


Apontamentos de Processamento Digital de Imagens de Satélite Exercícios

ArcGIS



**Geomática (Curso de Agronomia)
Módulo de Detecção Remota**

**Universidade de Évora, Escola de Ciências e Tecnologia
Departamento de Engenharia Rural**

**Adélia M. O. de Sousa
2020**

Índice

1. Introdução	3
2. Análise visual de imagens de satélite	3
2.1. Melhoramento de contraste (Stretch)	3
2.2. Composição colorida	5
3. Processamento de Imagem	8
3.1. Classificação digital de imagem	8
3.1.1. Classificação digital de imagem	8
3.1.2. Classificação digital de imagem	13
4. Transformação de dados	21
4.1. Índices de vegetação	21
4.1.1. Análise multitemporal	24
4.1.2. Identificação de zonas de gestão diferenciada	26
4.2. Análise de componentes principais	27

1. Introdução

A análise e extração de dados da superfície terrestre é de extrema importância, tornando-se cada vez mais acessível tendo em conta o forte crescimento das novas tecnologias na última década. A Detecção Remota surge como a ciência e técnica que permite obter informação sobre objectos localizados na superfície terrestre sem estar em contacto físico directo com o objecto.

Nestes apontamentos, descreve-se resumidamente os princípios aplicados na Detecção Remota, ou seja, o processamento de imagem de satélite com as técnicas mais utilizadas para obter informação detalhada sobre a superfície terrestre. Estão apresentados exercícios práticos com diferentes técnicas e imagens de diferentes satélites direccionados para aplicações em agricultura, no software ARCGIS.

2. Análise visual de imagens de satélite

- Resolução espectral, radiométrica e espacial das imagens a analisar?

- Analisar os valores de cada banda através das propriedades (**Properties/Source**) - a variação destes valores depende da resolução radiométrica (8, 11, 16 ou 32 bits), por exemplo para 8 bits os valores dos pixels variam entre 0 e 255. Estes valores são os chamados números digitais (ND) que representam a reflectância registada pelo sensor do satélite na área da superfície terrestre referente a cada pixel (resolução espacial).

Também se pode analisar os valores mínimos e máximos de todas as bandas em:

Toolbox/Spatial Analyst Tools/Multivariate/Band collection statistics.

Na maior parte das imagens a análise das bandas individuais torna-se difícil pelo baixo contraste dos tons de cinzento (quando se analisa uma imagem de satélite banda a banda, deve-se colocar sempre uma tabela de cores em tons de cinzento. Para melhorar a análise visual de cada banda, faz-se o melhoramento do contraste.

2.1. Melhoramento de contraste (**Stretch**)

A função **Stretch** permite ajustar a tabela de cores utilizada por forma a tornar mais fácil a análise visual da imagem, “obrigando” a imagem a ter o máximo de tons de cinzento disponíveis, que depende da resolução radiométrica.

Os exemplos seguintes são com imagens do satélite Landsat 5 TM para uma área rural no Alentejo.




Figura 1. Imagem original (banda 2).

- Os métodos mais utilizados para o melhoramento de contraste em imagem são: desvio padrão, histograma e pela definição dos valores mínimo e máximo.

Melhoramento do contraste por ajuste do histograma

- com o botão do lado direito do rato aceder às **Properties...** - opção **Simbology (Fig. 2)**
 - por defeito a opção seleccionada é *Stretched*. Nesta janela podemos ver o valor mínimo e máximo desta banda.

- definir o tipo de stretch a ser aplicado a esta banda:

Standard deviations

Aplica um escalamento das cores automático com base no desvio padrão dos ND (valores dos pixels).

Na Figura 2 apresenta-se a imagem com este método de contraste aplicado.




Figura 2. a) Janela *Layer Properties* - opção *Standard deviation* e b) imagem resultante.

Histograma

Permite ao utilizador definir o intervalo de valores onde serão aplicados todos os tons de cinzento ajustando o histograma manualmente (Fig. 3). Desta forma iremos reduzir o intervalo de variação dos ND e aplicar o máximo da sua resolução radiométrica a esse novo intervalo. Os pixels com os valores anteriores ao limite inferior e valores superiores ao limite superior serão agrupados em duas classes (colunas no histograma) e tomam o valor de 0 e 255, respectivamente.




Figura 3. a) Ajuste do histograma e b) imagem resultante.

2.2. Composição colorida

Data Managment /Raster/ Raster processing/Composite bands

As diferentes bandas do satélite podem ser associadas às três cores (RGB) vermelho, verde e azul de modo a melhorar a análise visual da imagem. Há dois tipos de composição colorida: no visível (cor real) e em falsa cor.

No visível ou na cor real - esta combinação de cores simula a imagem que o olho humano vê, ou seja, fazemos a combinação de cores de acordo com as bandas que registam a informação nos respetivos intervalos de comprimentos de onda.

