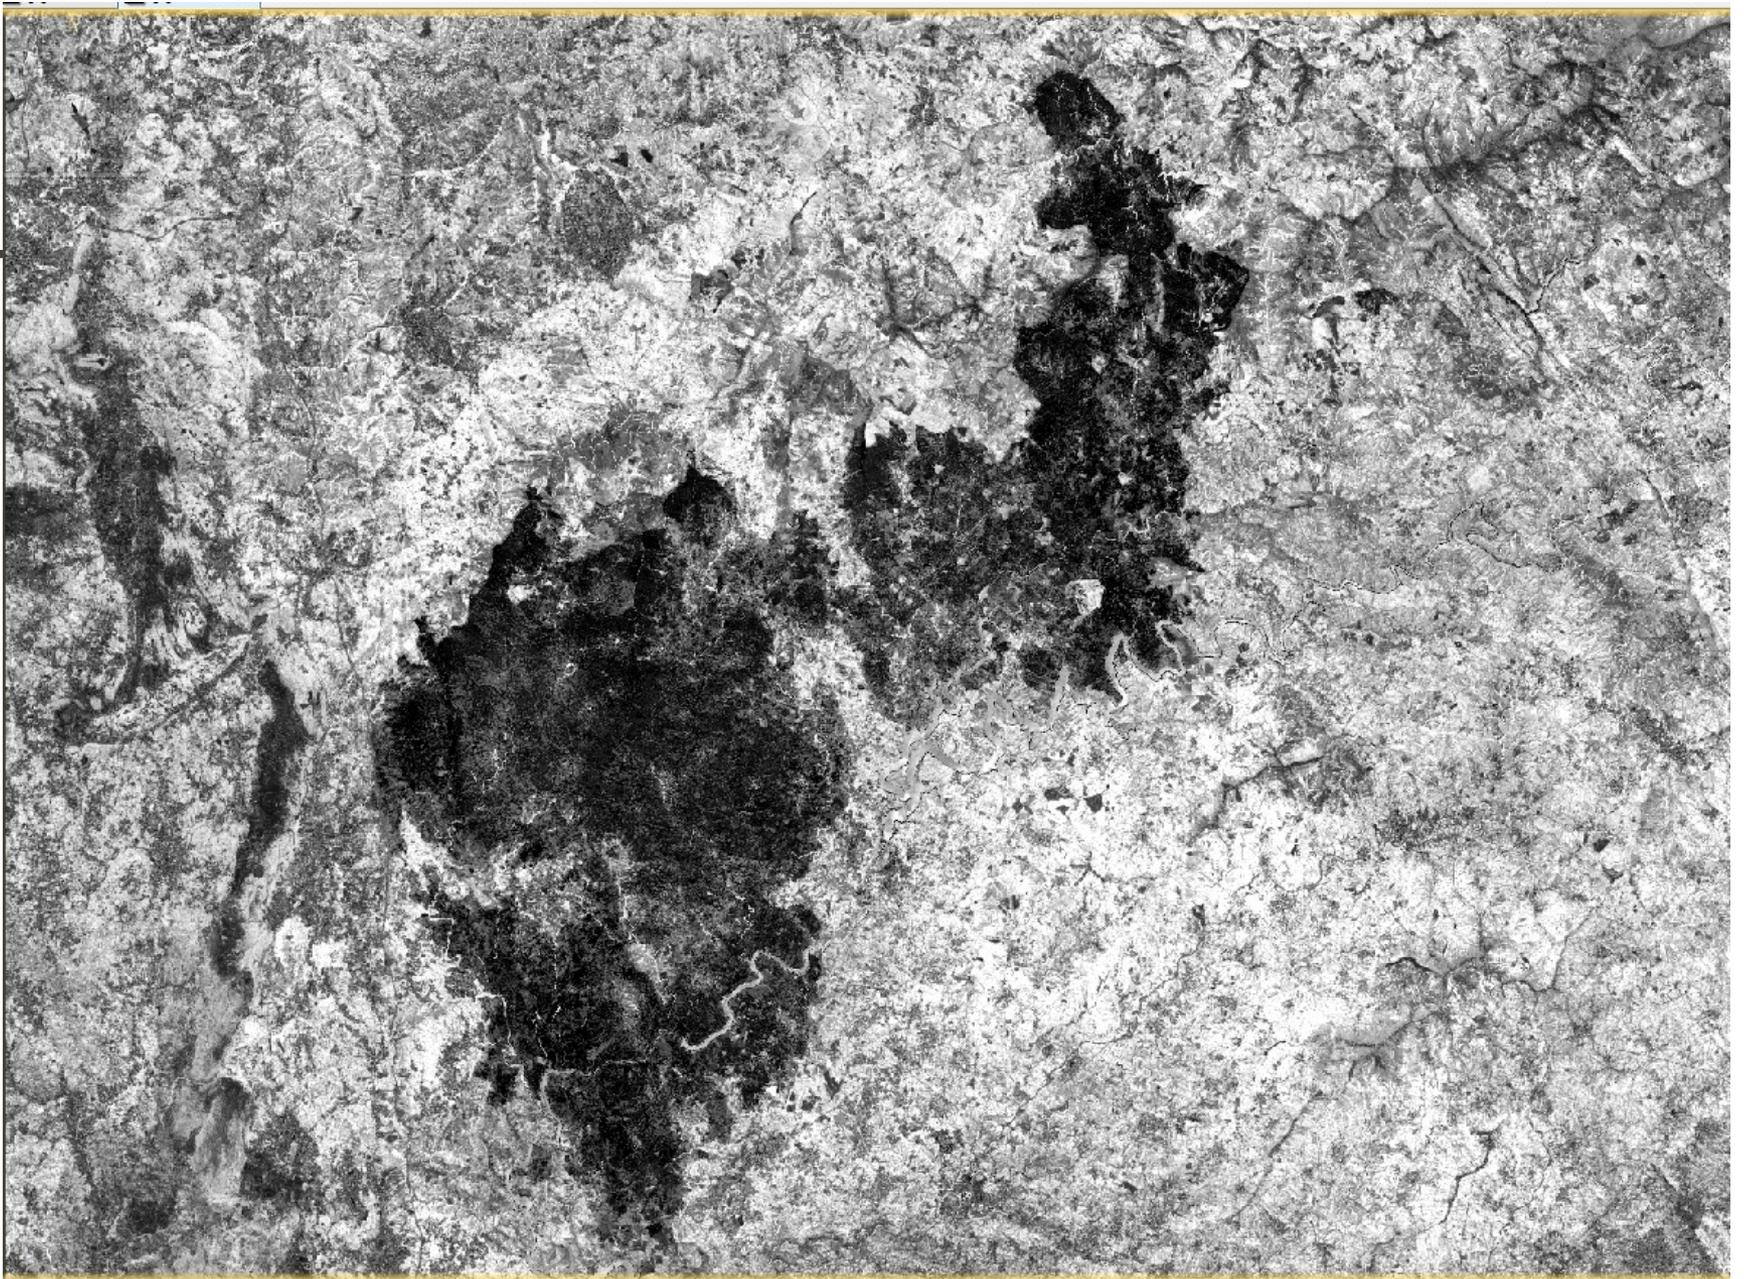
$$BAI = \frac{1}{(\rho_{NIR} - 0.06)^2 + (\rho_{Red} - 0.1)^2}$$

$$NBRS = \frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}}$$



Sentinel-2, T29TNE, 4/7/2017

Burned Area Index (Post_BAI > 188.88)



Sentinel-2, T29TNE, 4/7/2017

Normalized Burn ratio, Post_NBRS < -0.17079

Segmentação de Imagem

(Divisão da imagem em regiões ou objectos, segundo um critério)

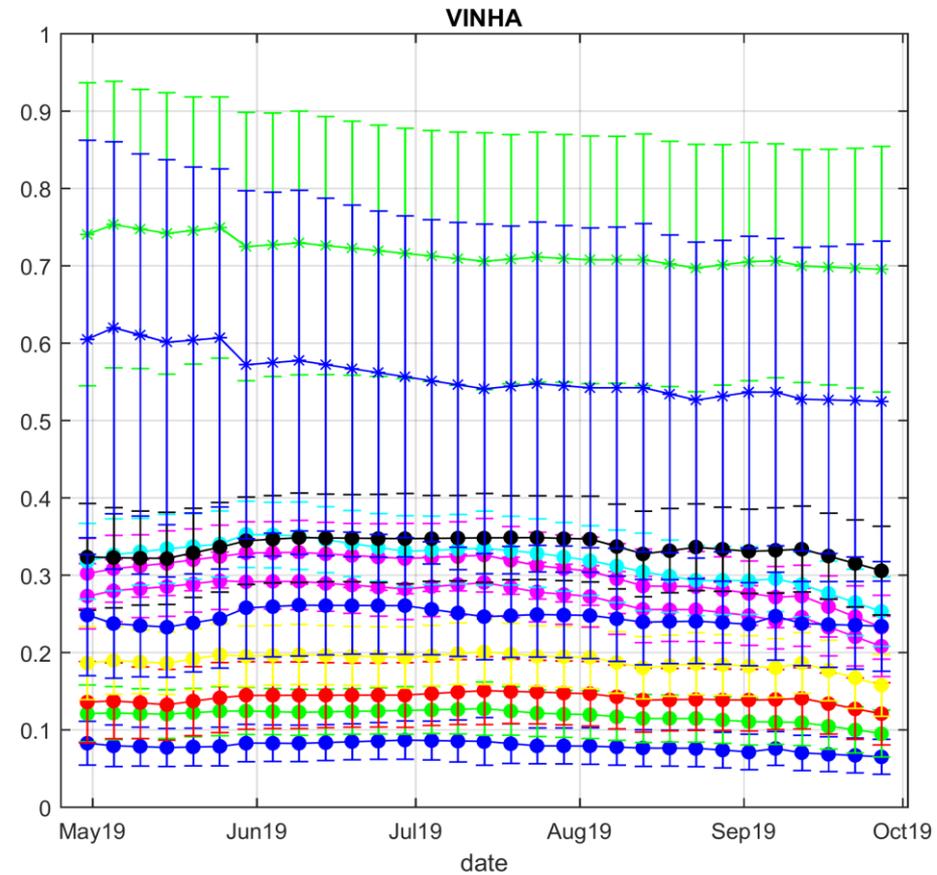
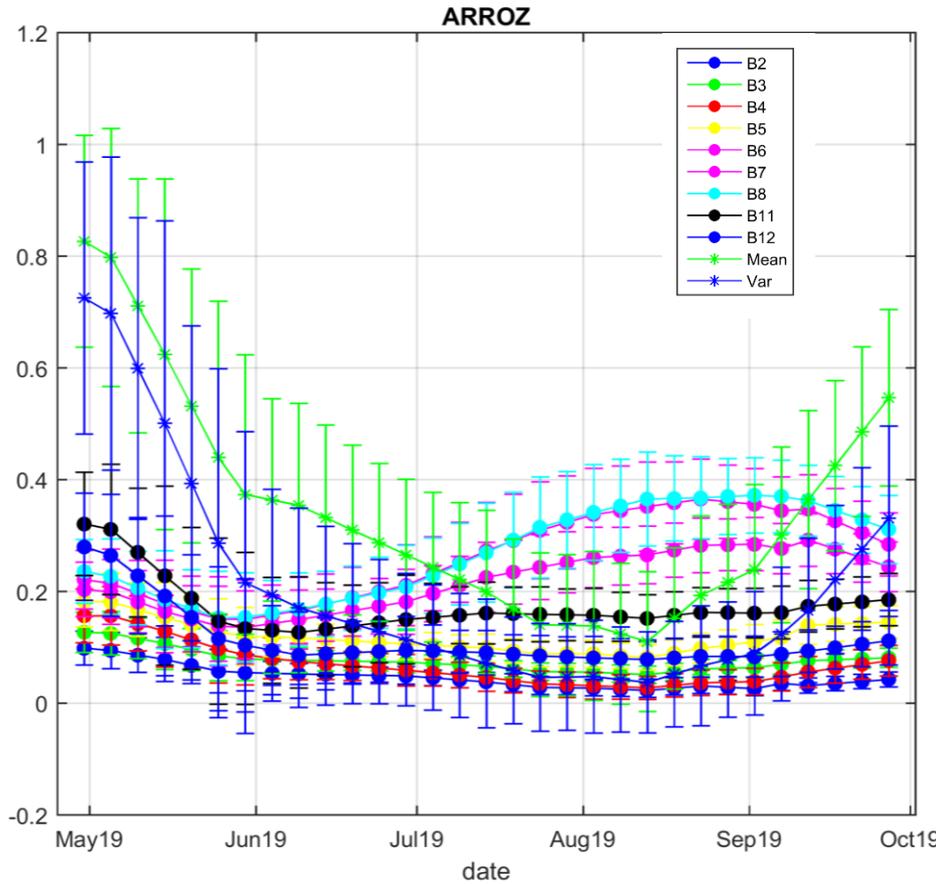
NDWI2: Água / não Água

NDVI: Vegetação / não Vegetação

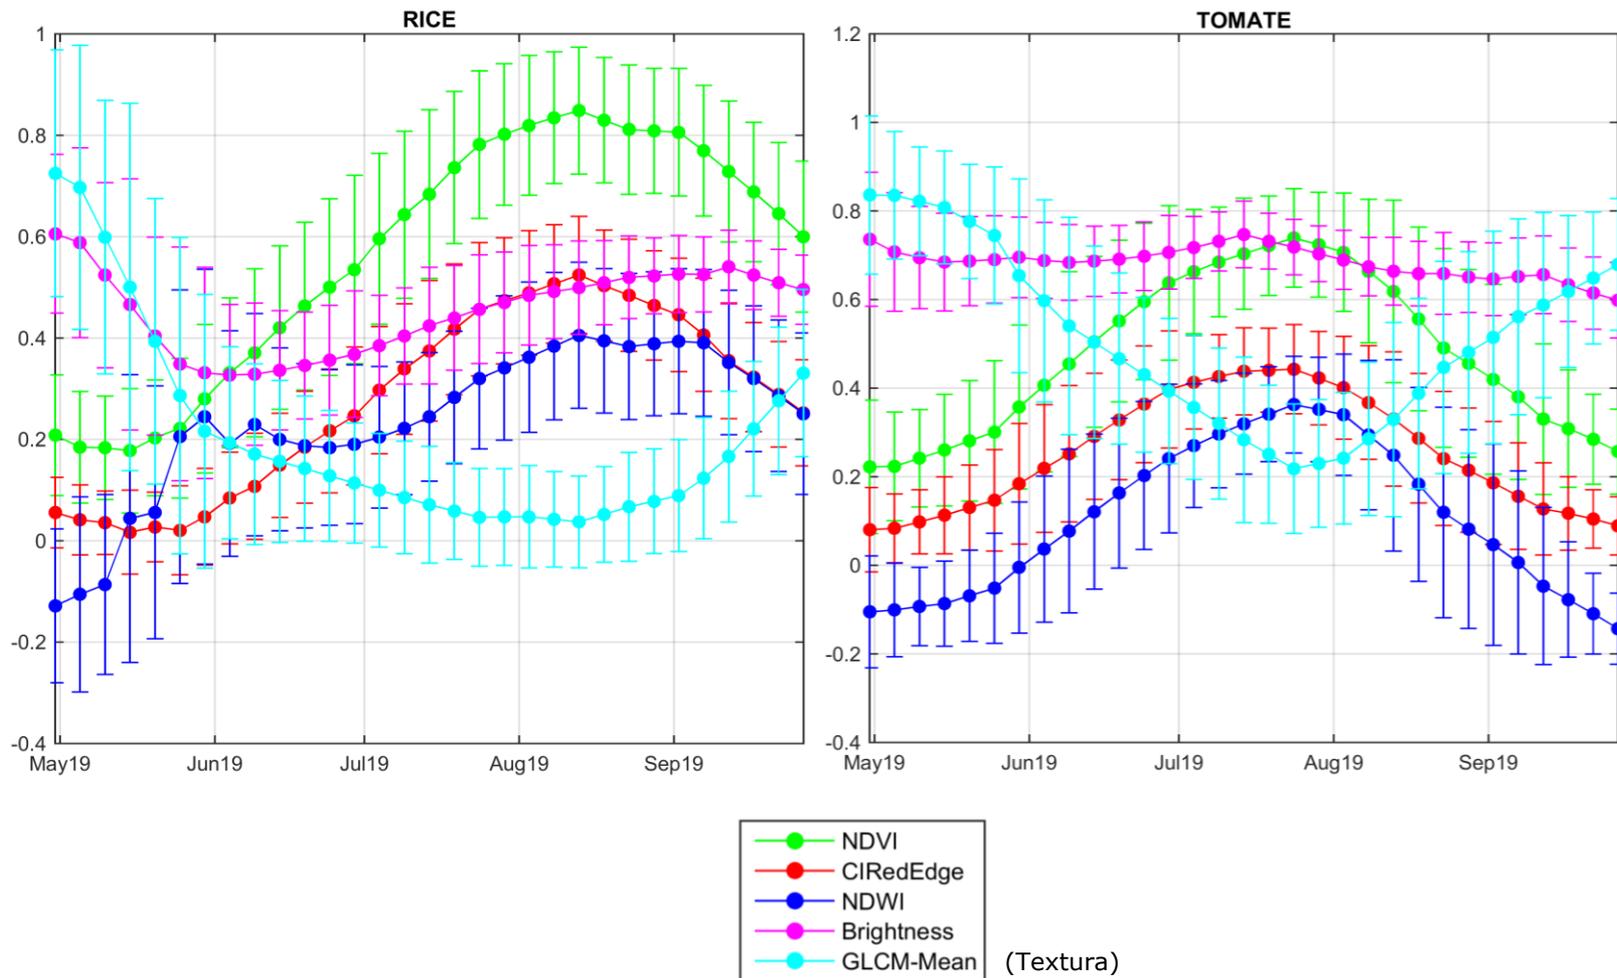
NDVI: Culturas temporárias/
Culturas Permanentes.