Red – banda do vermelho

Green – banda do verde

Blue - banda do azul

Exemplos com imagem do satélite Landsat 5 TM

Dados disponíveis na plataforma de apoio às aulas

Red – banda 3 (banda correspondente ao intervalo de comprimento de onda da radiação eletromagnética do vermelho)

Green - banda 2 (banda correspondente ao intervalo de comprimento de onda da radiação eletromagnética do verde)

Blue - banda 1 (banda correspondente ao intervalo de comprimento de onda da radiação eletromagnética do azul)

Exercício:

Dados: Imagem Landsat 5 Thematic Mapper

Resolução espacial: 30 m (banda térmica – 120 m)

Resolução espectral: 7 bandas

Banda 1 - Azul

Banda 2 – Verde

Banda 3 – Vermelho

Banda 4 – Infravermelho próximo

Banda 5 – Infravermelho médio

Banda 6 – Infravermelho térmico

Banda 7 – Infravermelho médio

Resolução temporal: 16 dias

Resolução radiométrica: 8 bits (256 níveis de informação)

Largura da faixa registada: 185 km

Com imagens do satélite Landsat, fazer uma composição colorida no visível e duas em falsa cor (uma com a vegetação indicada a verde e outra com a vegetação a vermelho)

- Juntar as bandas para fazer a combinação colorida (RGB) - **Data Management tools / Raster / Composite Bands**




Figura 4. Selecção da função *Composite Bands*.

Na Janela de composição das bandas, seleccionar as respectivas bandas, neste caso as seis bandas disponíveis do satélite Landsat (sem a banda 6 - Infravermelho térmico) (Fig. 5). Defina o nome deste novo ficheiro na pasta onde está a trabalhar e coloque a extensão **.tif** (melhor formato para imagem).




Figura 5. Janela de agrupamento das bandas (*Composite bands*).

O grupo das imagens surge na **Table of contents - Layers** (Fig. 6)




Figura 6. Composição colorida (RGB).

Em seguida basta seleccionar o **Layers properties/ Symbology** e atribuir as bandas às cores (RGB) (Fig. 7). A imagem resultante está indicada na Fig. 8.




Figura 7. Seleção das bandas associadas a cada cor, composição colorida no visível (RGB – b3b2b1).




Figura 8. Imagem resultante da composição colorida no visível (RGB – b3b2b1).

Nesta imagem, resultante da composição colorida no visível, simula a nossa visão, porque faz a correspondência das cores com a respetiva banda do satélite. A vegetação surge em tons de verde, água a escuro e os solos em tons de castanho, cinza ou branco.

Composição colorida em Falsa cor - combinação de quaisquer bandas independente dos intervalos de comprimentos de onda que representam, ou seja, não se faz a correspondência entre banda e a cor.

Exemplos de composições coloridas em falsa cor mais comuns:

Red - banda do vermelho

Green - banda do Infravermelho próximo

Blue - banda do verde

Exemplos com imagem Landsat 5 TM

Red - banda 3

Red - banda 5

Green - banda 4

Green - banda 4

Blue - banda 2

Blue - banda 3

Processo ilustrado na Figura 9.

Nota: nos exemplos de composição colorida em falsa cor referidos acima, a banda do infravermelho próximo está sempre atribuída à cor verde. A razão para esta escolha é facilitar a análise da imagem resultante, as áreas que estão a verde correspondem efetivamente a vegetação pela sua elevada reflectâncias no infravermelho próximo.




Figura 9. a) Escolha das bandas associadas a cada cor e b) Imagem resultante da composição colorida no visível (RGB – b3b4b2).

Neste segundo exemplo utilizamos a banda 5 (infravermelho médio) (Fig. 10).




Figura 10. a) Escolha das bandas associadas a cada cor e b) Imagem resultante da composição colorida no visível (RGB – b5b4b3).

Composição colorida em falsa cor, onde a vegetação se apresenta a vermelho (Fig. 11):

Red - banda 4
Green - banda 3
Blue - banda 2




Figura 11. Composição colorida em falsa cor (RGB – b4b3b2).

Composição colorida com imagem do satélite Sentinel 2 (RGB – Vermelho, Infravermelho próximo, Verde) (Fig. 12)




Figura 12. Composição colorida com imagem do satélite Sentinel 2 a) no visível RGB - Vermelho, Verde, Azul) e b) em falsa cor (RGB - Vermelho, Infravermelho próximo, Verde).

3. Processamento de imagem

3.1. Classificação de imagem

Existem dois métodos de classificação de imagens, **Assistida/Supervisionada** e **Não Assistida/Não Supervisionada**.


A classificação supervisionada “pixel a pixel”, onde a unidade mínima de processamento é o pixel, consiste na identificação de tipos específicos de cobertura do solo, que devem ser conhecidos à priori. Este tipo de classificação tem um pressuposto, ter conhecimento preciso sobre a área de estudo para assim definir as classes de interesse e, posteriormente, aplicar o algoritmo de classificação mais adequado.

Na classificação Supervisionada/Assistida orientada a objecto, a unidade mínima de classificação não é o pixel, mas sim um conjunto de pixels (objecto). A primeira fase deste método é o processo de segmentação de imagem, que se baseia em determinadas características dos objectos, informação espectral e espacial, neste caso informação dos pixels, no entanto também considera outras propriedades, tais como: a cor, a forma, a textura, a área, entre outras.

a) **Classificação Supervisionada/Assistida**, o utilizador define as assinaturas espectrais de categorias conhecidas, tais como zona urbanas, florestas, agricultura, etc...através da indicação de amostras de treino em locais cuja Uso/ocupação do solo é conhecido. Posteriormente o classificador associa cada pixel à assinatura mais similar.

b) **Classificação não supervisionada**, o computador agrupa pixels em categorias de assinatura prováveis e o utilizador identifica que tipo de cobertura efetivamente ela representa. Este tipo de classificação não necessita de informação prévia.

Barra de comandos: Image **Classification (Customize/ToolsBar/Image Classification)**



3.1.1. Classificação Assistida/Supervisionada

Exercício 1

Dados: imagem do satélite Quickbird (Digital Globe – lançado a 18 de Outubro de 2001)

Resolução espacial : 2.4 m / 0.70 m

Resolução espectral : 4 bandas multiespectral / 1 pancromática

Banda 1- azul

Banda 2 – Verde

Banda 3 – vermelho

Banda 4 - infravermelho

Resolução temporal: 1 a 3.5 dias (dependendo da latitude)

Resolução radiométrica: 11 bits (2048 níveis de informação)

Largura da faixa registada: 16.5 km

Definir o projeto no ARCGIS, e definir o sistema de projeção da imagem:

Predefined / Projected coordinate Systems/UTM/Northern Hemisphere/WGS 1984 complex UTM Zone 29N (Fig. 13).




Figura 13. Definir o Sistema de Projecção UTM Zona 29N.

Etapas a percorrer para realizar a classificação assistida:


- i) Definir a legenda (classes de ocupação /uso do solo)
- ii) Digitalizar as áreas de treino
- iii) Gravar as áreas de treino e as assinaturas espectrais
- iv) Analisar os diagramas de dispersão
- v) Correr os classificadores

i) Definir a legenda (classes de uso/ocupação do solo)

Para a área de estudo correspondente à imagem QuickBird (por exemplo):

- Ribeira
- Montado
- Vegetação ripícola
- área urbana
- Acessos
- Solo

ii) Digitalizar as áreas de treino



Com base na imagem resultante da composição colorida, no presente caso RGB-342 (Fig. 14), digitaliza-se as áreas de treino (Fig. 14), ou seja, pequenas amostras (polígonos) das classes de uso/ocupação do solo que se definiram na legenda para esta classificação.




Figura 14. RGB – b3b4b2.

As áreas de treino devem ser digitalizadas de forma rigorosa, aumentando a imagem no local que se pretendem digitalizar, por forma a não ser introduzido pixels que não correspondem às classes que se está a representar.




Figura 15. Ilustração do processo de digitalização das áreas de treino.

Deve-se digitalizar várias áreas de treino para a mesma classe, no entanto devem-se agrupar por forma a ficarem só com um nome, o nome da classe. Este agrupamento de diferentes áreas de treino numa só classe faz-se através do comando  (Fig. 16).




Figura 16. Agrupamento de várias áreas de treino para uma classe (neste caso – Solo).

iii) Gravar as áreas de treino e criar as assinaturas espectrais (Assinature files .gsg), (Fig. 17).




Figura 17. Gravar as áreas de treino e criar as assinaturas espectrais.

iv) Análise das áreas de treino digitalizadas (Scatterplots)




Figura 18. Ilustração da análise dos scatterplots.

Esta análise permite ver a confusão espectral entre cada classe e analisar quais as melhores bandas a separar as classes.

Na Figura 19 apresenta-se um conjunto de *scatterplots* onde se pode analisar a distribuição espacial das classes em análise. Podemos analisar que a melhor banda a discriminar as 3 classes é a banda 4 com a banda 1, onde as nuvens de pontos que representam aparecem separadas no espaço. Todas as outras bandas mostram grande sobreposição espectral entre duas classes (rosa e verde). Para as mesmas bandas estas duas classes apresentam boa separação com a terceira (azul).




Figura 19. Exemplo da análise dos *Scatterplots* de três classes.

v) Aplicar os classificadores (Máxima verosimilhança)




Figura 19. Aplicação do classificador de máxima verosimilhança.

Resultado da classificação

- Avaliar visualmente o resultado da classificação (Fig. 21) por comparação com a imagem de RGB.