NDVI: Vitalidade da vegetação

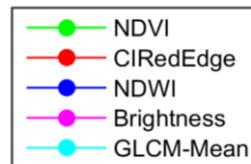
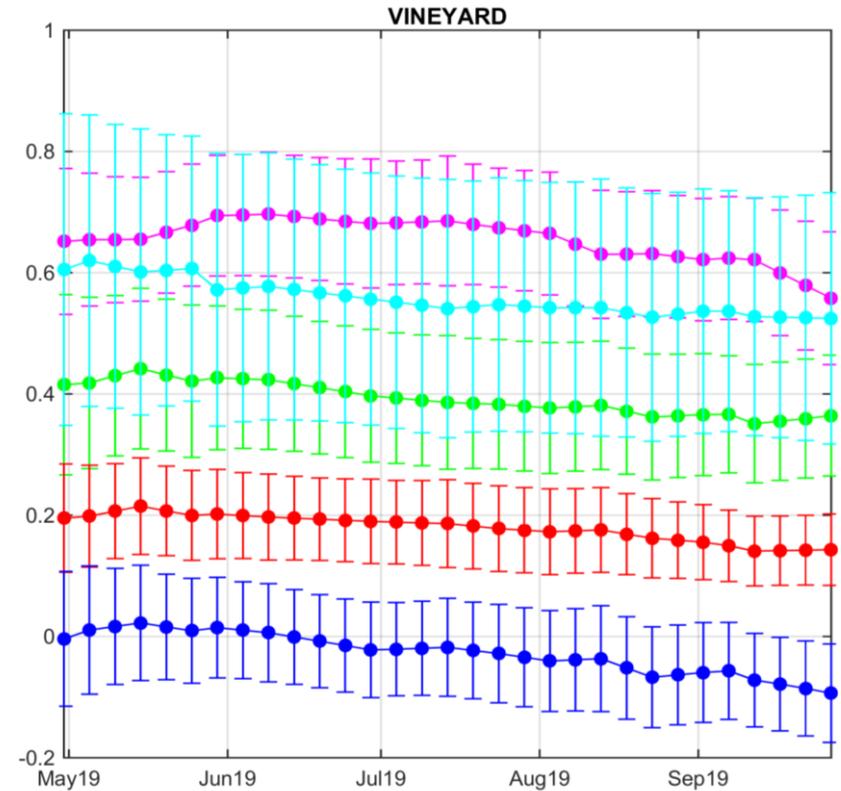
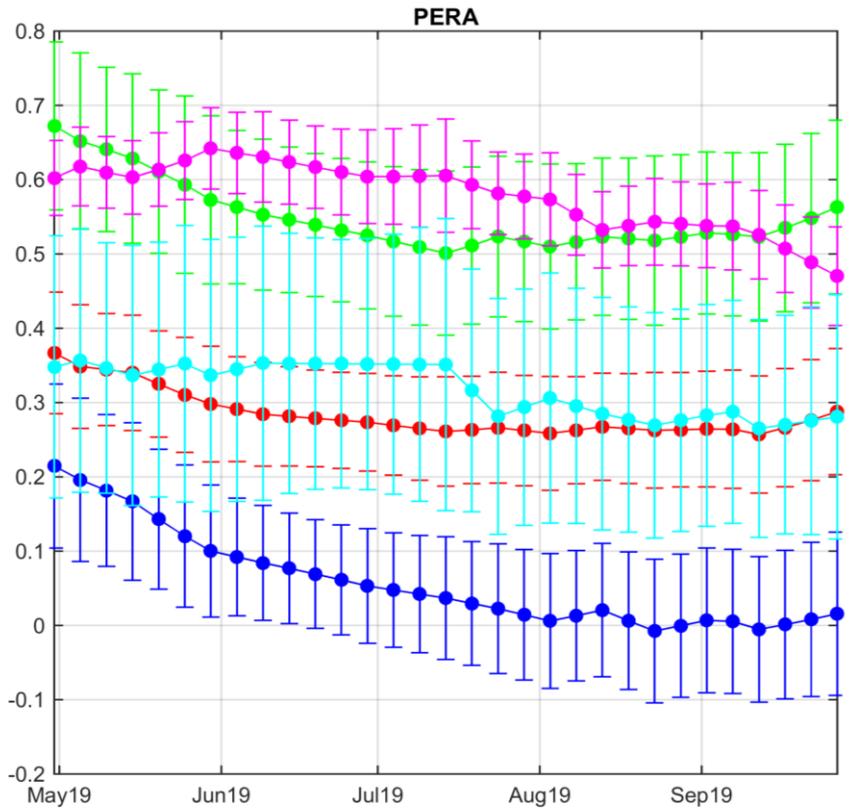
Spectral Signature

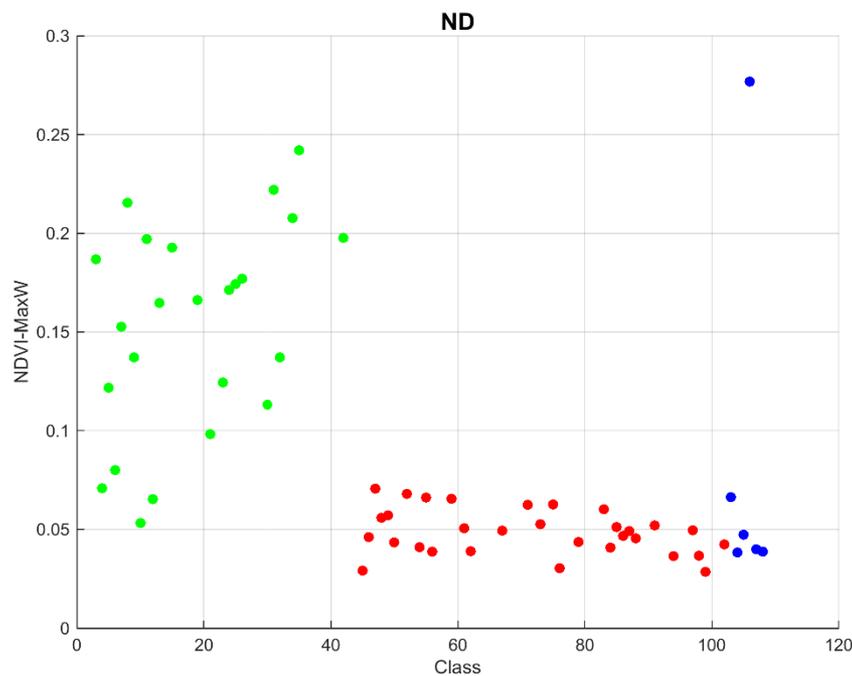
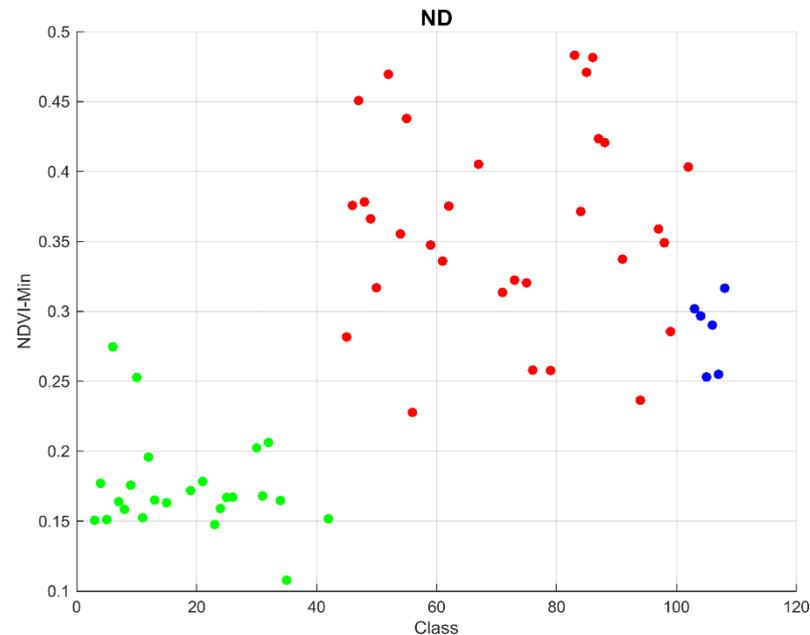
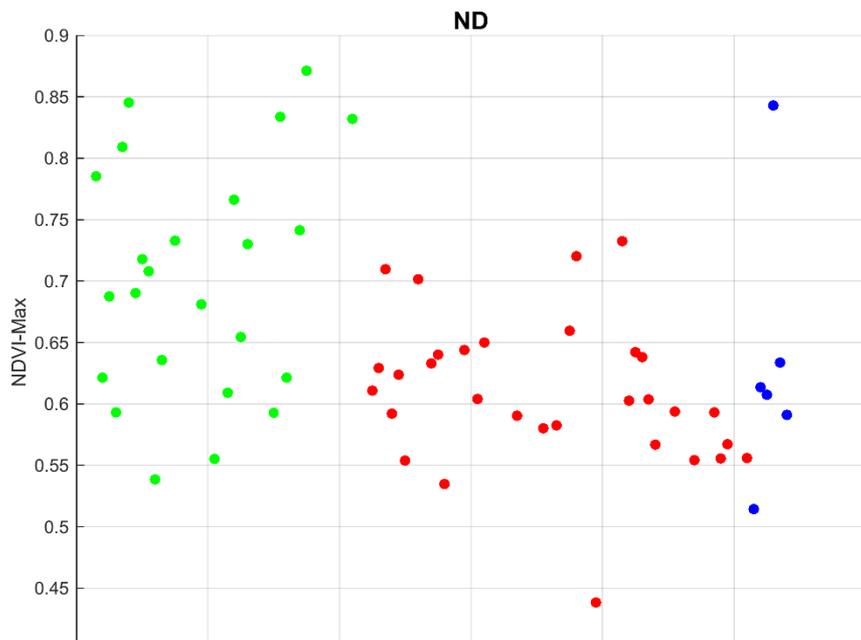


Assinatura Espetral - Culturas Temporárias



Assinatura Espetral - Culturas Permanentes





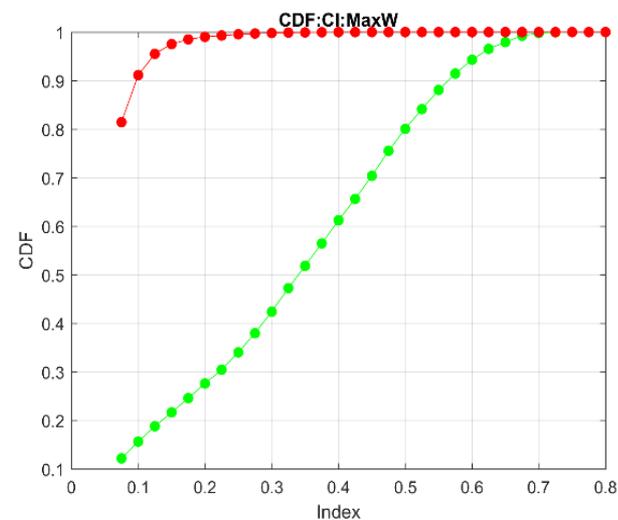
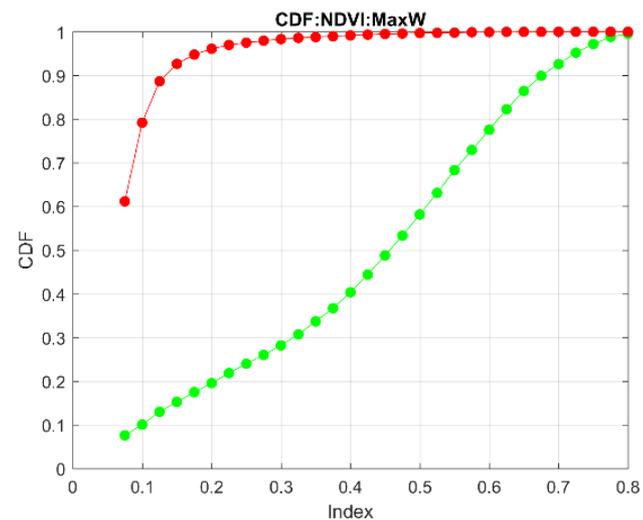
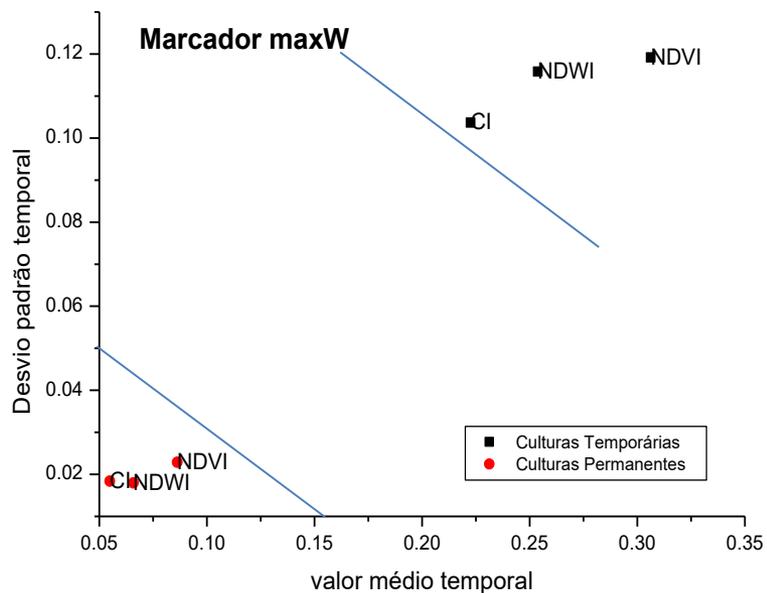
Métricas baseadas em índices
Min, Máx, Média, Std, maxW,
MinW

Verde: Culturas Temporárias

Vermelho: Culturas Permanentes

Azul: Vinha+ Olival+ ..

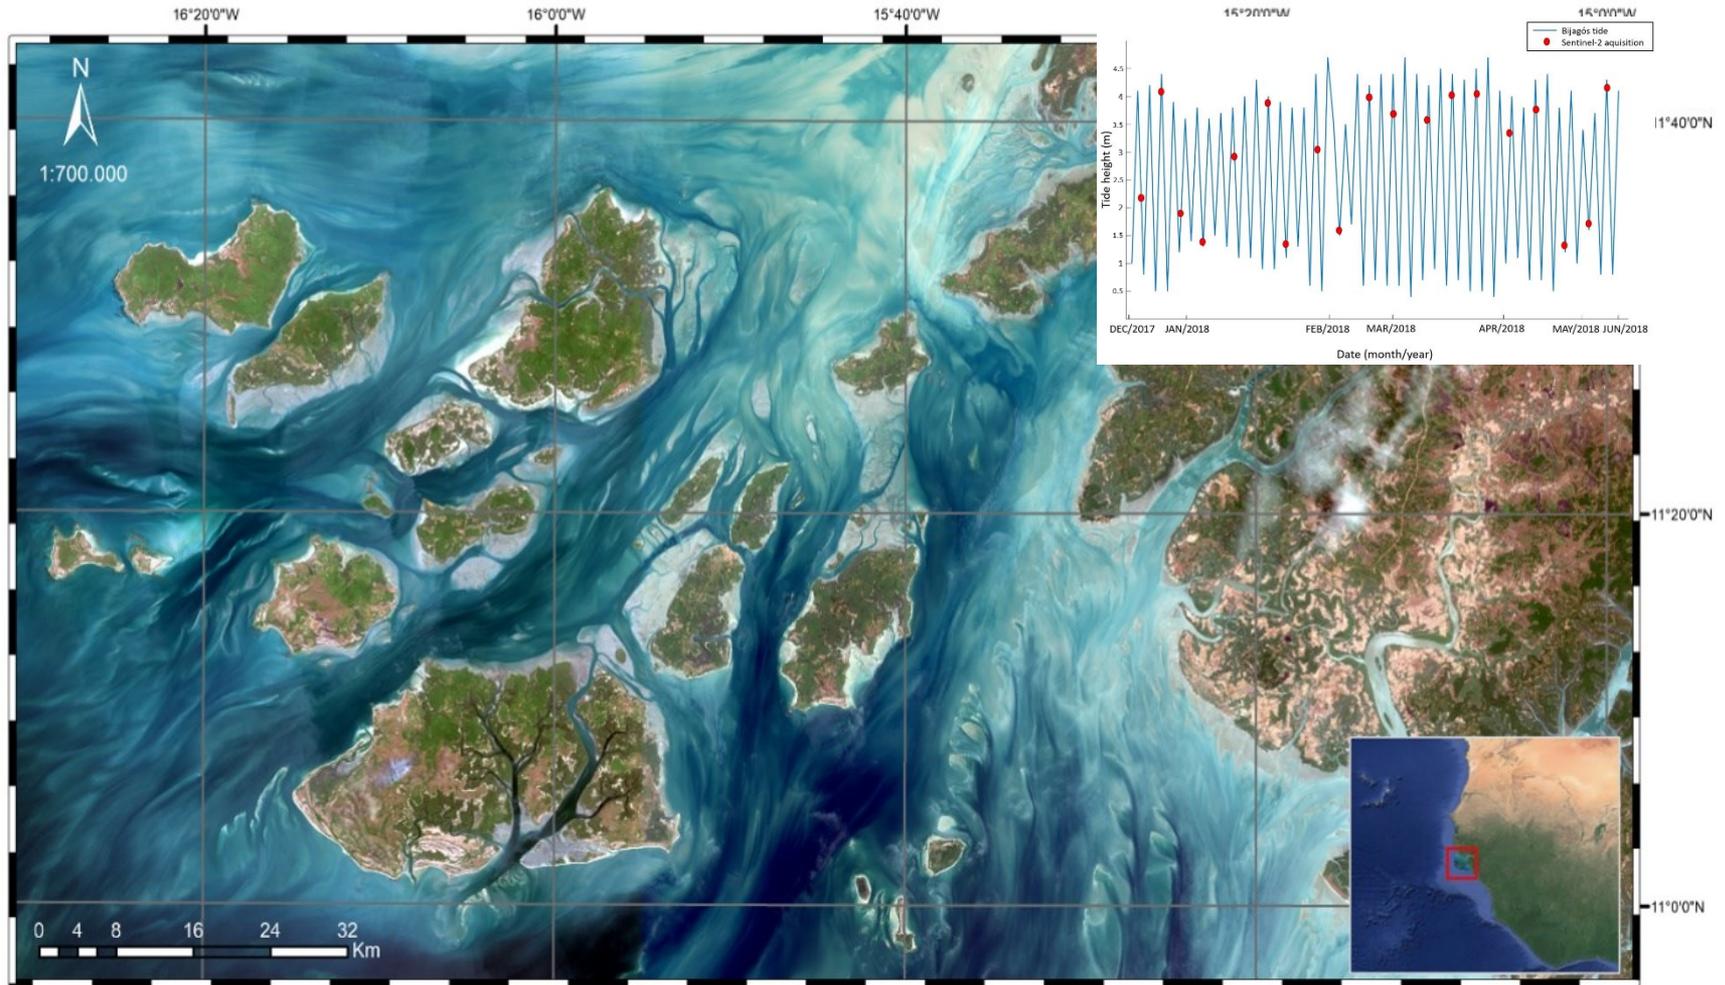
Função Distribuição Cumulativa



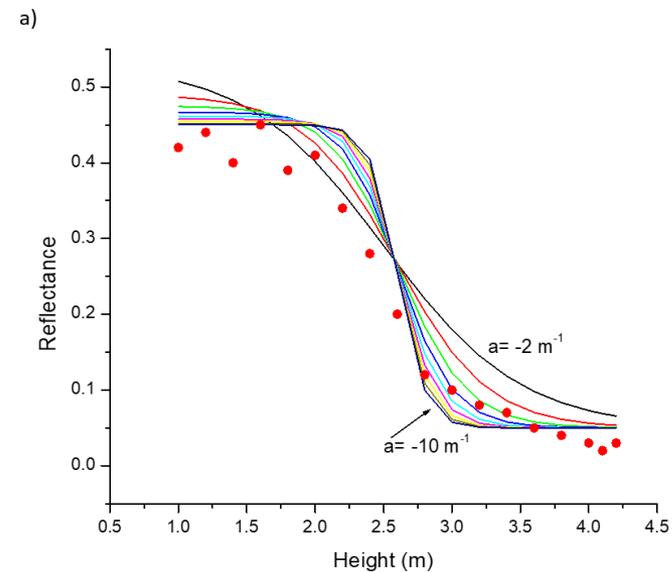
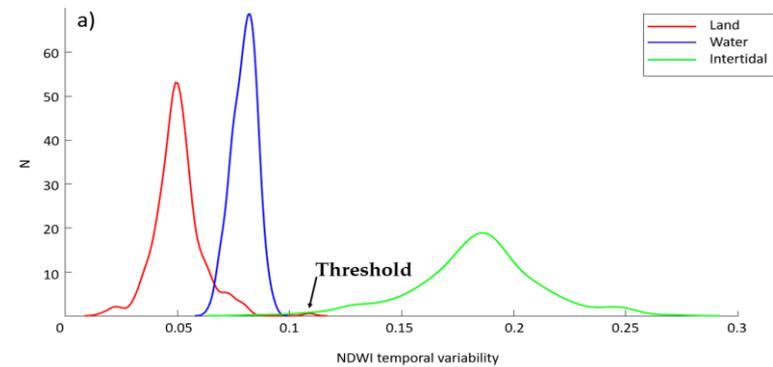
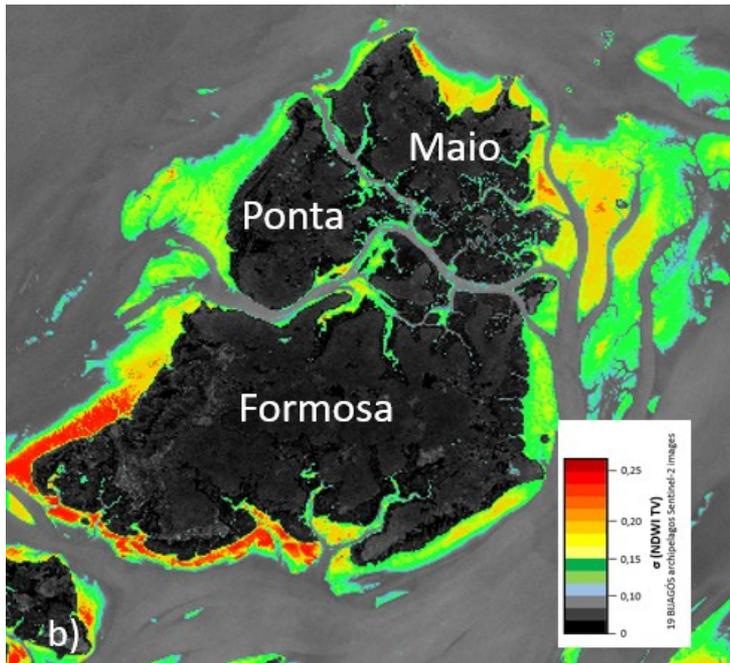
Verde: Culturas Temporárias