Figura 21. Resultado da classificação.

Atribuição do nome correcto às classes de ocupação do solo (Fig. 22)




Figura 22. Atribuir nome das classes ao resultado da classificação.

Atribuir os elementos cartográficos (Fig. 23) e criar um mapa final para apresentar o resultado (introduzir no layout a legenda, escala e orientação cartográfica) (Fig. 24).




Figura 23. Janela de atribuição dos elementos cartográficos.




Figura 24. Mapa final com a cartografia de ocupação do solo.

Exercício 2:

Objectivo – Identificar e cartografar as diferentes culturas existentes na área em estudo.

Classificação Assistida/Supervisionada para uma zona de diversas culturas (região de Santarém).

Imagem Landsat 8, com indicação de classes de uso do solo (ficheiro de pts_culturas)

Dados: imagem do satélite Landsat 8 (Tabela 1)

Resolução espacial: 30 m

Resolução espectral: 10 bandas multiespectral / 1 pancromática

Tabela 1. Características do satélite Landsat 8.

SATÉLITE LANDSAT-8	
Características	Sensores <i>Operational Land Imager (OLI) Bandas 1 a 9 e Thermal Infrared Sensor (TIRS) Bandas 10 e 11</i>
Largura de Faixa	170x185 km
Bandas Espectrais/Resolução espacial	Banda 1 <u>Coastal aerosol</u> (0,43-0,45 μm) - 30 m Banda 2 <u>Blue</u> (0,450-0,51 μm) - 30 m Banda 3 <u>Green</u> (0,53-0,59 μm) - 30 m Banda 4 <u>Red</u> (0,64-0,67 μm) - 30 m Banda 5 <u>Near Infrared NIR</u> (0,85-0,88 μm) - 30 m Banda 6 <u>SWIR 1</u> (1,57-1,65 μm) - 30 m Banda 7 <u>SWIR 2</u> (2,11-2,29 μm) - 30 m Banda 8 <u>Panchromatic (PAN)</u> (0,50-0,68 μm) - 15 m Banda 9 <u>Cirrus</u> (1,36-1,38 μm) - 30 m Banda 10 <u>Thermal Infrared TIRS 1</u> (10,6-11,19 μm) - 100 m Banda 11 <u>Thermal Infrared TIRS 2</u> (11,5-12,51 μm) - 100 m
Resolução Radiométrica	16 Bits
Projeção	Projeção UTM, <u>Datum</u> WGS 1984
Revisita	16 dias
Órbita	<u>Heliossíncrona</u> (altitude de 705 km)

Fonte: *United States Geological Survey (USGS, 2013).*

Para o exercício estão disponíveis as 7 bandas:

Banda 1- costeira

Banda 2 - azul

Banda 3 - verde

Banda 4 - vermelho

Banda 5 - infravermelho próximo

Banda 6 - infravermelho médio 1

Banda 7 - infravermelho médio 2

Composição colorida (Falsa cor), destacando as áreas de vegetação a verde e os solos a rosa (Fig. 25):

Red - banda 4

Green - banda 5

Blue - banda 3




Figura 25. Composição colorida em falsa cor com indicação de classes (culturas).

Com base na informação fornecida sobre as classes existentes na área em estudo bem como no enquadramento do uso /ocupação do solo que se identifica na imagem, procede-se à marcação das amostras de treino (Fig. 26). Resultado do processo de classificação (Fig. 27).

Definição da Legenda

Digitalização das amostras de treino




Figura 26. Ilustração da marcação das amostras de treino para cada classe e seleção do classificador.




Figura 27. Resultado do processo de classificação.

3.1.2. Classificação não assistida ou não supervisionada

Neste método de classificação não necessitamos de ter informação sobre a área de estudo. O algoritmo de classificação vai agrupar os pixels com base nas suas características espectrais.

Neste tipo de classificação, a 1ª etapa é a aplicação dos classificadores. O próprio classificador é que vai agrupar os pixels segundo as suas semelhanças espectrais.

Selecionar o classificador – Barra de ferramentas **Image Classification** - **Iso Cluster Unsupervised Classification** (Fig. 28).




Figura 28. Selecção do classificador Iso Cluster.

Neste classificador tem de ser definido (Fig. 29):

- composição de bandas a serem consideradas na classificação;
- número de classes que se pretende obter;
- número mínimo de pixels por classe.
- intervalo de separação espectral entre cada classe.




Figura 29. Janela do classificador Iso Cluster.

Nota: Neste método de classificação deve-se sempre indicar um número de classes superior ao que se pretende efectivamente. Se se verificar que duas ou mais classes correspondem ao mesmo tipo de ocupação do solo procede-se à reclassificação da imagem resultante da classificação agrupando os conjuntos de pixels criados no processo de classificação automática, através do processo de reclassificação da imagem resultante.

Por exemplo, a Fig. 30 apresenta o resultado de uma classificação com o algoritmo Iso Cluster e para 10 classes. Se quisermos manter as classes iniciais definidas para esta área de estudo teremos de as analisar, comparando com o RGB e agrupar as 10 em 6 classes. Esta operação faz-se através do módulo de reclassificação – **Spatial Analyst Tools / Reclass / Reclassify** (Fig.31).




Figura 30. Exemplo de um resultado da classificação com o algoritmo Iso cluster para 10 classes.




Figura 31. Reclassificação dos conjuntos de pixels.

4. Transformação de dados espectrais

A transformação de dados espectrais baseia-se na realização de operações e procedimentos estatísticos por forma a realçar determinados aspectos dos dados originais. Sendo de destacar o cálculo de índices de vegetação e a análise de componentes principais.

4.1. Índices de Vegetação

O índice espectral de vegetação, normalmente designado apenas por índice de vegetação (IV), é um valor obtido directamente ou através de um quociente, diferença ou outra transformação de dados espectrais. Este valor representa as características da vegetação, como o índice de área foliar, biomassa, peso verde, peso seco, percentagem de coberto, etc. Os índices de vegetação usam-se, portanto, para correlacionar dados espectrais com parâmetros de vegetação.

Um bom índice de vegetação deverá satisfazer alguns critérios:

- realçar o sinal da vegetação;
- normalizar o efeito de sinais “não- verdes”, tais como solo e água.
- minimizar o efeito de variações externas, devidas à atmosfera e às geometrias de iluminação e observação).
- ser de aplicação generalizável no espaço e no tempo.

Existem dois tipos de índices de vegetação:

Índices baseados em quocientes

O índice de vegetação do quociente simples (Simple Ratio Vegetation Index, $SR = IVP/V$) e o índice da diferença normalizada (Normalized Difference Vegetation Index, $NDVI = (IVP - V)/(IVP + V)$) são os índices mais comuns deste tipo. Ambos envolvem quocientes de valores simples ou combinações lineares de bandas do infravermelho próximo (IVP) e Vermelho (V).

O NDVI apresenta valores entre -1 e 1, devido à normalização da diferença entre as variáveis (IVP e V). Quando os valores são próximos de 1 (IVP elevado e V baixo) demonstra vegetação densa, próximos de zero solo e valores próximos de -1 representam água.

Índices de tipo ortogonal ou índices de vegetação baseados em distâncias à linha de solos

Os índices de tipo ortogonal distinguem-se dos baseados em quocientes porque as isolinhas de quantidade de vegetação não convergem para a origem, mantendo-se paralelas à linha do solo. Estes índices maximiza o sinal da vegetação verde, mantendo constante a sua informação relativa ao solo.

Os índices de vegetação permitem uma melhor análise do coberto do solo, facilitando a detecção de alterações principalmente do coberto vegetal em estudos multitemporais. Ainda pode ser utilizado como nova banda no processo de classificação de imagem, ajudando a discriminar diferentes tipos de ocupação do solo.

Exercício

Dados: Imagem do satélite Landsat 8 – imagem com diferentes culturas agrícolas da região do vale de Santarém. Duas datas (22 de Julho e 23 de Agosto) (Fig. 32)




Figura. 32. Composição colorida em falsa cor (RGB – Vermelho, Infravermelho próximo, Verde).

a) Objectivo: Análise do NDVI

Calcular o índice de vegetação NDVI: ***Spatial analyst tools / Map Algebra/ Raster Calculator*** (Fig. 33)

Nota: Como o valor do NDVI são valores reais tem de se seleccionar sempre a função FLOAT.

$$\text{NDVI} = (\text{IVp} - \text{V}) / (\text{IVp} + \text{V}),$$

onde IVp e V corresponde ao Infravermelho próximo e Vermelho.




Figura 33. Cálculo do NDVI (Raster calculator).




Figura 34. Imagem resultante do NDVI em escala de cinzentos e com uma das paletes de cores mais adequada para a análise da imagem de NDVI.

Analisando os valores da imagem do NDVI (Fig. 34) podemos verificar diferentes estados de crescimento da vegetação, ou a presença do solo em algumas parcelas.

Calcule a área (ha) das zonas que tem vegetação densa com base no índice de vegetação NDVI.

Primeiro passo será avaliar o valor de NDVI a partir do qual é considerado vegetação densa. No presente caso $NDVI \geq 0.40$ (verificar o valor interrogando os pixels – *Identify*).

Spatial Analyst / Reclassify





Figura 35. Mapa com indicação das zonas com vegetação densa.

Para estudos multitemporais, como detecção de alteração do coberto entre diferentes datas os índices de vegetação facilitam a análise.

4.1.1. Análise multitemporal

Os índices de vegetação permitem realizar de forma fácil uma análise multitemporal, verificar as alterações de uso/ocupação do solo entre duas datas.