Vermelho: Culturas Permanentes

Intertidal bathymetry Bijagos



Intertidal bathymetry Bijagos



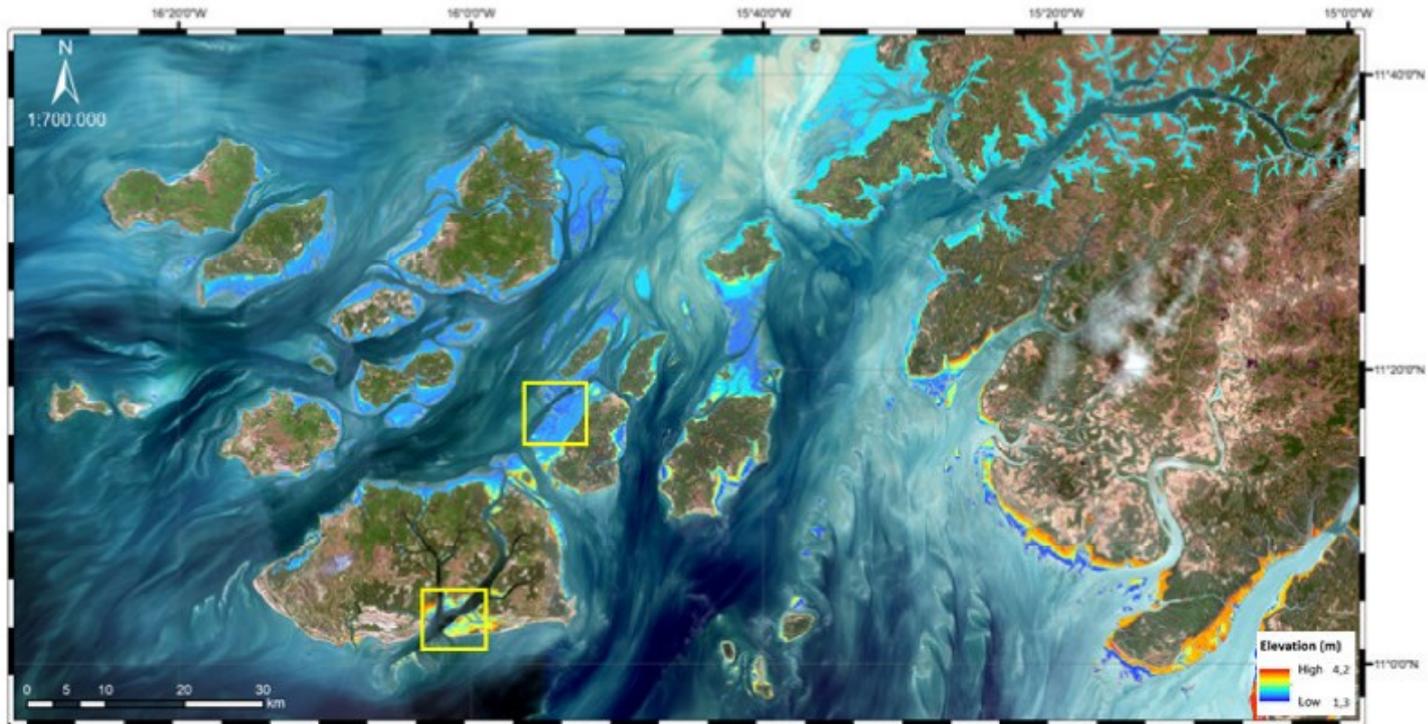
$$\sigma(x, y) = \sqrt{\frac{1}{M} \sum_{i=1}^M (NDWI_i - \overline{NDWI})^2}$$

Regressão Logística:

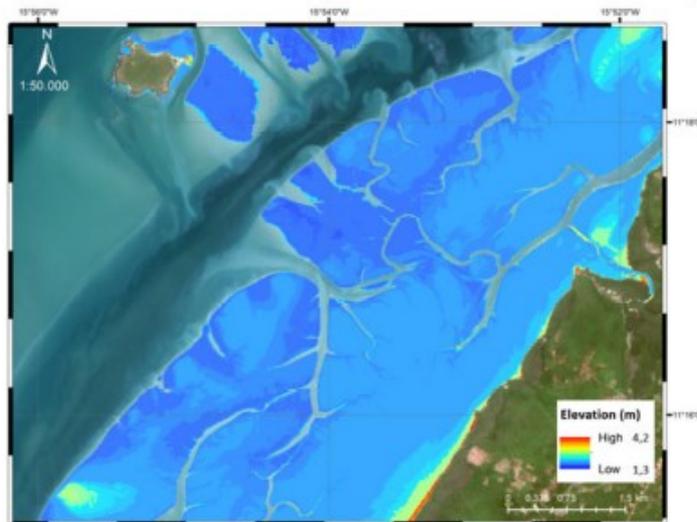
$$\rho_i(x, y) = \frac{k}{1 + e^{-a(h_i - h_t)}} + LowLim$$



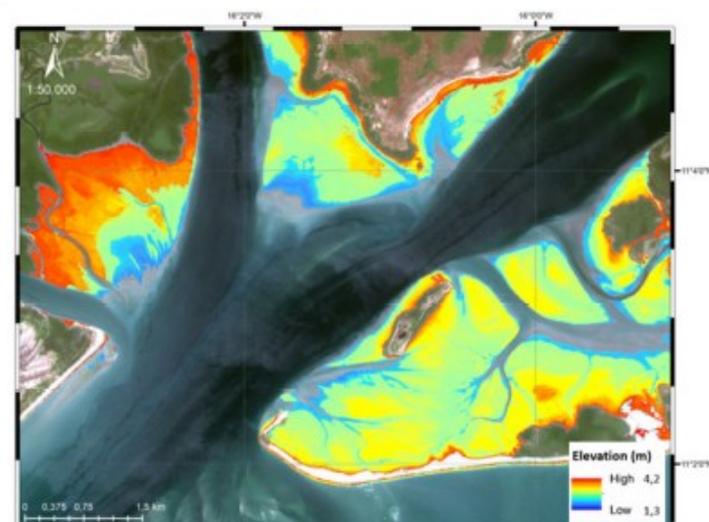
Ciências
ULisboa



(a)



(b)



(c)

Período de
exposição
da zona
intertidal

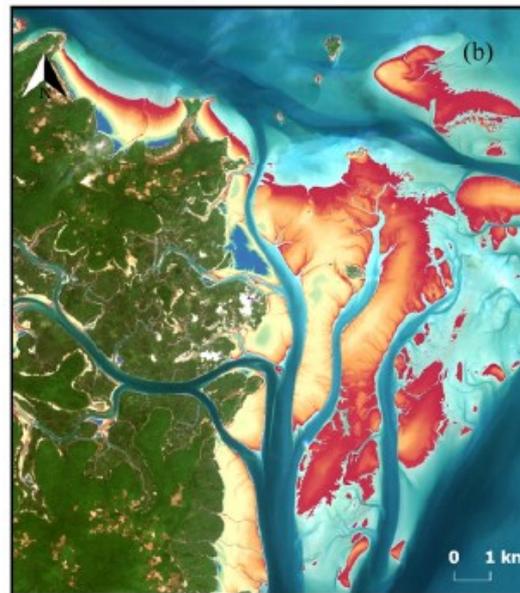
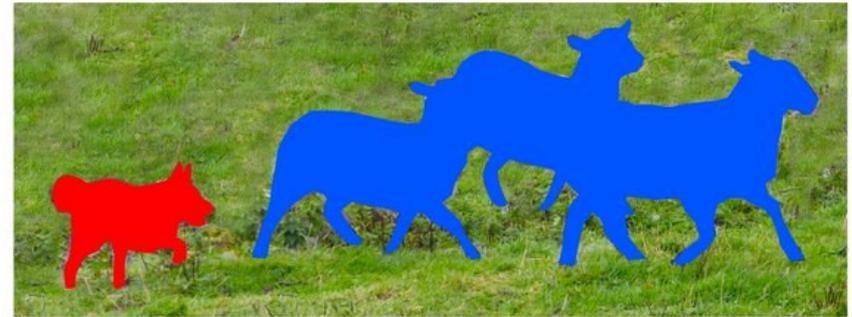




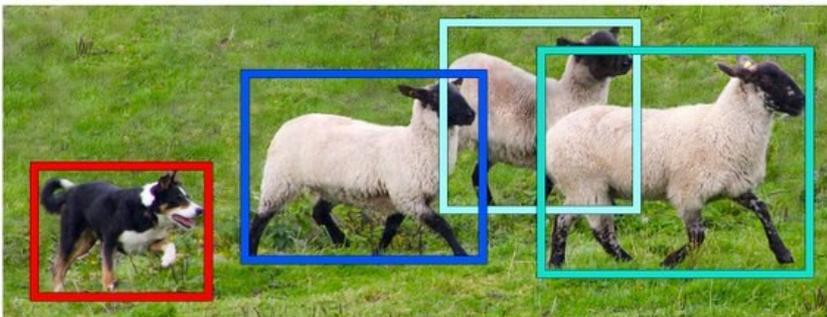
Image Classification



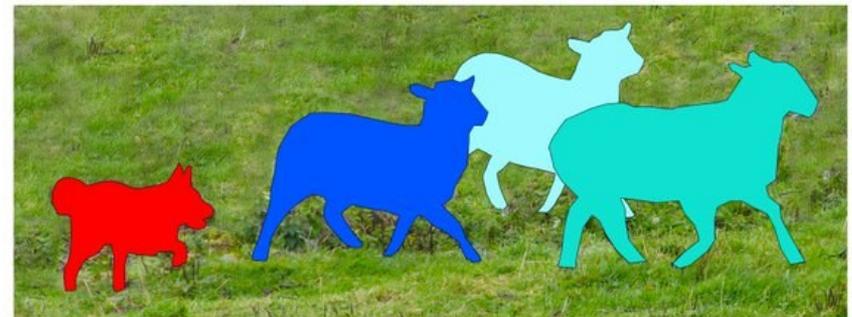
Image Recognition



Semantic Segmentation



Object Detection



Instance Segmentation

Segmentation in an image is the process of the breaking down the digital image into multiple segments (that is divided into the set of different pixels into an image).



Ciências
ULisboa

Image Classification



Image classification actually, refers to the task of extracting the information classes from a multiband raster image. It analyzes the numerical properties of various image features and organizes the data into the different categories — or you can say image classification is like image categorization.

In fact, **data classification** algorithms typically employ two phases of processing — training and testing.



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

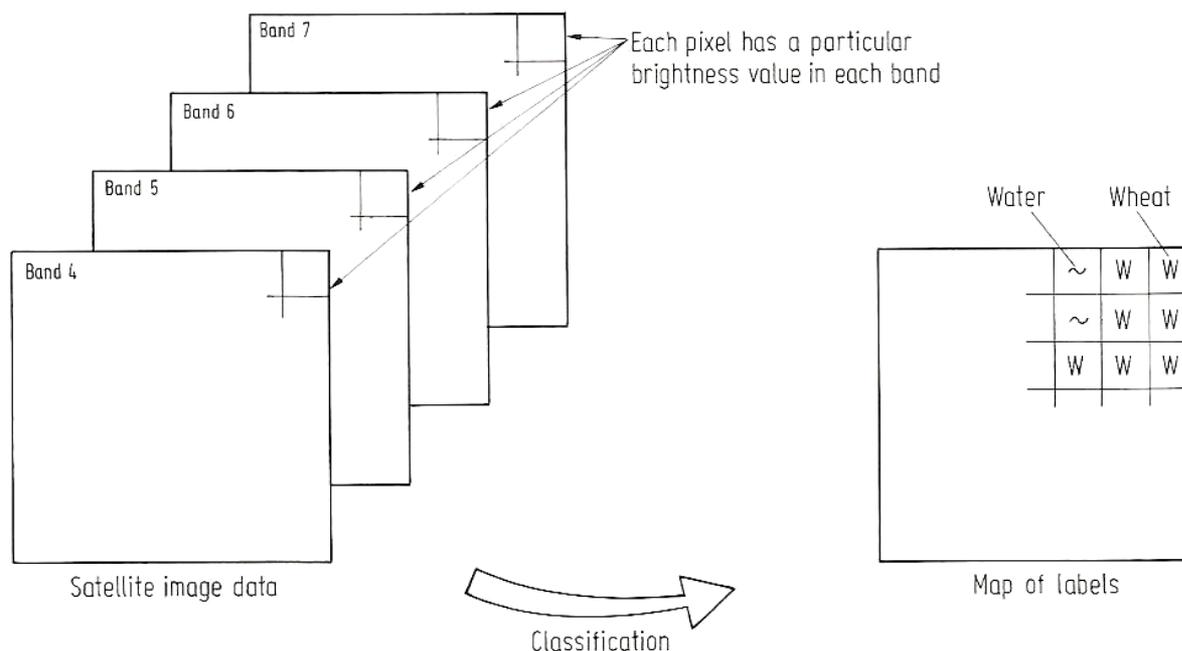


Image Classification

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

UnSupervised

(clustering)

Os píxeis 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

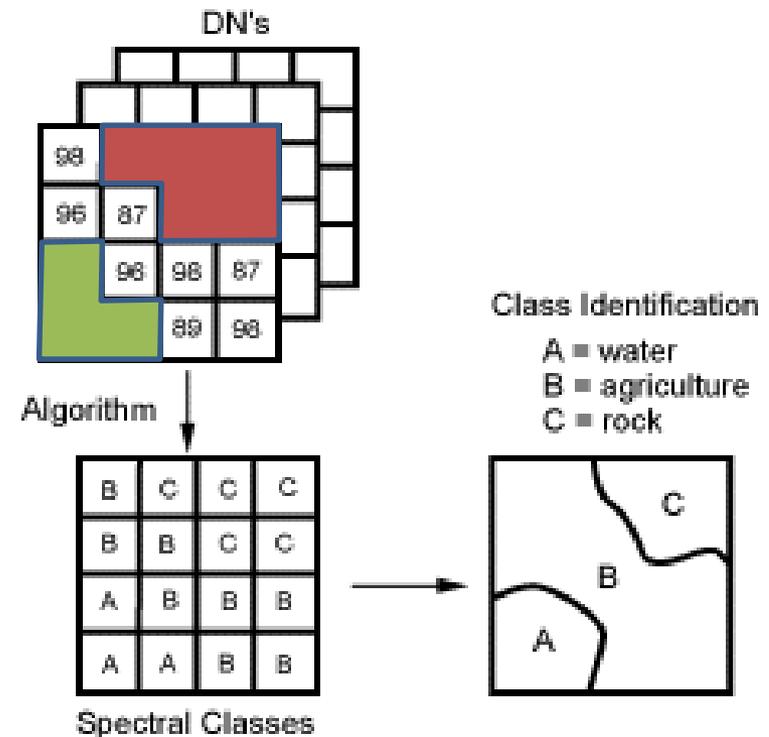
ISOData
K-Means
Aprendizagem Automática

Unsupervised methods

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

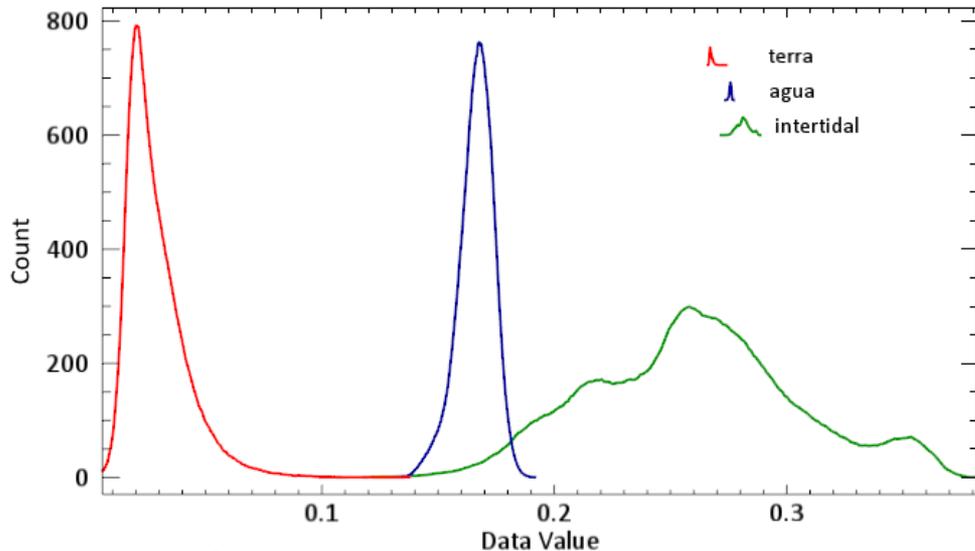
Este método baseia-se em algoritmos que analisam todos os píxeis e formam conjuntos de píxeis (os chamados *cluster* ou padrões) apenas olhando ao valores dos píxeis.

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



Unsupervised method– K-Means

NDWI temporal variability

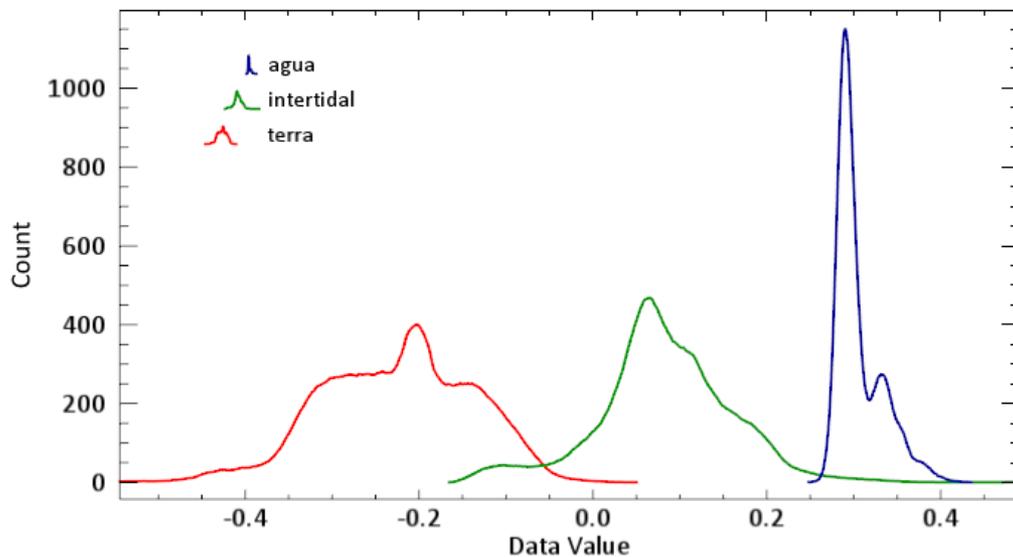


Band 1

Two bands / 3 classes

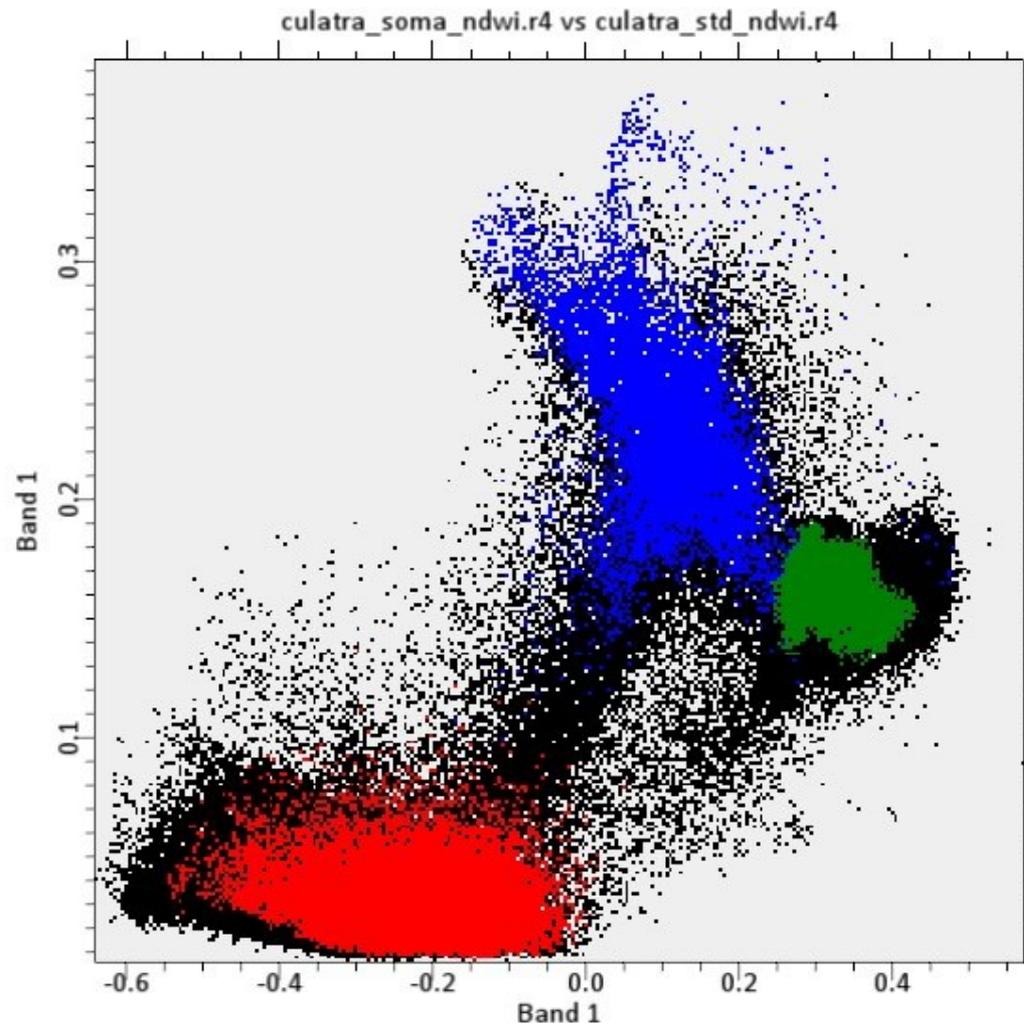
Band 2

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 píxeis a essas classes usando a medida da mínima distância.

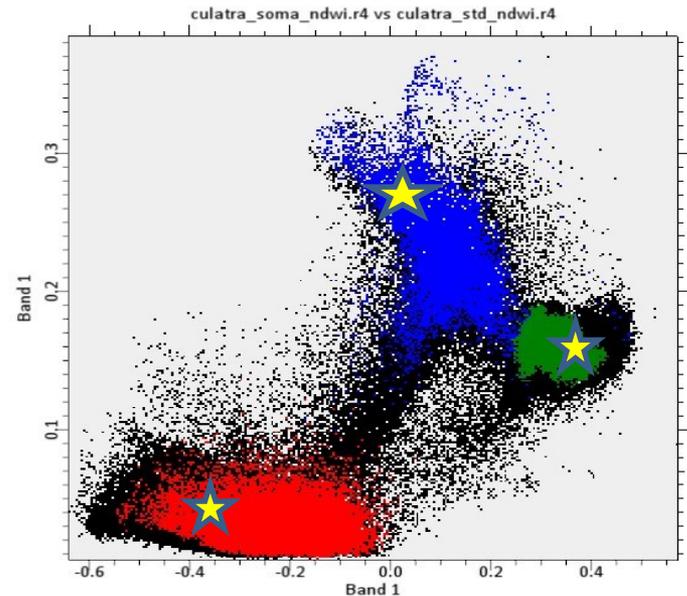
Cada iteração recalcula a média e reclassifica os píxeis relativamente à nova média

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

O processo é continuado até que o número 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

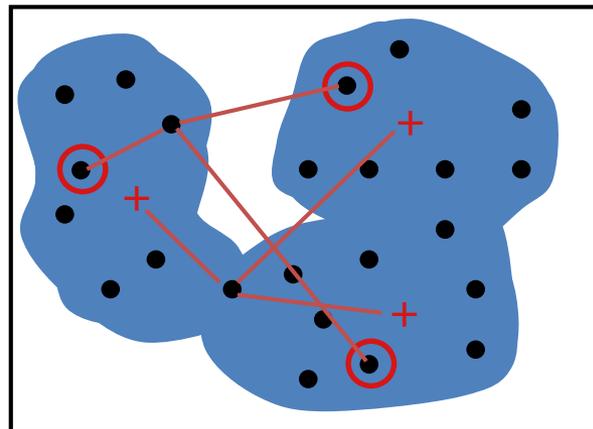


Centróide = centro de gravidade do cluster

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

Algoritmo K-means

Exemplo K = 3



2ª Iteração



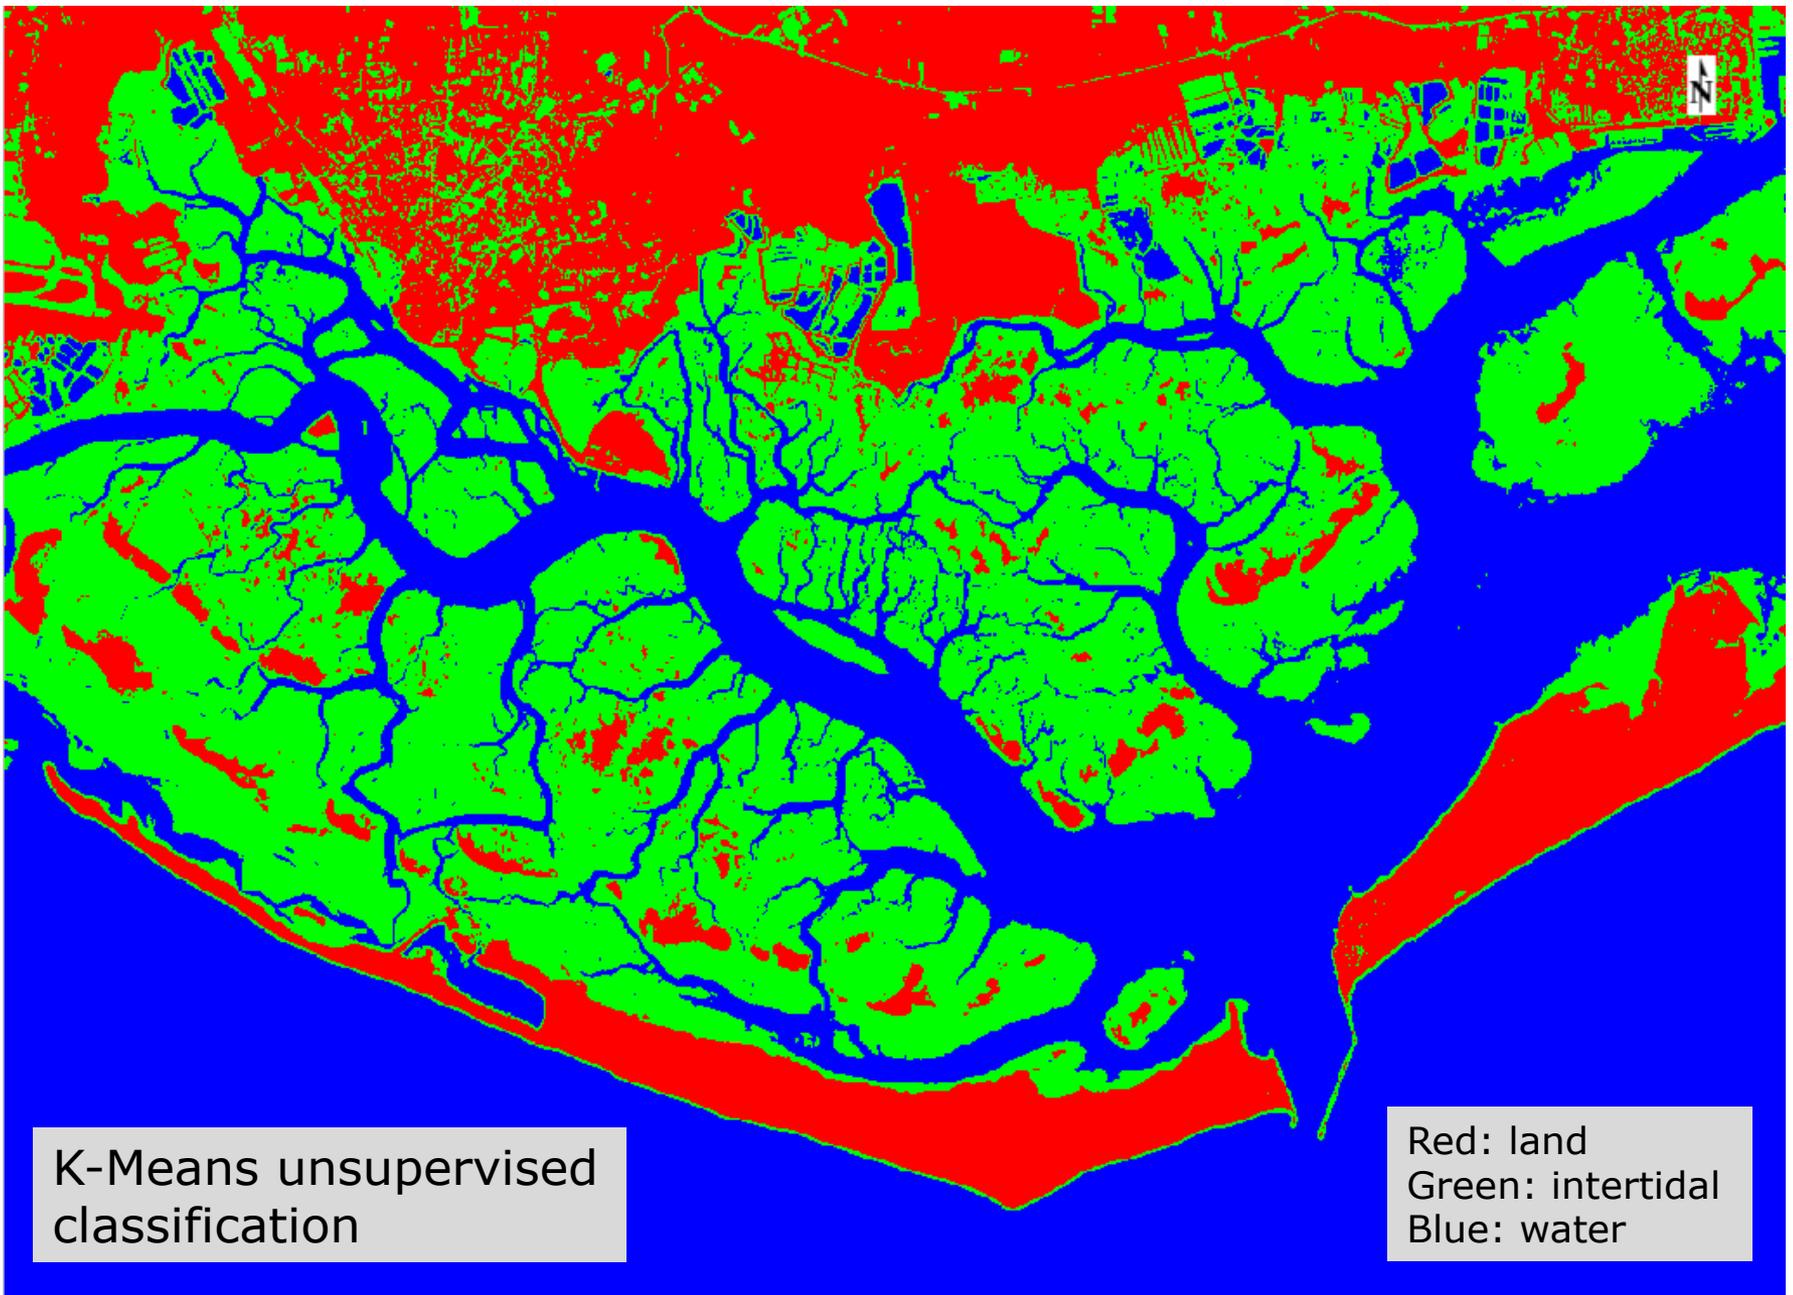
Banda 1 (media do NDWI) / banda 2 (Std do NDWI)