Exercício

- b)** Calcular o índice de vegetação para duas datas (Julho e Agosto) para detetar as parcelas onde houve alteração do estado das culturas.

Realizar a diferença entre as duas imagens do NDVI




Figura 35. Imagem do NDVI para a data de Julho (a), para a data de Agosto (b) e a diferença entre as duas datas (posterior menos anterior)(c).

A diferença entre NDVI obtido com imagens de duas datas diferentes (Fig. 35).

$NDVI_{ag} - NDVI_{jul} > 0$ - alteração de coberto - ganho de vegetação (neste caso, desenvolvimento de culturas)

$NDVI_{ag} - NDVI_{jul} \cong 0$ - sem alterações significativas de coberto

$NDVI_{ag} - NDVI_{jul} < 0$ - alteração de coberto - perda de vegetação (neste caso, colheita de algumas culturas)

Utilizando a ferramenta *Reclassify* pode-se obter uma imagem com as zonas onde houve ganho (0.10 até máximo valor na imagem de diferenças) e perda (valor mínimo na imagem de diferenças até - 0.10) de vegetação bem como as zonas sem alteração significativa (-0.10 a 0.10) (Fig. 36).



Figura 36. Mapa com as zonas de alteração significativa do coberto vegetal e das zonas onde não houve alterações significativas.

4.1.2. Zonas de gestão diferenciada

A gestão diferenciada é de importância relevante na agricultura, destacando-se os factores económicos e o ambientais. por exemplo, na quantidade de fertilizante e ou pesticida a aplicar, na quantidade e qualidade da produção, etc.

Para a definição dessas zonas podem utilizar-se índices de vegetação, mapas de condutividade elétrica, mapas de solos, etc.

Para o caso do índice de vegetação NDVI, que permite de forma expedita criar mapas de zonas com características diferentes a nível de densidade da vegetação e presença de clorofila, ou seja, o seu vigor vegetativo e indicação do seu stress hídrico.

Estes mapas são criados, através do processo de classificação de imagem de satélite ou através da ferramenta *Reclassify*, identificando as zonas com características espectrais diferentes. Na Fig. 27 podemos analisar uma área agrícola, dividida em duas áreas com diferentes utilizações, onde se identificam zonas para possível gestão diferenciada.




Figura 37. Ilustração de uma área agrícola com identificação de zonas para gestão diferenciada.

4.2. Análise de componentes principais

Um aspecto a considerar na classificação digital de imagens de satélite é a redundância de informação existente nas diferentes bandas, ou seja, existe por vezes uma correlação muito elevada entre bandas, indicando que estas contêm o mesmo tipo de informação. Uma forma para analisar este aspecto passa por fazer uma Análise de Componentes Principais (ACP). A ACP de forma simplificada é a redução da informação contida em várias variáveis de forma a não haver sobreposição de informação.

A ACP é um método multivariado de redução dos dados. Este método permite eliminar a correlação existente entre as variáveis em análise, diminuindo a informação, ou seja, criando novas variáveis não correlacionadas entre si, chamadas componentes principais.

No caso de imagens de satélite, a transformação de uma imagem nas suas componentes principais corresponde a determinar os planos imagem que a compõem num outro referencial do espaço multispectral em que estes planos são não-correlacionados (Fig. 38). As componentes principais da imagem são combinações lineares das bandas originais.




Figura 38. Ilustração do processo de ACP.

No exemplo que se apresenta a seguir, as variáveis são as 8 bandas multiespectrais do **satélite WorldView 2**.

Características deste satélite:





Figura 39. Especificações do satélite WorldView 2.

a) Aplicação do método de ACP

A aplicação deste método aos dados do satélite WorldView2, tem como objectivo reduzir a informação contida nas 8 bandas, evitando assim processar a totalidade das bandas para realizar a classificação.

Há duas formas de seleccionar esta função:

Spatial Analyst Tools/Multivariate/Principal Components ou



O exemplo do quadro seguinte é o resultado da análise das 8 bandas de uma imagem de satélite (WorldView2) sobre uma parcela agrícola (Azarento, Fronteira) utilizando esse algoritmo.

A Fig. 40 ilustra a janela da função do cálculo das componentes principais. Define-se as bandas sobre as quais se pretende aplicar a redução da correlação, define-se o nome das novas imagens, ou seja das componentes principais e o nome do ficheiro de texto onde serão apresentados os resultados (matriz de correlação etc...)





Figura 40. Janela da função do cálculo das componentes principais.

Como resultado do processo ACP, obtém-se 8 imagens que correspondem às componentes principais e um ficheiro de texto com os cálculos realizados, indicado no quadro seguinte.