The 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

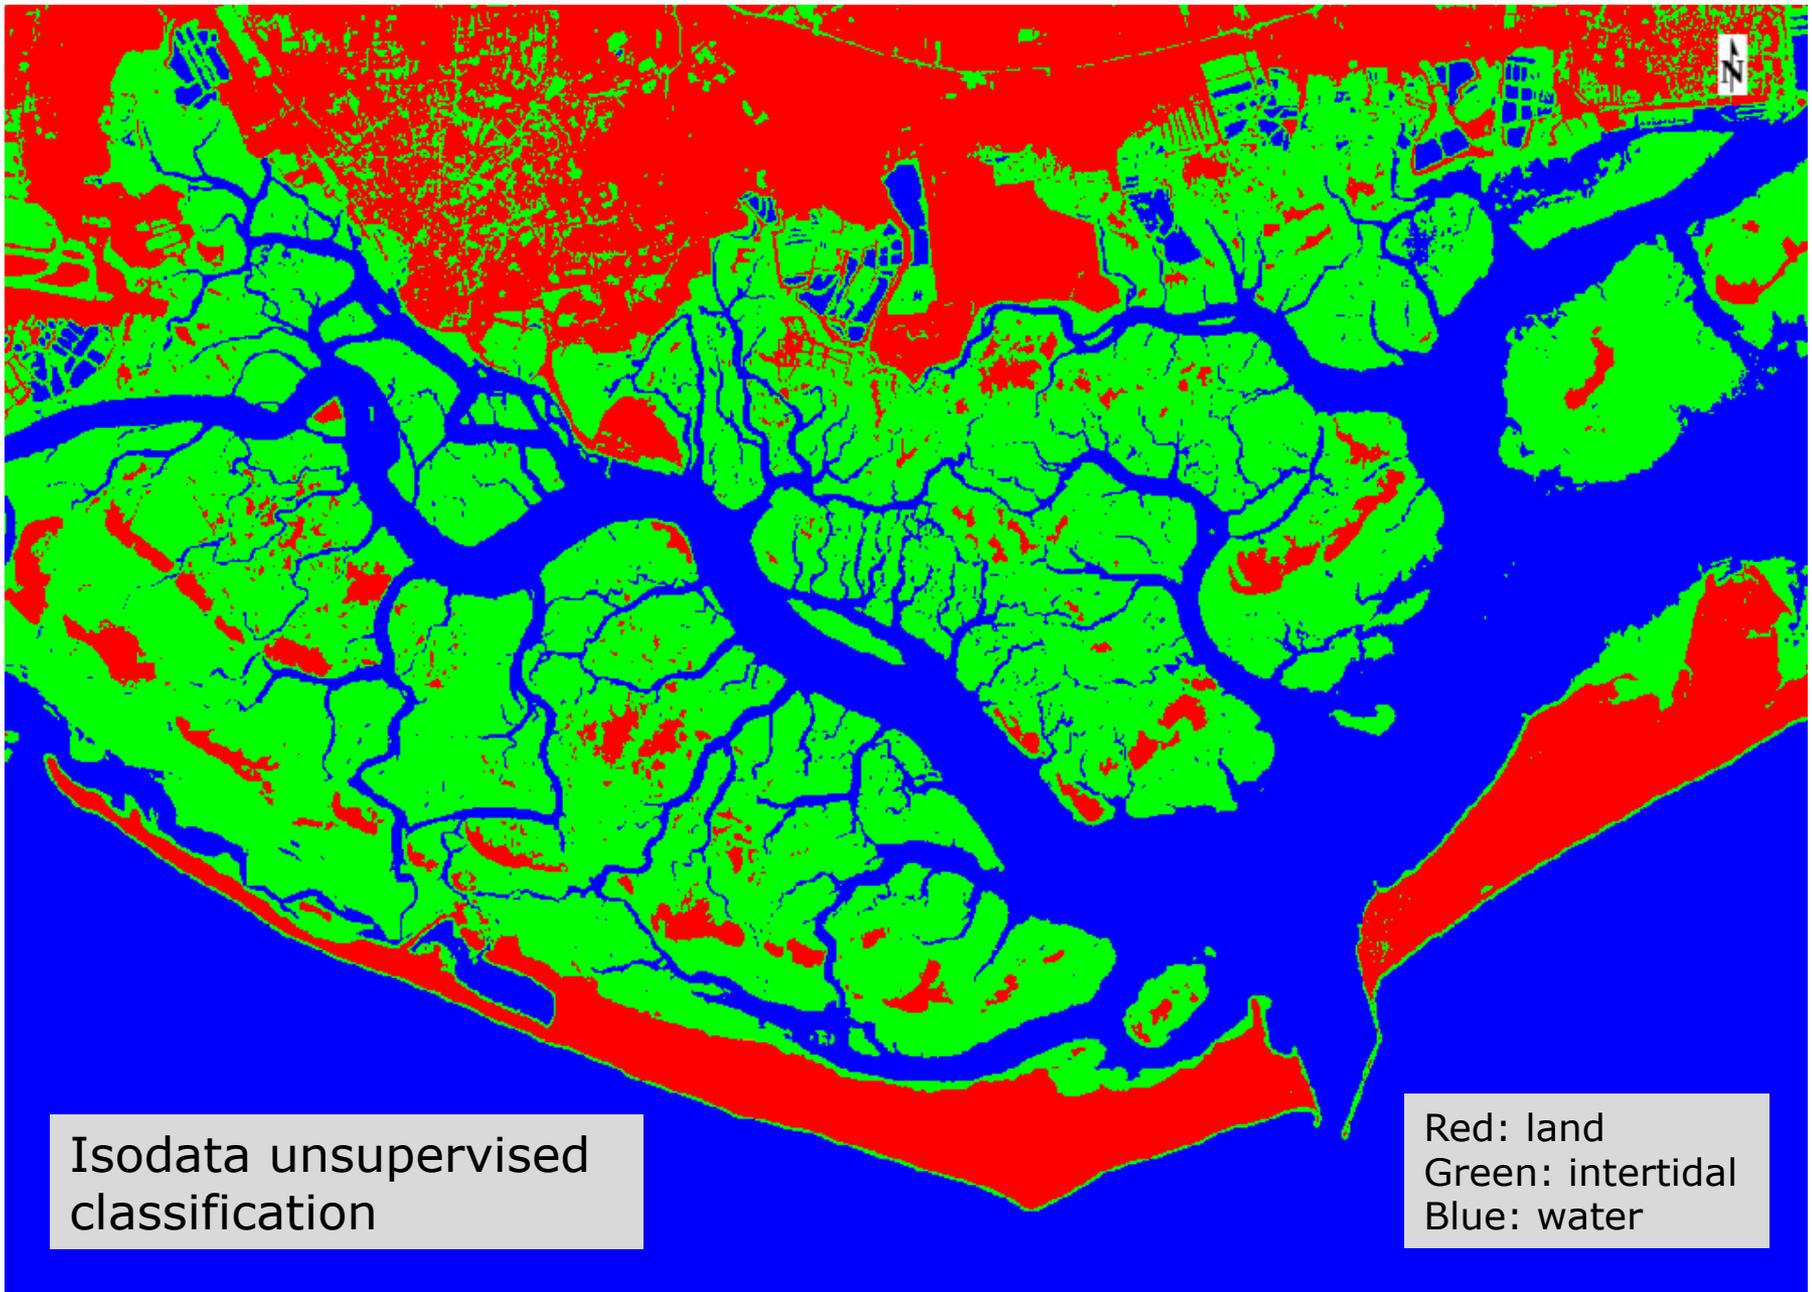
K-Means unsupervised classification



Unsupervised classification: ISODATA

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

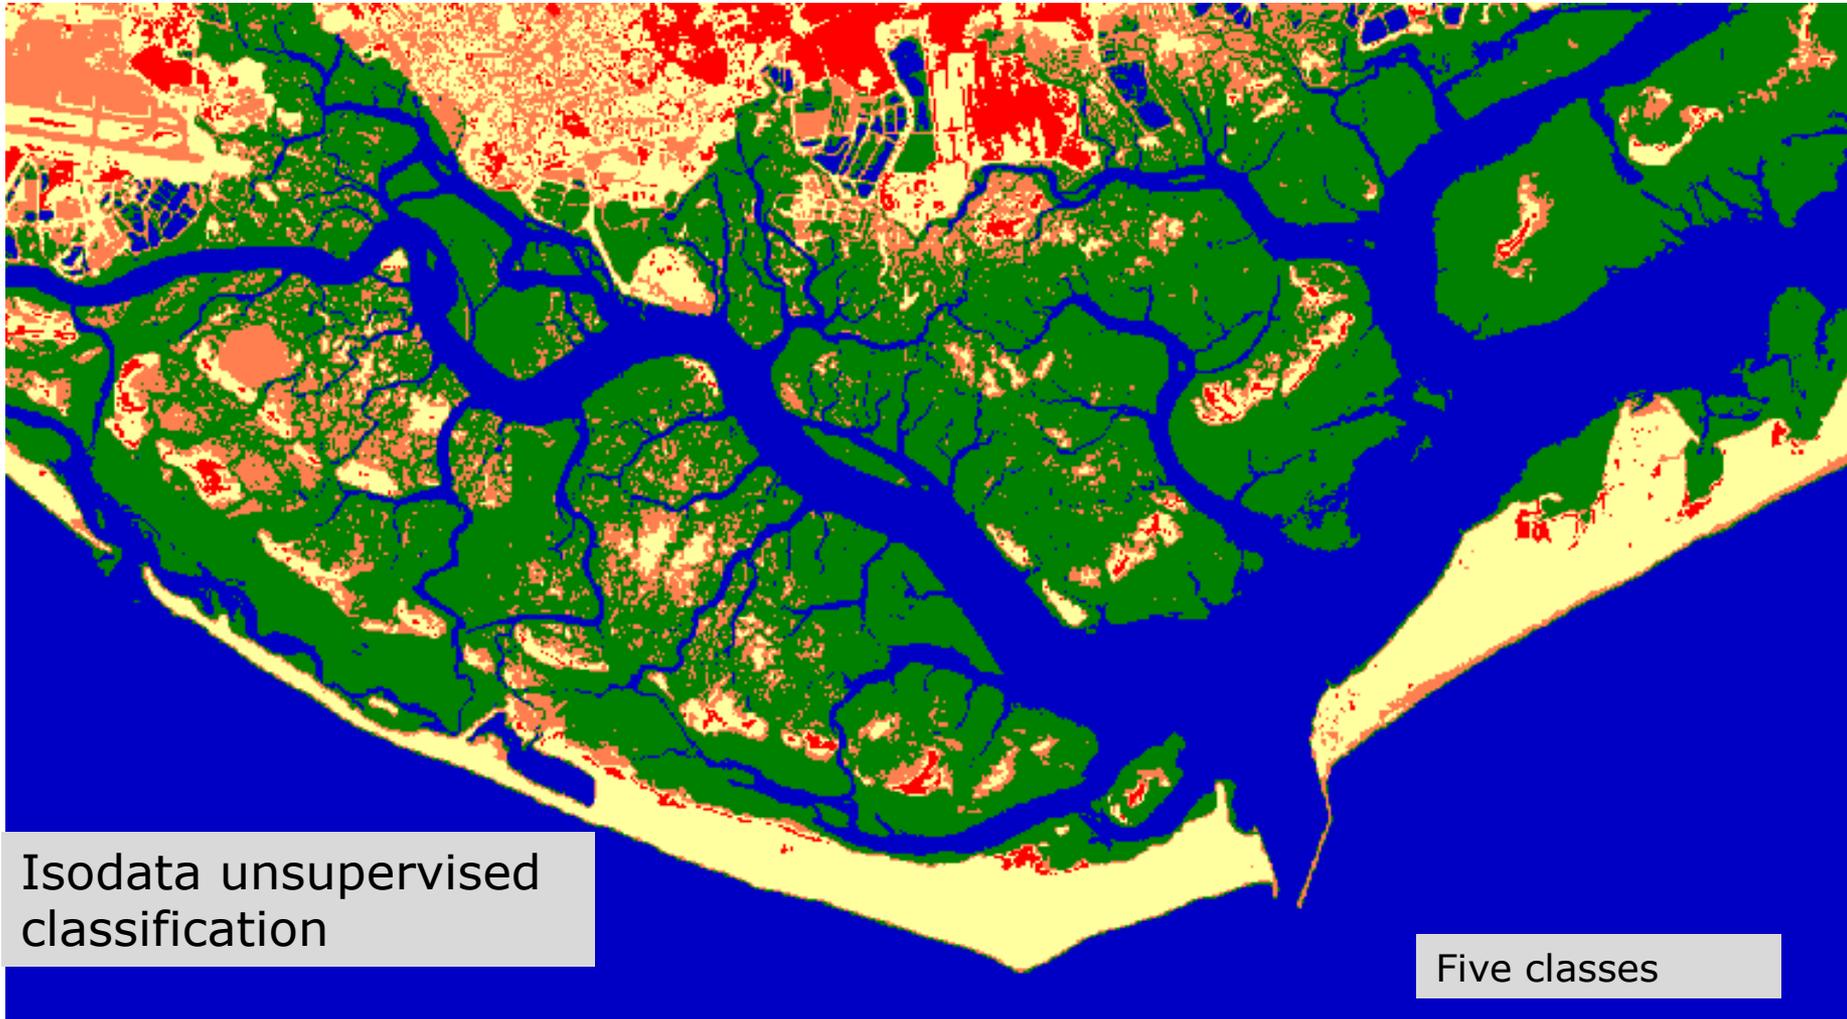
Idêntico ao anterior mas em que o número de clusters é automaticamente ajustado durante o processo iterativo por junção e/ou divisão de clusters com valores muito elevados do desvio padrão





Ciências
ULisboa

ISODATA unsupervised classification





Edição 2023

10.ª edição do CanSat Portugal
26 a 30 de abril, Ponte de Sor

Em 2023, completaremos 10 anos de CanSat Portugal. São 10 anos a ajudar os jovens do ensino secundário a viverem uma missão espacial real em pequena escala. 10 anos que esperamos que se repitam por muitos mais.

A 10ª Edição terá lugar no Aeródromo Municipal de Ponte de Sor de 26 a 30 de abril 2023.

Obrigado a todos os que nos ajudaram e ainda ajudam a tornar possível esta competição. Bem hajam!

[Sobre o CanSat Portugal](#) :: [Equipas Finalistas](#) :: [Resumo da missão](#) :: [Condições de participação](#) :: [Regulamento](#) :: [Inscrições](#) :: [Datas importantes](#) :: [Recursos](#) :: [Edições anteriores](#) :: [Workshop de Formação de Professores](#) :: [CanSat Internacional da ESA](#) :: [Imprensa e Fotos](#) :: [Organização](#)



Alguns dos melhores momentos do CanSat Portugal, entre 2015 e 2022. Vemos fotos de grupo e de equipas que ganharam a competição nacional e até a Europeia, organizada pela ESA.

[Sobre o CanSat Portugal](#)



um satélite neste volume reduzido, nomeadamente a sua antena (emissora), bateria e sensores.

Objetivos da competição

As equipas participantes devem projetar um CanSat que seja capaz de sobreviver a um lançamento, que pode ser feito de várias formas:

Através de um avião, drone, balão ou mesmo a partir de um pequeno foguetão, que pode chegar a uma altitude de 1 km. Após o lançamento, durante a descida, o CanSat deve executar uma missão científica, comunicar os dados a um computador no solo e aterrar de forma segura. A missão inclui a análise dos dados recolhidos.

Com esta competição, os estudantes têm a oportunidade de passar por todos os estágios de um projeto especial real de pequena escala, ao longo de um ano letivo. Por outras palavras, terão de escolher os objetivos da sua missão, projetar o seu CanSat, integrar todos os seus componentes, testar o sistema, preparar para o lançamento e analisar os dados científicos obtidos.

No final, o trabalho das equipas será avaliado em duas grandes vertentes: em termos relativos, pela forma como desempenham uma missão comum atribuída a todos os participantes; e em termos individuais, pela criatividade e valor científico de uma missão científica extra escolhida pela própria equipa.

O ESERO Portugal organiza esta competição a nível nacional desde 2014. Serão selecionadas 15 equipas para a prova final. A equipa vencedora fica qualificada para competir no CanSat Internacional, organizado pela ESA.



Foto-montagem de grupo da final CanSat Portugal 2017, que decorreu em Santa Maria, nos Açores.

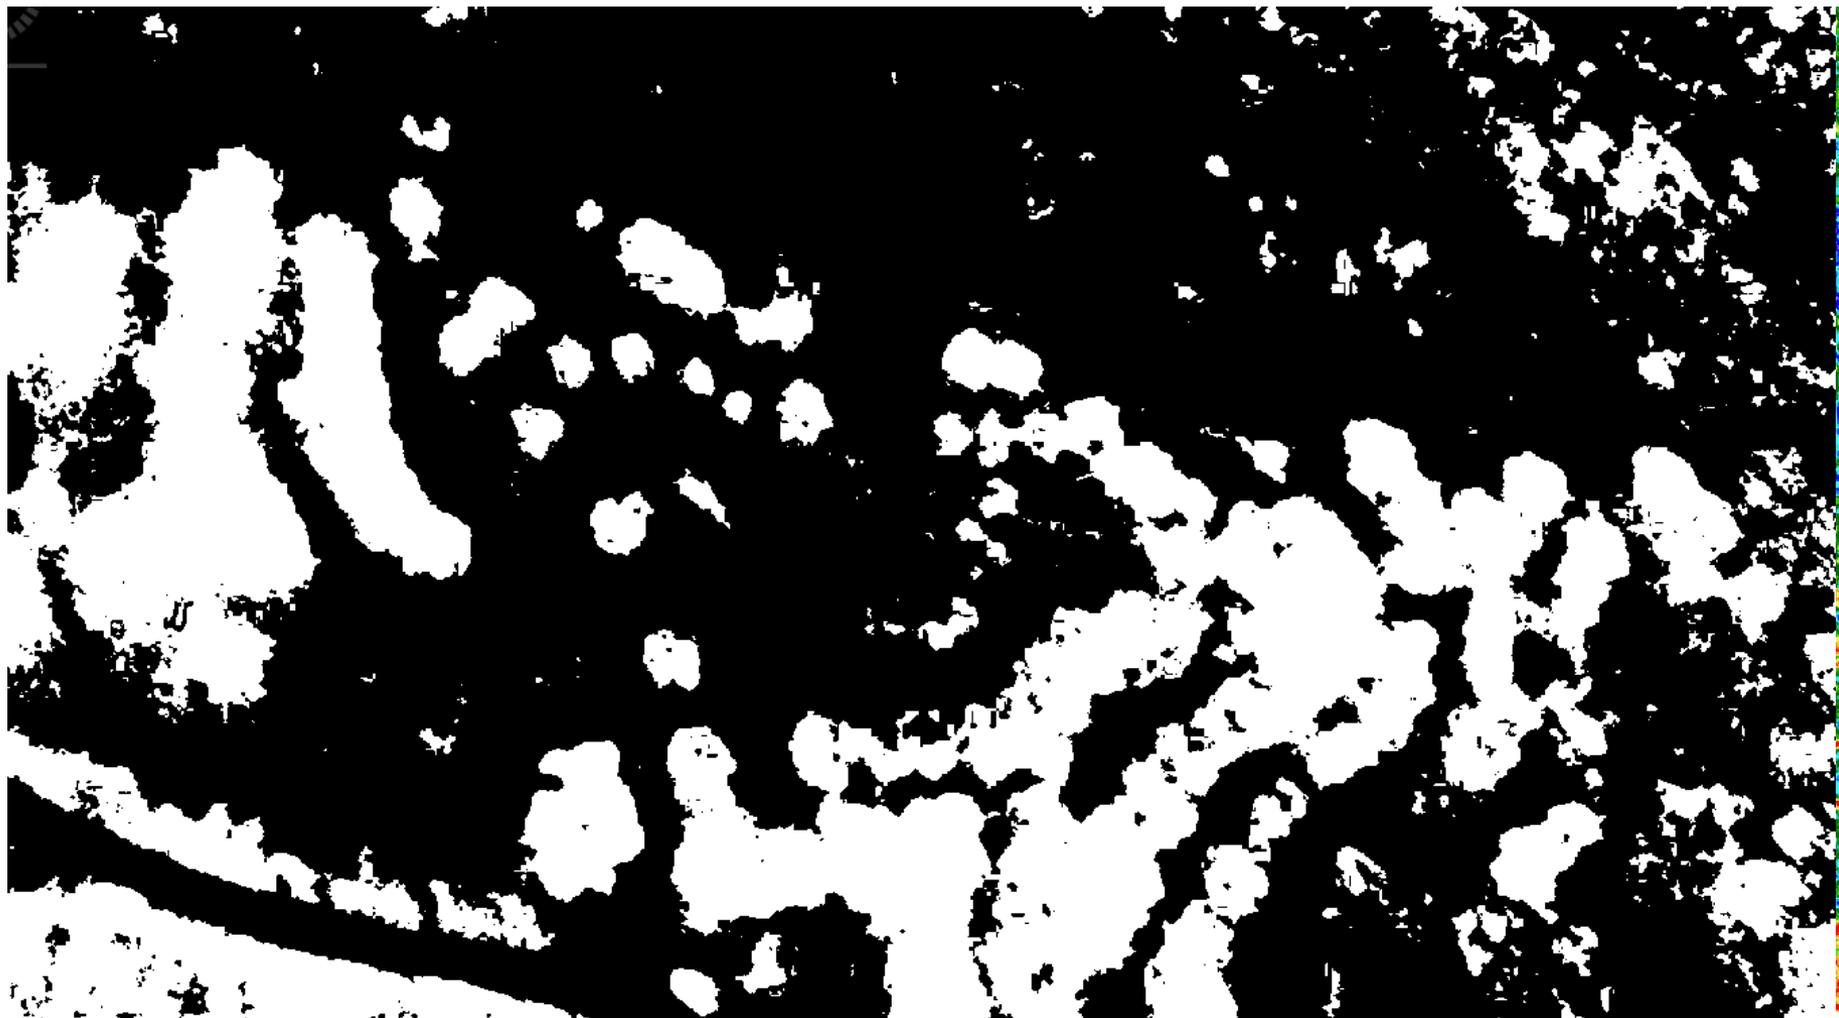


Ciências
ULisboa



Video cansat.h264





Passos na classificação supervisionada

1. Escolher a legenda

Spectral Classes

Escolher os tipos de ocupação do 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 píxeis representativos de cada classe legenda

Sample data
Training data set

Estes píxeis 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 (espectral)** dessa classe.

4. Classificar

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

5. Calcular a exatidão e a tabela de confusão

(Confusion table)

Calcular a exatidão da classificação e produzir a tabela de confusão que resume os resultados da classificação.

Bayes Classification

Representemos as classes espectrais de uma imagem por:

w_i , $i=1,\dots,M$, M número de classes

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

$\mathbf{x} = (x_1, x_2, \dots, x_N)$ Posição no espaço multiespectral

Em que x_1, x_2, \dots, x_N é a reflectância do píxel \mathbf{x} nas bandas 1 a N

Classificação de Bayes

A determinação da classe à qual um píxel na posição \mathbf{x} pertence pode ser visto como 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 píxeis de uma imagem pertencem à classe espectral w_i então $p(w_i) = 0.2$.

$p(\mathbf{x})$ é a probabilidade de um píxel ter uma determinada assinatura espectral \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:

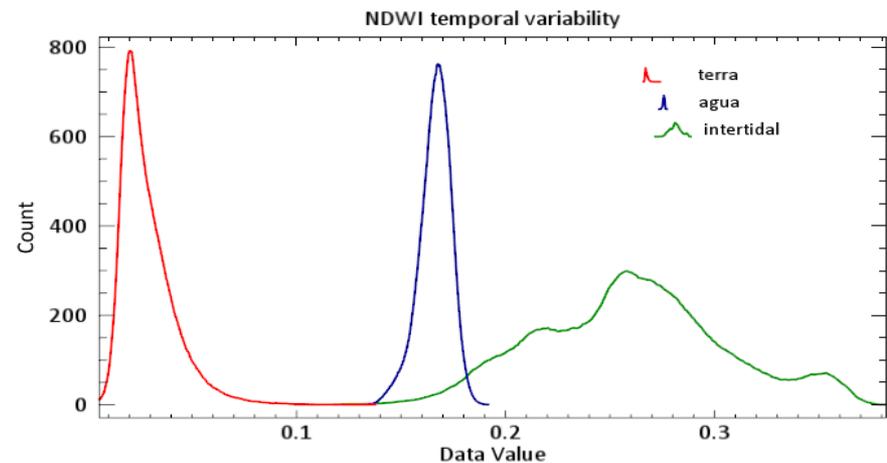
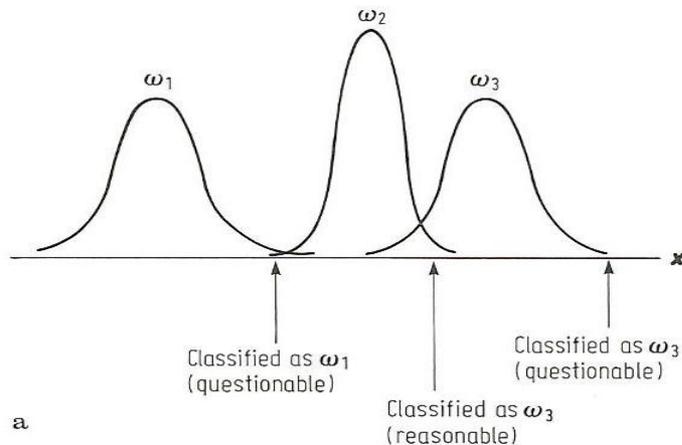
$$g_i(x) = \ln p(w_i) - \frac{1}{2} \ln \left| \Sigma_i \right| - \frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i)$$

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 píxeis 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:

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

Ou, equivalentemente:

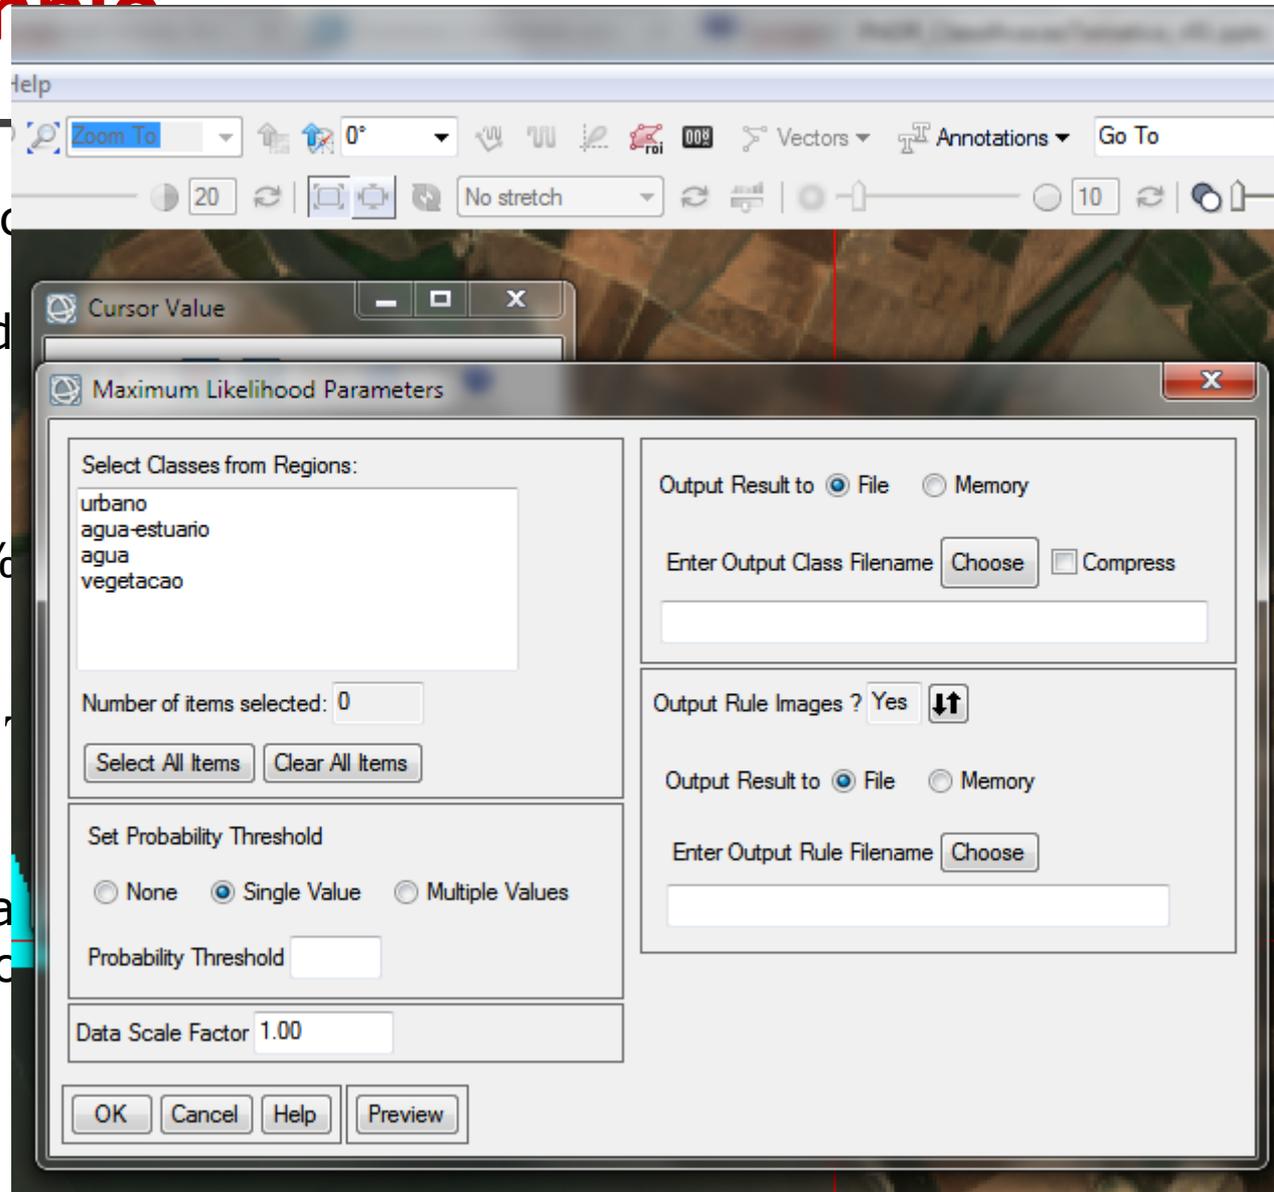
$$\sim \chi^2 \quad \left((x - m_i)^t \Sigma_i^{-1} (x - m_i) \right) < -2T_i + 2 \ln p(w_i) - \ln \left| \Sigma_i \right|$$

Exemplo

Como exemplo de tal que 95% de ou seja, de modo rejeitados.