Analisando as CP na Fig. 41 verifica-se que as primeiras se assemelham a algumas das bandas originais do satélite, enquanto que outras deixam de apresentar informação perceptível, apresentando em parte da imagem ou na sua totalidade o chamado ruído. A CP1 mostra a maior variação da informação presente nas 8 bandas originais e a CP2 mostra a seguida maior variação, ou seja, a variação segundo o eixo ortogonal à CP1. As restantes CP pouco mais informação fornece da área em estudo.






Figura 41. Componentes principais da imagem do pivot Azarento (Fronteira).

Analisando o quadro podemos observar comprovar o que se verifica nas imagens das CP, que a CP1 contém 94% do total de informação contida nas 8 bandas analisadas e que esta componente em conjunto com a CP2 contém, a totalidade da informação existente nas 8 bandas analisadas.

b) Resultado da análise de componentes principais

Matriz de Covariância

Componentes	1	2	3	4	5	6	7	8
#	-----							
Banda 1	1440.89385	2827.90855	5814.60767	7837.46863	7675.56548	6167.04418	1910.17782	2386.1371
Banda 2	2827.9085	5627.65755	11571.75229	15501.7338	15256.22923	12243.0818	3887.9247	4790.6877
Banda 3	5814.60767	11571.75229	23962.9899	31988.7743	31476.557	25468.4185	8322.2294	0102.3869
Banda 4	7837.46863	15501.73384	31988.77433	43213.02657	42284.30157	34171.77489	10622.15759	13282.96602
Banda 5	7675.56548	15256.22923	31476.55743	42284.30157	41758.9296	33325.8936	10360.37365	12915.82037
Banda 6	6167.04418	12243.0818	25468.41854	34171.77489	33325.8936	28056.0977	10138.66296	11967.8337
Banda 7	1910.1778	3887.92472	8322.22947	10622.15759	10360.37365	10138.66296	8762.38219	7785.2673
Banda 8	2386.13712	4790.68778	10102.38696	13282.96602	12915.82037	11967.83374	7785.2673	7997.1428

Matriz de Correlação

Layer	1	2	3	4	5	6	7	8
#								
Banda 1	1.00000	0.99308	0.98954	0.99324	0.98951	0.96995	0.53758	0.70293
2	0.99308	1.00000	0.99647	0.99405	0.99520	0.97435	0.55366	0.71411
3	0.98954	0.99647	1.00000	0.99408	0.99504	0.98224	0.57433	0.72977
4	0.99324	0.99405	0.99408	1.00000	0.99540	0.98140	0.54588	0.71453
5	0.98951	0.99520	0.99504	0.99540	1.00000	0.97363	0.54161	0.70677
6	0.96995	0.97435	0.98224	0.98140	0.97363	1.00000	0.64663	0.79898
7	0.53758	0.55366	0.57433	0.54588	0.54161	0.64663	1.00000	0.93003
8	0.70293	0.71411	0.72977	0.71453	0.70677	0.79898	0.93003	1.00000

Eigenvalues **150371.34** **9195.73** **603.15** **343.22** **162.34** **106.44** **25.93** **10.98**

Matriz de Eigenvectors

Banda 1	0.09671	-0.03743	-0.03706	-0.01777	-0.13011	0.21152	0.45009	0.85048
2	0.19208	-0.06256	-0.14651	-0.01323	0.09145	0.33469	0.75357	-0.49931
3	0.39764	-0.08910	-0.18302	0.17425	0.51617	0.57911	-0.39956	0.09292
4	0.53344	-0.18672	0.06447	-0.06485	-0.75857	0.19333	-0.21272	-0.11897
5	0.52344	-0.20252	-0.42842	-0.24974	0.21933	-0.61934	0.05454	0.06640
6	0.42826	0.09881	0.73163	0.38681	0.20109	-0.24734	0.14198	0.01275
7	0.14869	0.75653	-0.40728	0.44827	-0.17799	-0.08331	0.00976	-0.00367
8	0.17768	0.57338	0.23412	-0.74297	0.11233	0.13707	-0.03785	0.00284

PERCENT AND ACCUMULATIVE EIGENVALUES

# PC Layer	EigenValue	Percent of EigenValues	Accumulative of EigenValues
1	150371.34303	93.5034	93.5034
2	9195.73050	5.7181	99.2215
3	603.14771	0.3750	99.5965
4	343.21607	0.2134	99.8099
5	162.33615	0.1009	99.9109
6	106.43968	0.0662	99.9771
7	25.92977	0.0161	99.9932
8	10.97737	0.0068	100.0000

Pela Figura 41, poderemos também verificar que as bandas mais semelhantes entre si são as bandas 1 e 2; 3 e 5; 4 e 6; e 7 e 8. As bandas 3, 4, 5 e 6 são ainda relativamente próximas entre si.




Figura 41. “Eigenvectors” da componente 1 e 2.

Com esta análise realizada, pode-se dizer que para realizar uma classificação de padrões diferentes sobre esta imagem, basta usar as duas primeiras CP em vez das 8 bandas originais.