Da tabela do χ^2 liberdade a 95%

Que pode ser ca e da distribuição



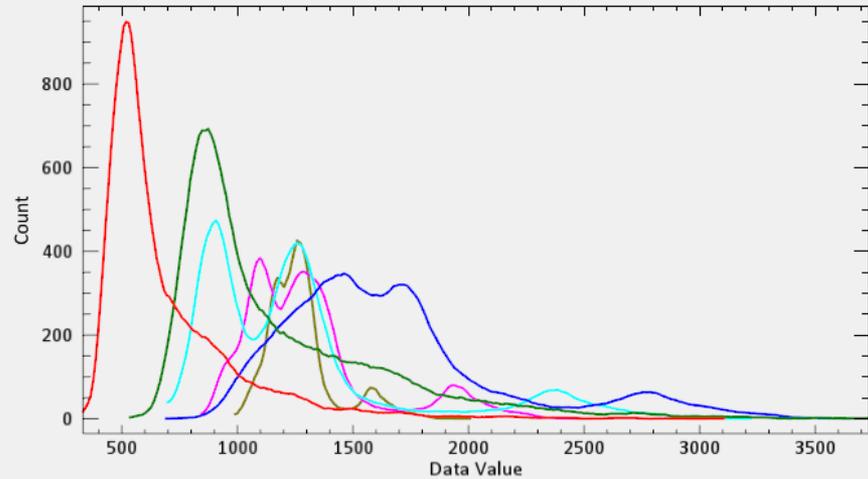
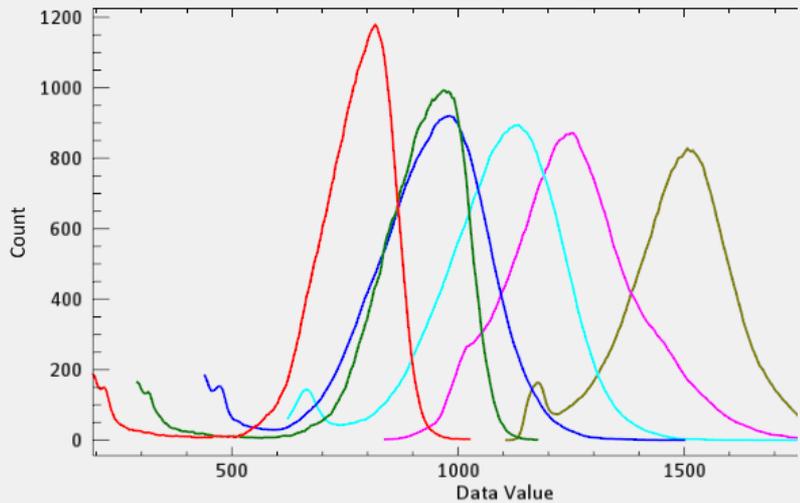


Ciências
ULisboa

Maximum Likelihood Classification



Histograms: xx.img



X: Data Value Y: Data Value

Locate Stat Report Precision

Locate Stat Report Precision

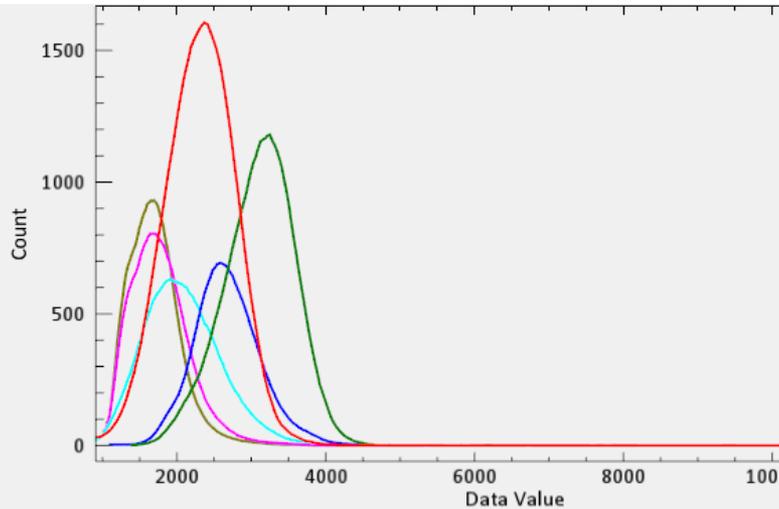
agua (aa)					
Basic Stats	Min	Max	Mean	StdDev	
Band 1	193	1027	749.51	135.02	
Band 2	291	1177	895.94	147.54	
Band 3	440	1501	927.05	148.40	
Band 4	624	1753	1087.74	145.36	
Band 5	839	1925	1258.07	143.22	
Band 6	1107	2018	1489.62	127.55	
Histogram	DN	Count	Total	Percent	Acc Pct
Band 1	193 - 196	30	30	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

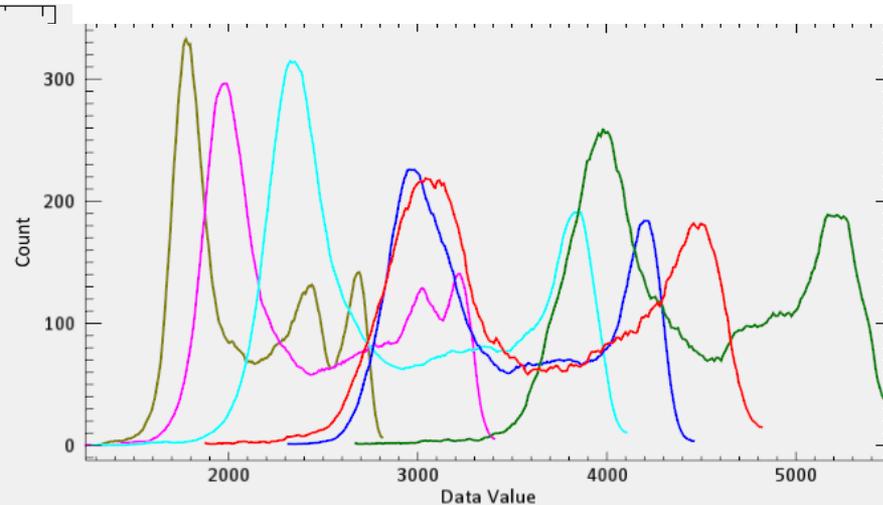
- Histogram: Band 1
- Histogram: Band 2
- Histogram: Band 3
- Histogram: Band 4
- Histogram: Band 5
- Histogram: Band 6



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)

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



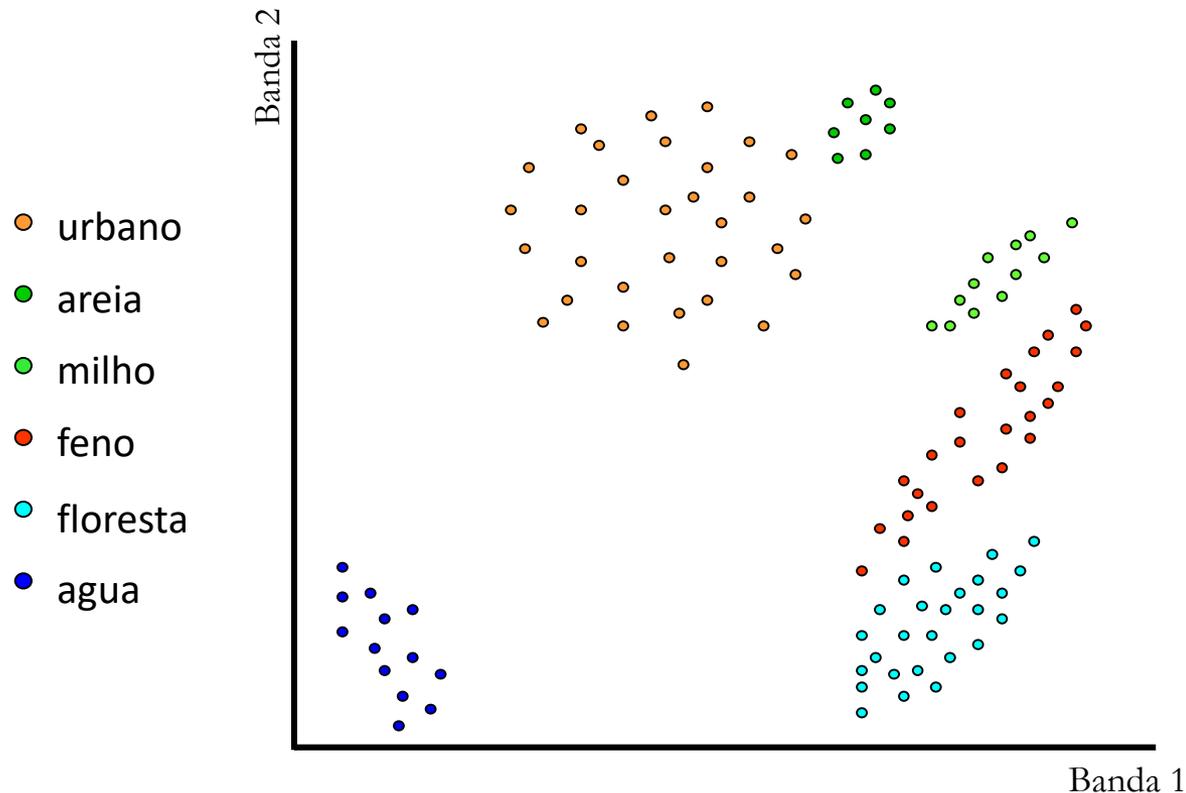
Maximum Likelihood Classification



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

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.

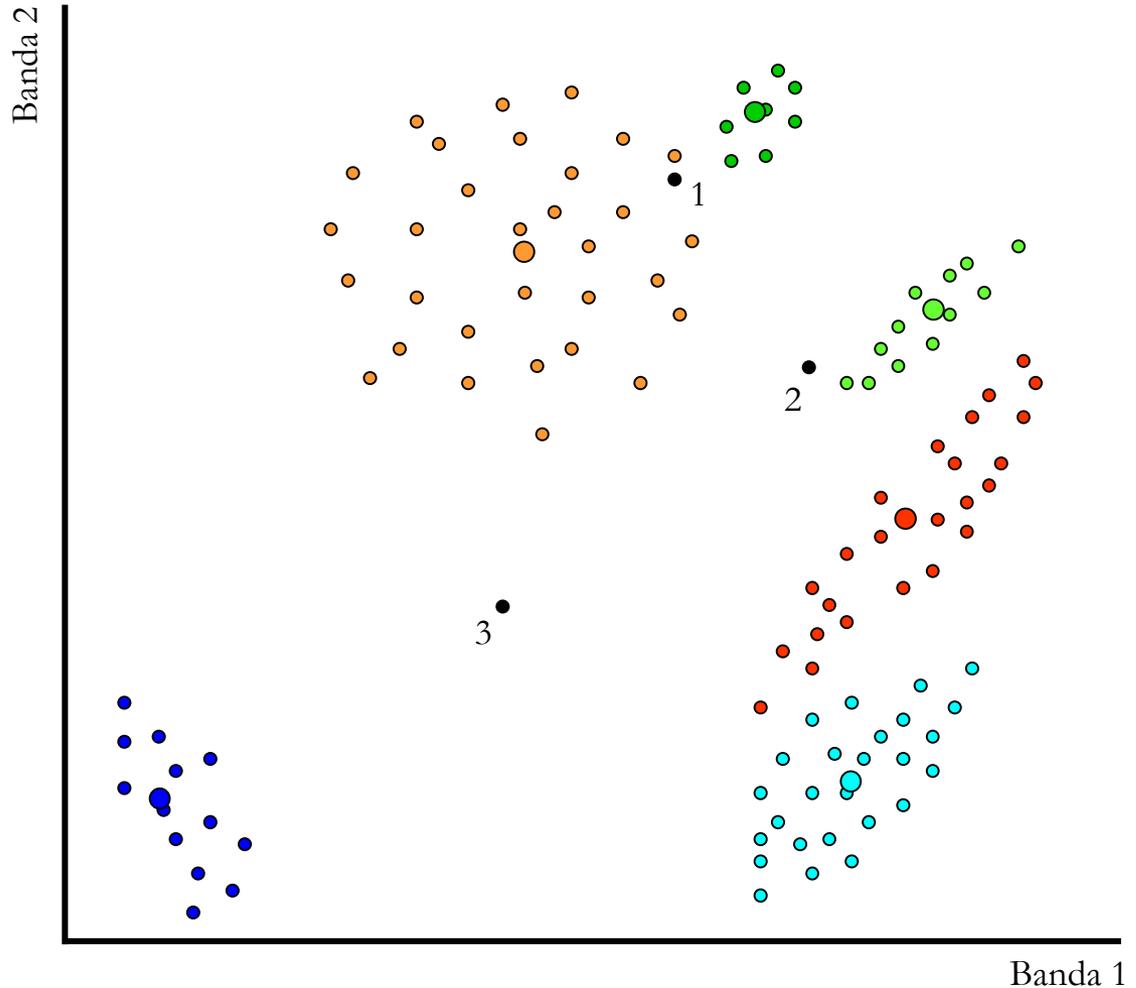


Exemplo

Pretendem-se
classificar os píxeis
1,2,3

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

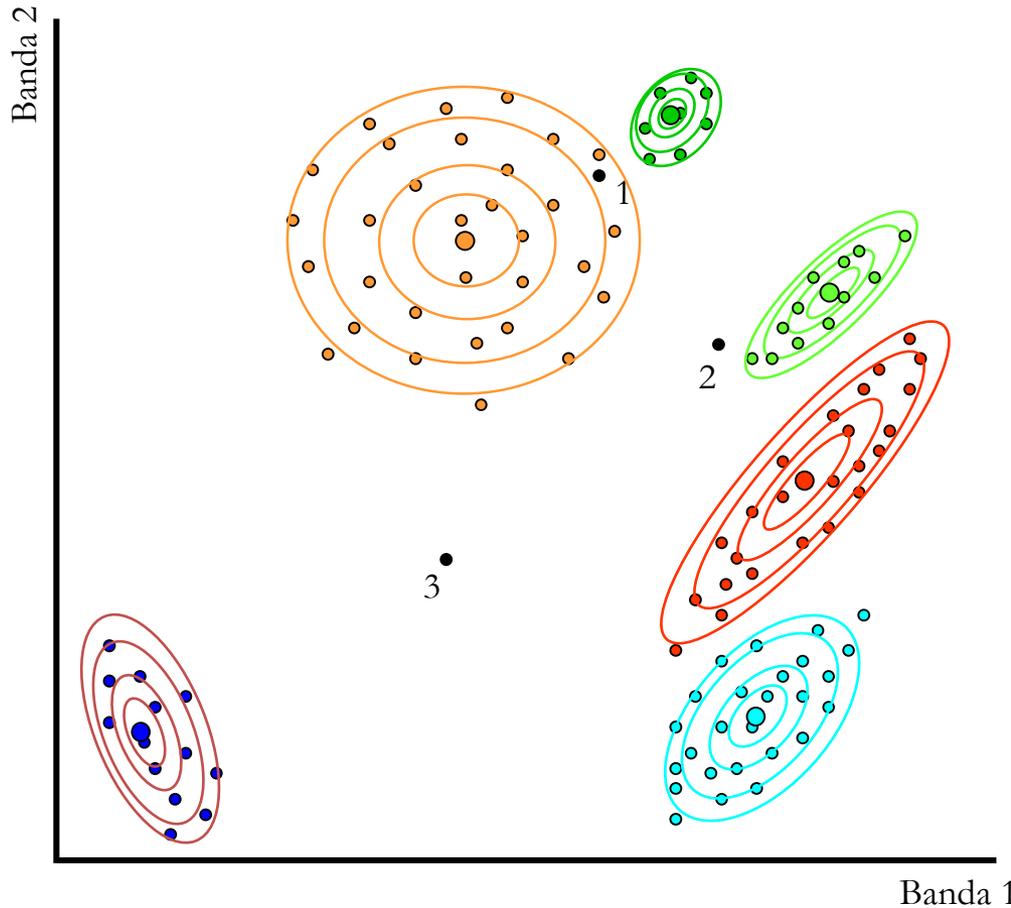
São representados os valores médios de cada classe (círculos maiores).





Maximum Likelihood

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



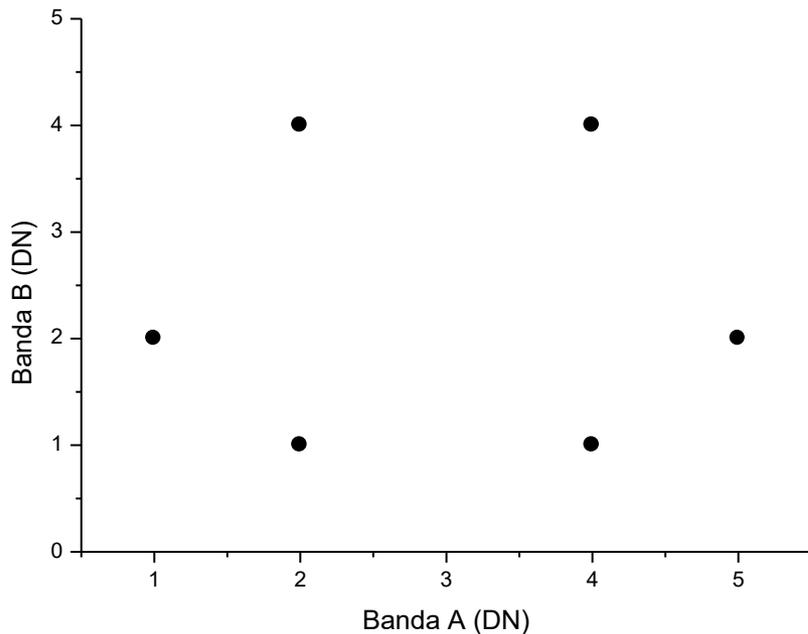
Classificação

- 1: urbano
- 2: não classificado
- 3: não classificado

Exemplo

Determine o vetor da média, a função covariância e correlação

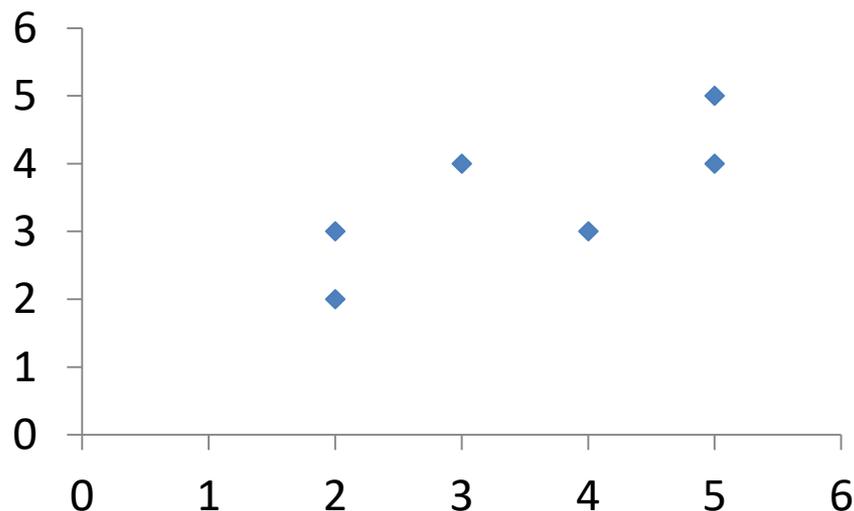
Conjunto de píxeis de uma classe



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 píxeis:

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 número 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.