No exemplo seguinte realiza-se a classificação assistida /supervisionada da área do pivô para identificar diferentes áreas de uso do solo através dos seus padrões diferentes, neste caso áreas de elevada e baixa produção de milho e duas zonas de áreas de solo da área não cultivada.

Exercício

Classificação Assistida / Supervisionada

- i) Em primeiro lugar e para facilitar os procedimentos seguintes agrupam-se as duas CP (Fig. 42)




Figura 43. Agrupamento das CP 1 e 2.

- c) Desta forma e analisando a imagem RGB das CP obtida pelo ARCGis podemos então desenhar as áreas de treino para a classificação dos diferentes padrões existente na imagem e que diferenciam a ocupação de solo. Com a informação recolhida com estas áreas de treino, serão criadas as assinaturas espectrais de cada região (Fig. 44).

No exemplo seguinte apresentam-se as áreas de treino possíveis para identificar 4 padrões diferentes que correspondem a duas zonas de produção (1 – baixa produção e 2 - alta produção) e duas zonas de solo inculto com padrões (assinaturas espectrais) diferentes (zonas 3 e 4).




Figura 44. Digitalização das áreas de treino para as classes em questão.

d) Gravar as áreas de treino



e) Criar e gravar as assinaturas espectrais –  (Não esquecer de colocar o ficheiro onde se agrupou as duas primeiras componentes principais no **Layer** da barra de ferramentas **Classification**).

Ou

ArcToolbox/ Spatial Analyst Tools/ Multivariate/ Create signatures (quando não se agrupou as componentes principais)

Neste caso, como se pretende que para o processo de classificação sejam utilizadas apenas as duas primeiras CP e não as bandas originais nem as restantes CP, recorre-se à função **ArcToolbox/ Spatial Analyst Tools/ Multivariate/ Create signatures**.

Assim, só se carregam as duas primeiras CP, as quais contêm 99% da informação presente nas 8 bandas.




Figura 45. Janela *Create Signatures*.

- f) Analisar os **Scatterplots** (o que nos permite verificar se as classes estão bem individualizadas).

No presente caso verifica-se uma excelente separação entre as classes, a band_1 (CP1) separa perfeitamente três classes, ou seja, as duas de tipos diferentes de solo e as outras duas, alta e baixa produção, enquanto que estas duas classes são separáveis pela Band_2 (CP2) (Fig. 46).




Figura 46. Análise do Diagrama de dispersão com as assinaturas espectrais.

Nota:

- para visualizar os diagrama de dispersão, neste caso que estamos já só a trabalhar com as componentes principais 1 e 2, no Layer na barra de classificação teremos de ter o ficheiro onde estão as componentes principais.
- os scatterplots que nos interessam analisar neste caso é apenas o primeiro, ou seja, onde estão as duas CP 1 e 2.

- g) Aplicar o classificador de máxima verosimilhança (Fig. 47 e 48).





Figura 47. Aplicação do algoritmo de classificação de máxima verosimilhança.




Figura 48. Atribuir o nome às classes – Labels da Simbology.

Na Fig. 49 apresenta o resultado final da classificação assistida pelo método de máxima verosimilhança.





Figura 49. Imagem classificada com as zonas de produção e de solos incultos referidos anteriormente.

Classificação não assistida /não supervisionada

a) Aplicação do classificador – Máxima verosimilhança



Neste classificador basta definir o número de conjuntos de pixels que se pretende obter. Há que ter em conta que muitas vezes o número de classes definidas não corresponde ao número resultante. Na Fig. 50 apresenta-se a janela do classificador Iso Cluster e o resultado da aplicação deste classificador com os parâmetros indicados (Fig. 51).




Figura 50. Janela do classificador Iso Cluster.




Figura 51. Imagem classificada com o classificador *Iso cluster* – 6 conjuntos de pixels.

O passo seguinte será atribuir as classes, Que classe de uso/ocupação do solo corresponde a cada uma dos seis conjuntos de pixel?

O classificador automático atribuiu 3 classes à metade cultivada do pivot, e outras 3 classes à metade não cultivada. Comparando com a imagem em RGB podemos atribuir 3 classes a diferentes produções da cultura e na outra metade do pivot apenas se pretende 2 tipos de solo, assim agrupa-se a classe 4 e 5 (solo mais escuro no RGB e 6 como outro tipo de solo).

Classe 1 – média produção

Classe 2 – alta produção

Classe 3 – baixa produção

Classe 4 – solo 1

Classe 5 – solo 1

Classe 6 – solo 2

Este agrupamento de classes - **Função *Reclassify*** (Fig. 52).




Figura 52. Janela do processo de classificação e a imagem resultante (5 classes).

E finalmente atribuir os nomes das classes (Fig. 53).




Figura 53. Atribuição dos nomes das classes e Layout do resultado da classificação.