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

Calculamos o conjunto de distâncias euclidianas:

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

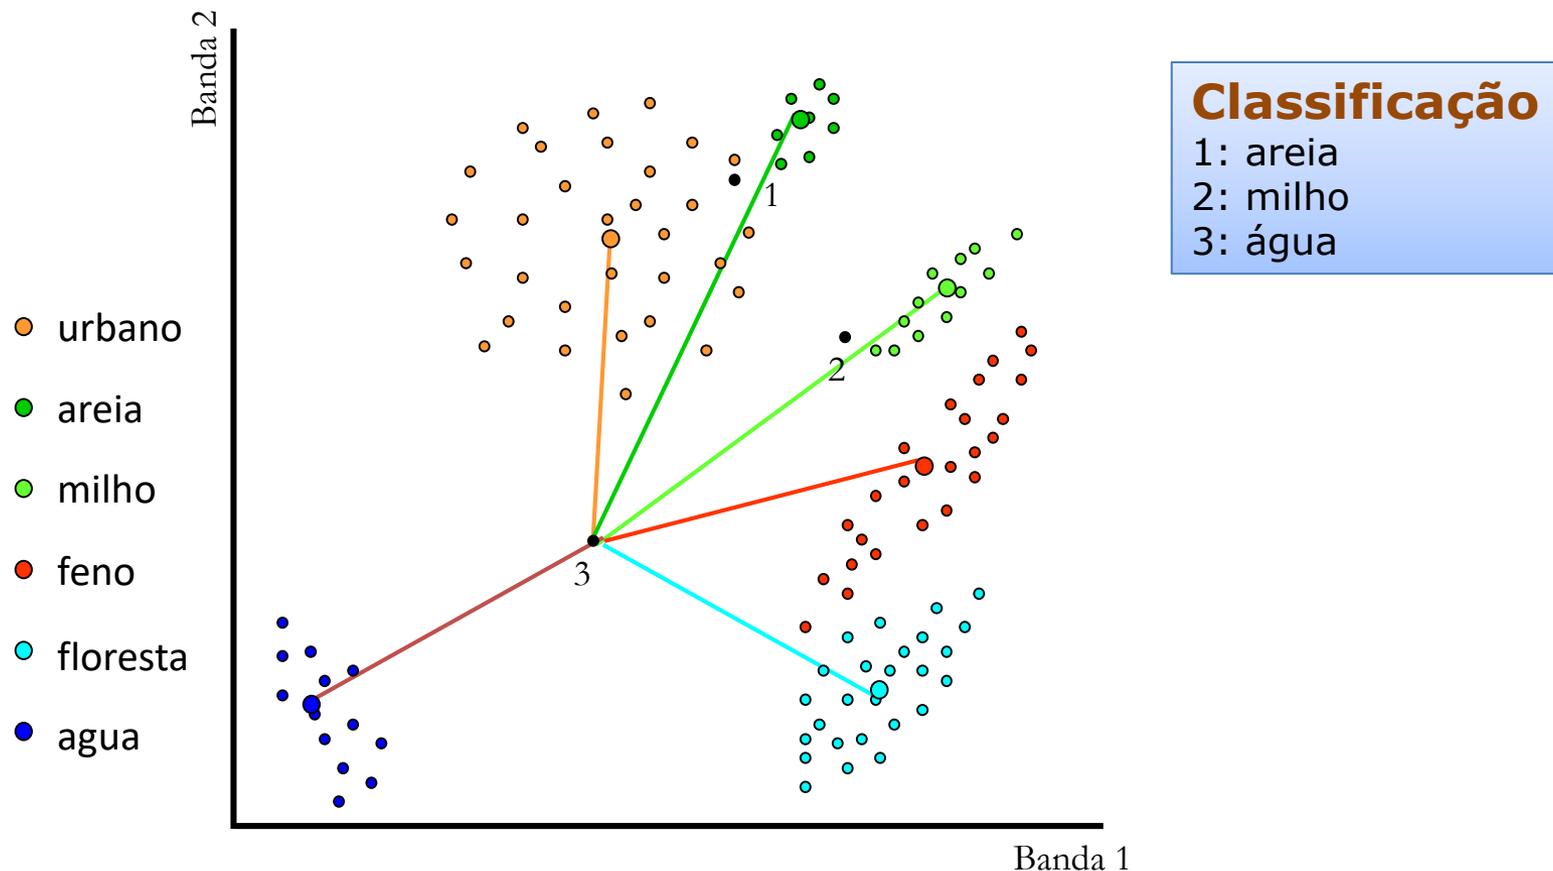
Expandindo o produto dá:

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

A classificação é realizada na base de que:

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

Classificador Distância Mínima

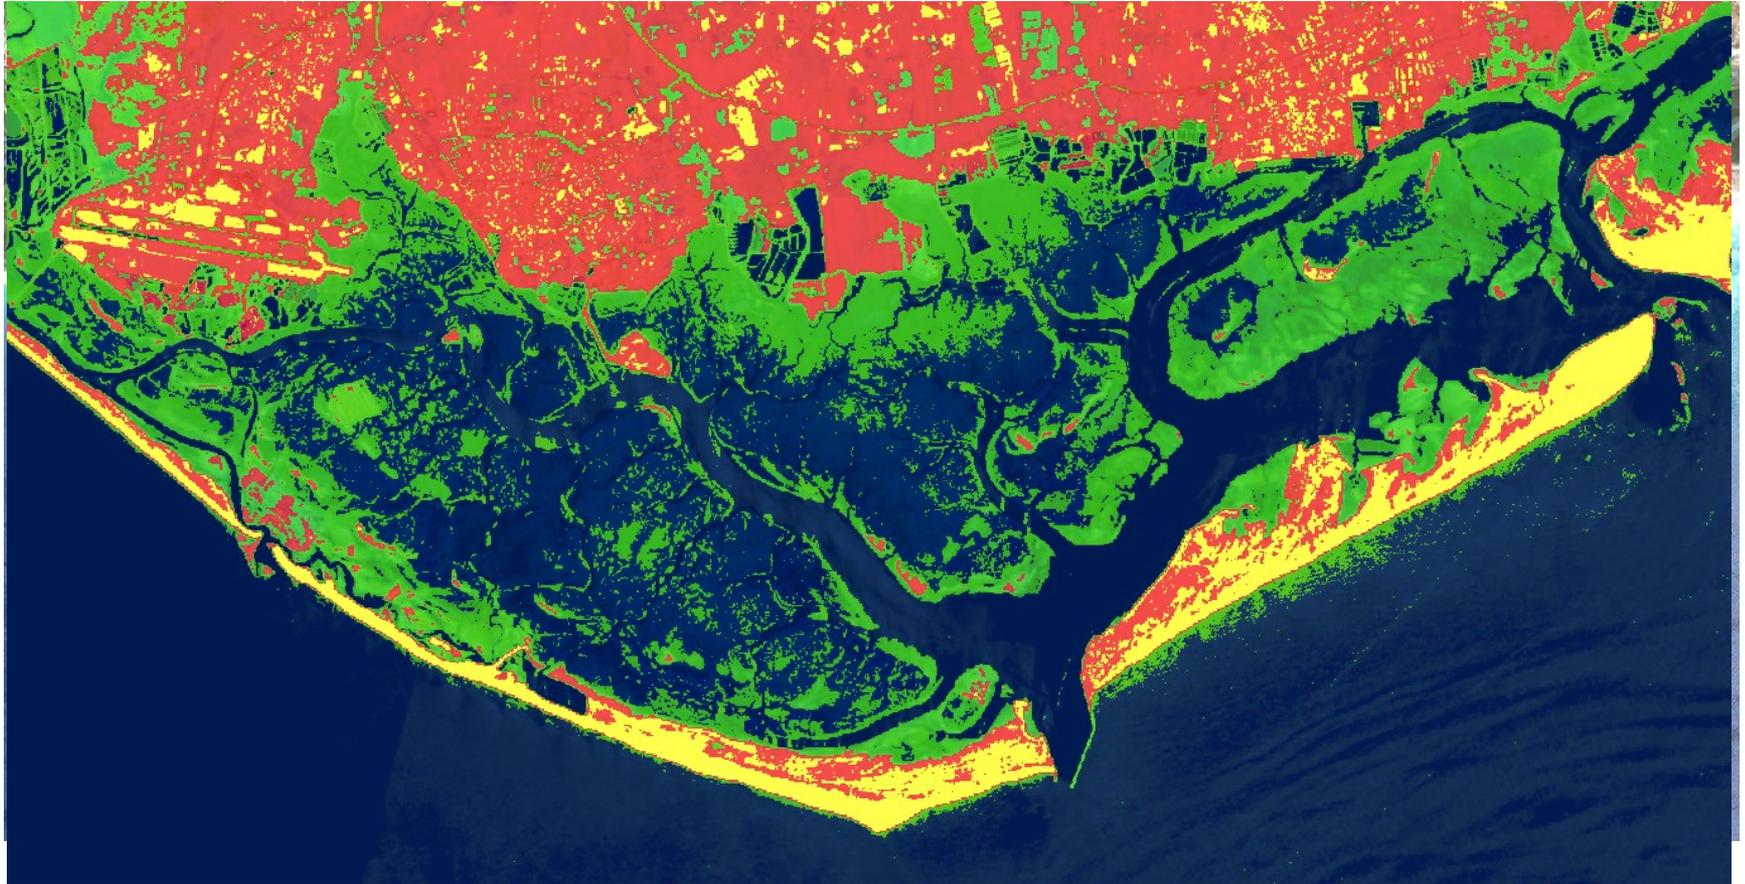


Desvantagem: a associação dum pixel ao padrão mais perto poderia introduzir efeitos desagradáveis como por exemplo associar um pixel ao padrão mais perto mas que é bastante “afastado” e portanto com um valor radiométrico (DN) bastante diferente.



Ciências
ULisboa

Minimum Distance

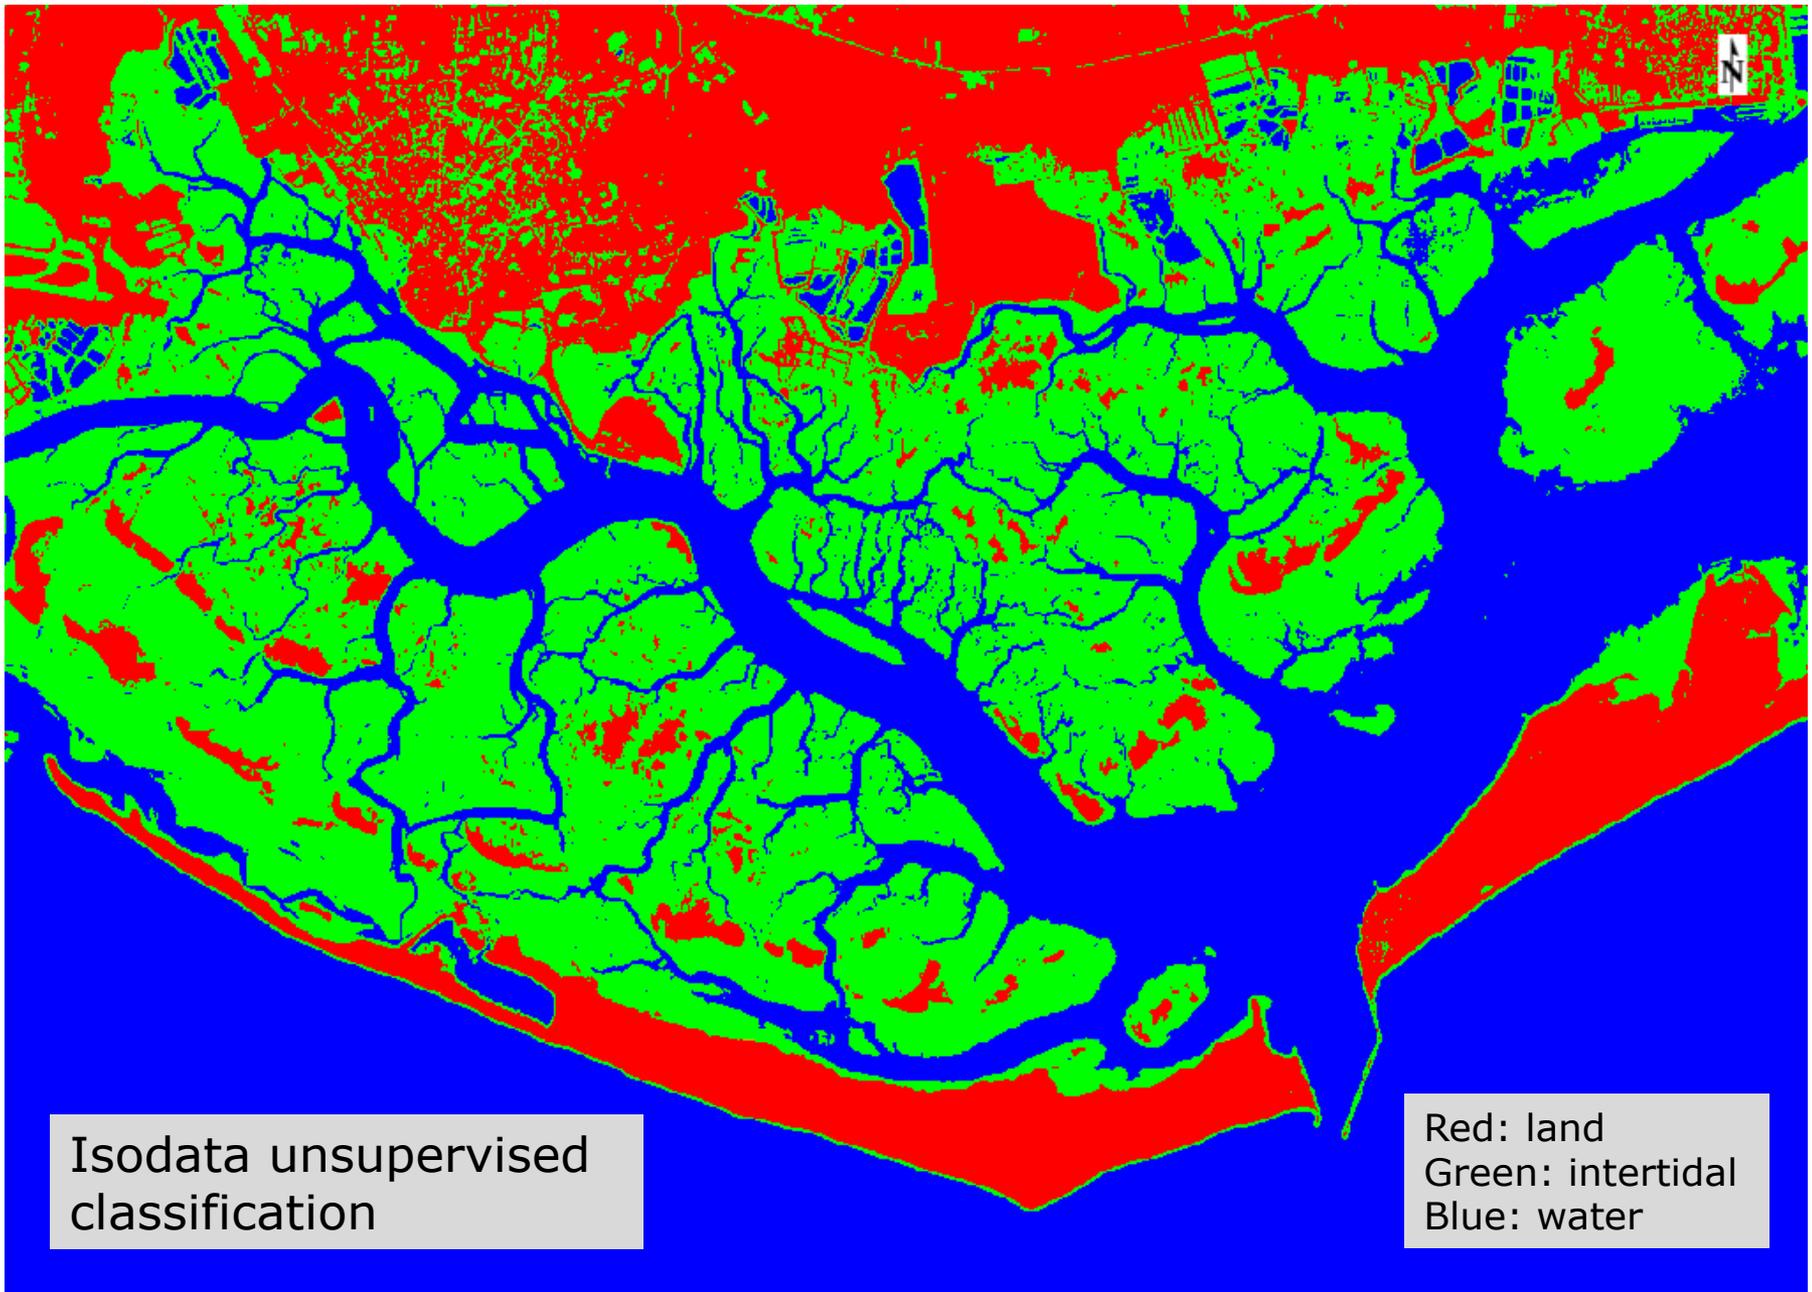




Maximum Likelihood Classification



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



Mahalanobis Classifier

Consideremos a função discriminante para o classificador da máxima verosimilhança. Se revertermos o sinal desta função pode ser considerado como a distância ao quadrado uma vez que o produto tem essa dimensão e o primeiro termo é constante. Podemos definir:

$$d(x, m_i)^2 = \ln \left| \sum_i \right| + (x - m_i)^t \sum_i^{-1} (x - m_i)$$

E classificar com base na mesma distância como para classificador da distância Euclidiana mínima.

O classificador de máxima verosimilhança pode ser visto como um classificador de distância mínima, mas a distância é sensível à direcção e modificada de acordo com a classe.

Mahalanobis Classifier

Consideremos agora o caso em que a matriz covariância é igual para todas as classes. O termo $\ln \Sigma_i$ deixa de ser discriminante e podemos eliminá-lo. A distância fica reduzida a:

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

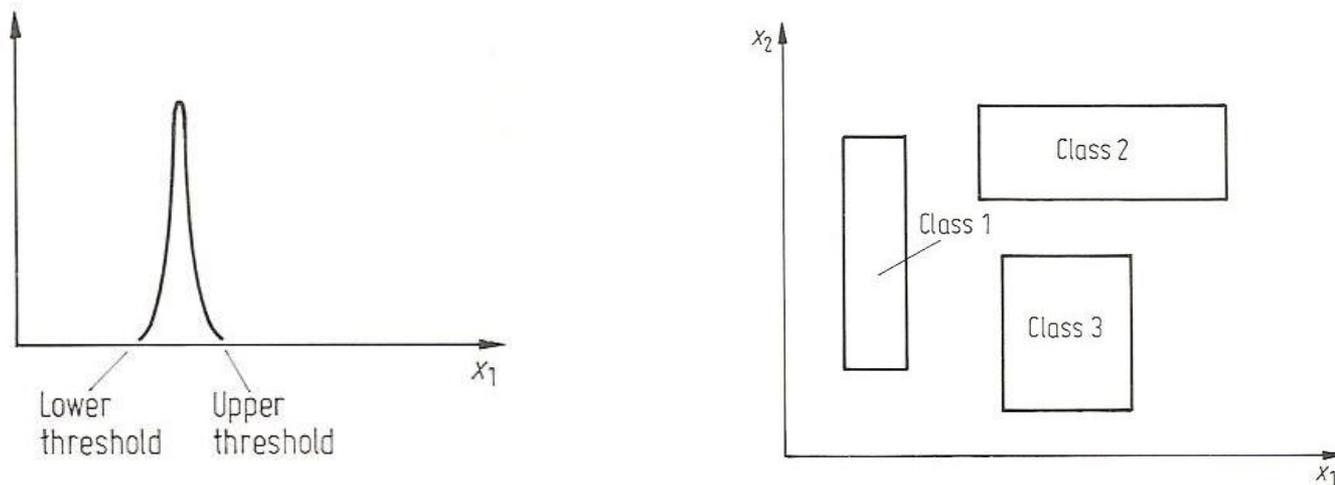
Este é o classificador **distância Mahalanobis**. (raiz quadrada da equação anterior)

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.

Classificador Paralelepípedo

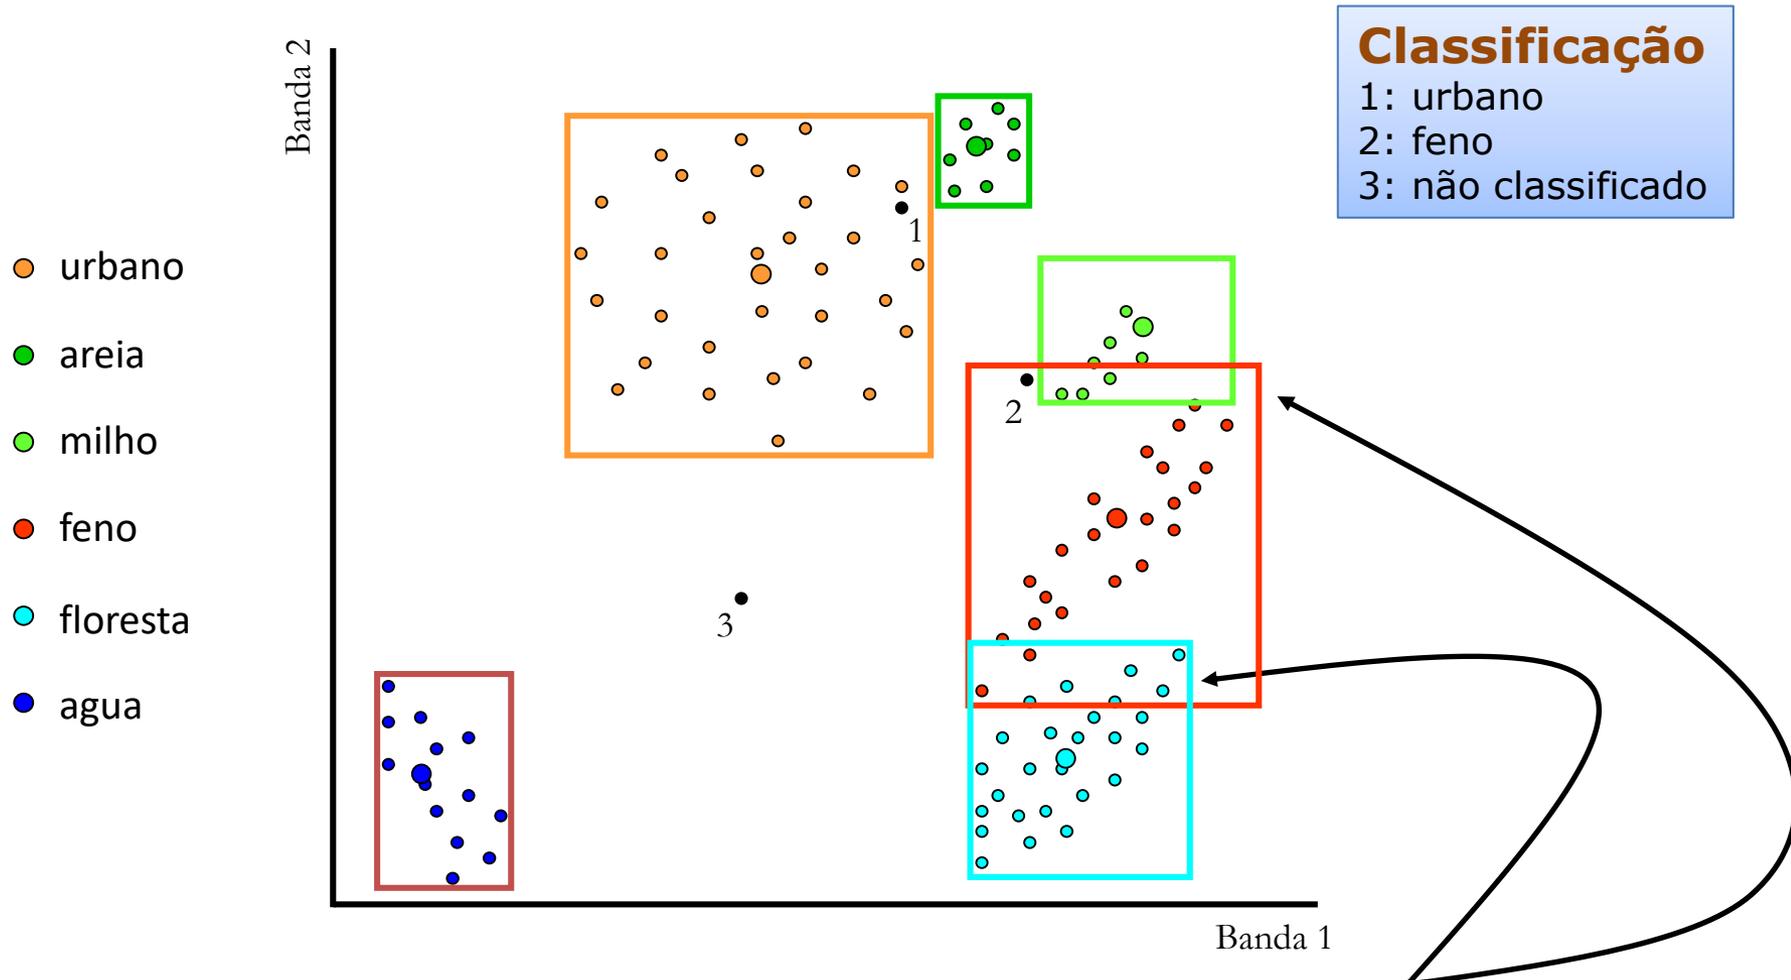
O classificador do paralelepípedo é treinado por análise dos histogramas de componentes espectrais com base nos dados treino



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.

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:

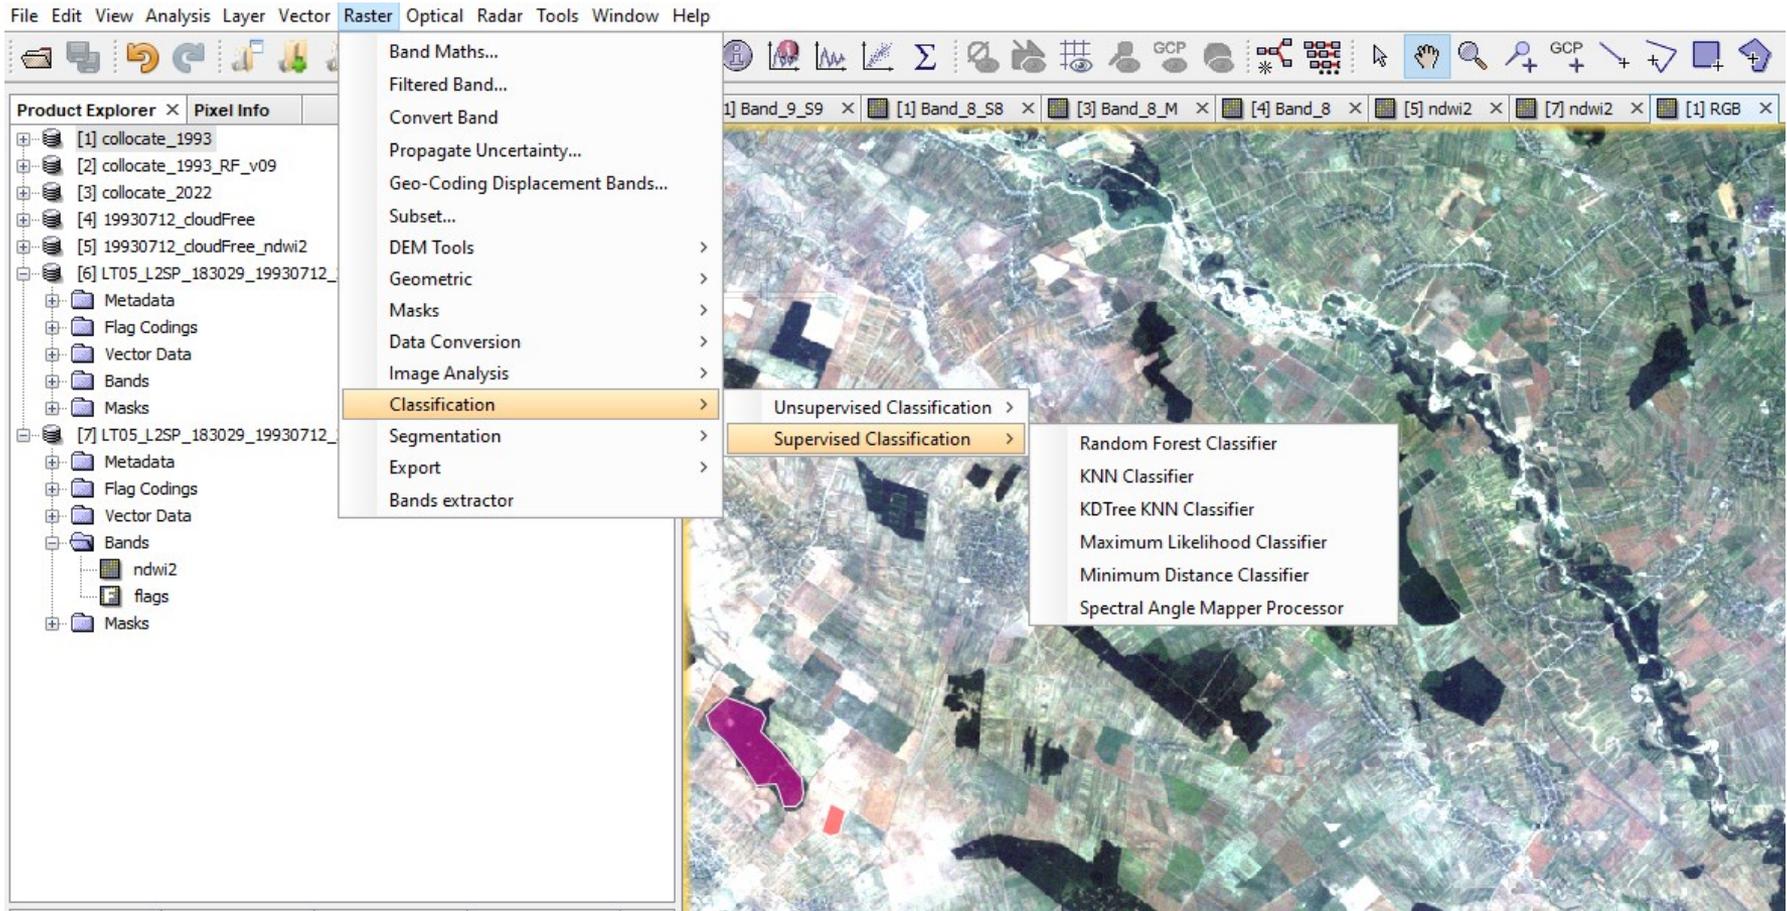
P1 (5,9)

P2 (9,8)

P3(15, 9)

P4 (3,7)

Algoritmos de Classificação do SNAP



The screenshot displays the SNAP (Sentinel Application Platform) software interface. The main window shows a satellite image of a rural landscape with a purple polygon highlighting a specific area. The 'Raster' menu is open, showing various processing options. The 'Classification' option is selected, and a sub-menu is displayed, listing several supervised classification algorithms.

File Edit View Analysis Layer Vector **Raster** Optical Radar Tools Window Help

Product Explorer × Pixel Info

- [1] collocate_1993
- [2] collocate_1993_RF_v09
- [3] collocate_2022
- [4] 19930712_cloudFree
- [5] 19930712_cloudFree_ndwi2
- [6] LT05_L2SP_183029_19930712_...
 - Metadata
 - Flag Codings
 - Vector Data
 - Bands
 - Masks
- [7] LT05_L2SP_183029_19930712_...
 - Metadata
 - Flag Codings
 - Vector Data
 - Bands
 - ndwi2
 - flags
 - Masks

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

1] Band_9_S9 × [1] Band_8_S8 × [3] Band_8_M × [4] Band_8 × [5] ndwi2 × [7] ndwi2 × [1] RGB ×

Unsupervised Classification >
Supervised Classification >
Random Forest Classifier
KNN Classifier
KDTree KNN Classifier
Maximum Likelihood Classifier
Minimum Distance Classifier
Spectral Angle Mapper Processor



Classification accuracy assessment

A avaliação baseia-se na tabela de contingências que compara, numa amostra de píxeis, 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

Píxeis 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

Píxeis 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

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

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

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

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

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 píxeis que foram correctamente classificados

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

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



Classification accuracy assessment

A percentagem de píxeis 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

Exatidão Global (Overall Accuracy)

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

$$N = 4$$

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

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

$$EG = 672 / 951 = 0.706$$

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 píxeis 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 (píxeis identificados como floresta) foi classificada como floresta.

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

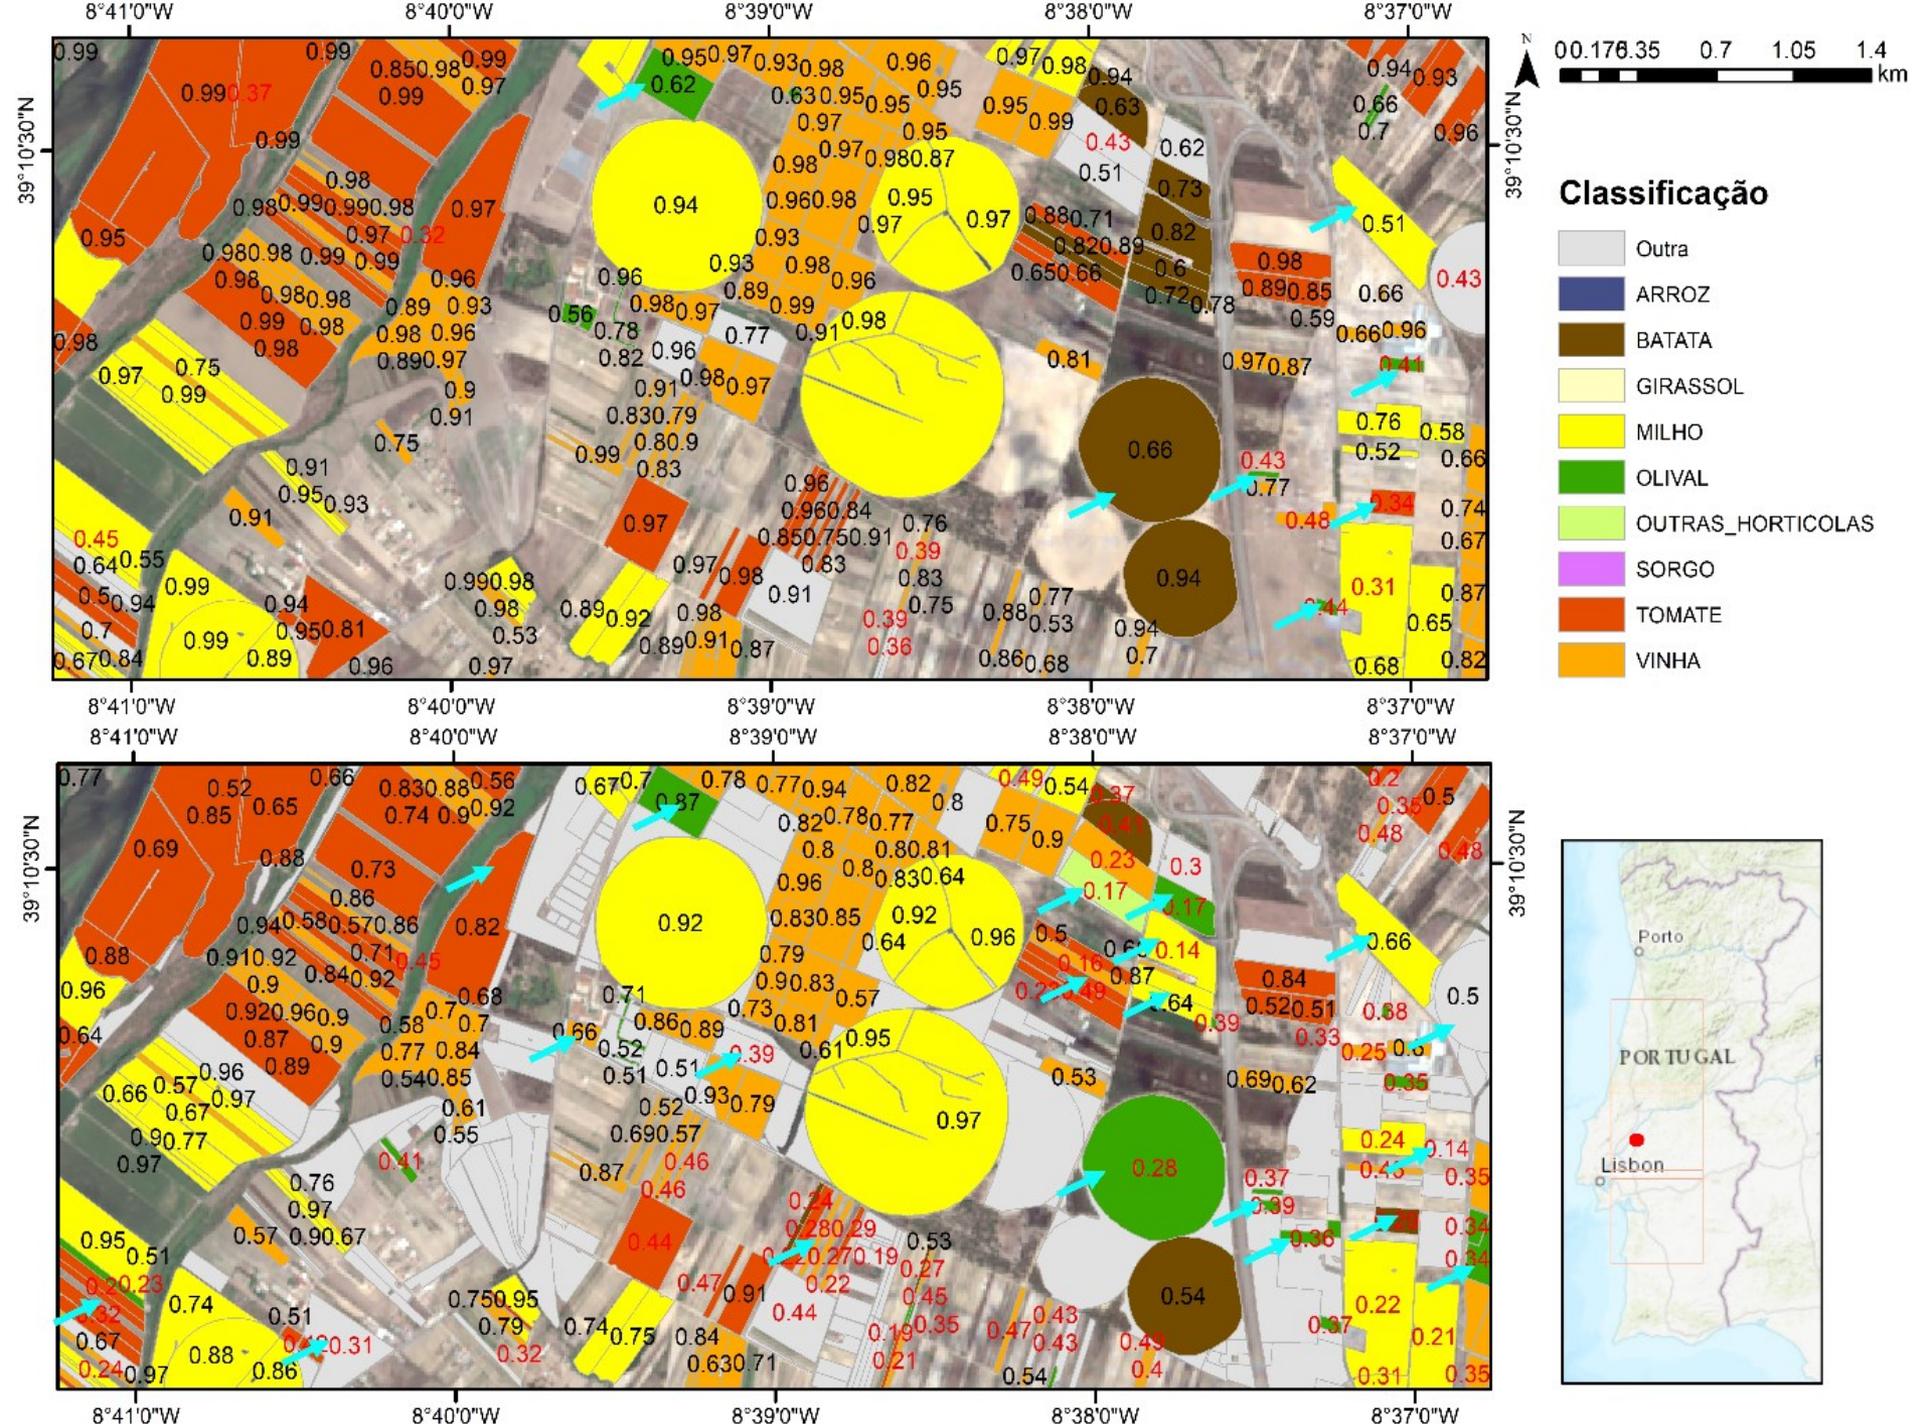
F1-score

O F1-score, com valores entre 0 e 1, corresponde à média ponderada entre precisão (exatidão do utilizador, EU) e revocação (exatidão do produtor, EP), 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*).

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



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

