

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ENGENHARIA GEOGRÁFICA, GEOFÍSICA E ENERGIA



Avaliação do Potencial das Imagens Sentinel-1 para Identificação de Culturas Agrícolas

Mestrado em Engenharia Geográfica

Cátia Sofia Alves Saraiva

Dissertação orientada por:
Prof. Dra. Ana Cristina Navarro Ferreira

2015

Resumo

O presente estudo tem como finalidade avaliar a potencialidade das imagens SAR (*Synthetic Aperture* RADAR) do satélite Sentinel-1 com dupla polarização (VV/VH) para a identificação de culturas na zona agrícola de Vila Franca de Xira (lezíria e mouchões). Ao longo do trabalho é analisado em que medida a utilização de canais adicionais de informação derivada destas imagens pode melhorar os resultados obtidos da classificação de imagens do satélite Landsat-8. Para identificar as diferentes culturas presentes na zona estudo, utilizaram-se séries temporais das imagens Landsat-8 e Sentinel-1, abrangendo a época de crescimento das culturas (de maio a julho de 2015). A informação derivada das imagens do satélite Sentinel-1 consistiu nos coeficientes de retrodispersão nas polarizações VV e VH, quocientes entre polarizações e diferenças entre polarizações. Numa primeira fase, avaliou-se qual o algoritmo e combinação de parâmetros (óticos e SAR) que permitiram obter os melhores resultados na classificação. Foram testados diferentes algoritmos de classificação nomeadamente, Máxima Verosimilhança (ML – *Maximum Likelihood*), Redes Neurais (NN – *Neural Network*) e Máquina de Suporte Vetorial (SVM – *Support Vector Machine*). Posteriormente, a partir da combinação e classificador selecionados realizou-se a classificação multitemporal. Os resultados foram testados e validados com informação do Sistema de Identificação de Parcelas (SIP) fornecido pelo Instituto de Financiamento da Agricultura e Pescas (IFAP). Adicionalmente, efetuou-se o estudo da fenologia das culturas através dos valores dos coeficientes de retrodispersão e do Índice de Vegetação de Diferença Normalizada (NDVI – *Normalized Difference Vegetation Index*). Verificou-se que a adição de informação SAR às bandas espectrais Landsat-8 permitiu melhorar os resultados obtidos. A combinação que permitiu obter os melhores resultados foi a junção das bandas Landsat-8 em conjunto com o coeficiente de retrodispersão para a polarização VH, utilizando o algoritmo de classificação SVM. A classificação multitemporal desta combinação permitiu melhorar resultados, tendo sido obtida uma precisão global de 94,1%, face aos 90,2% obtidos apenas com as bandas correspondentes à data com maior desenvolvimento das culturas, e um coeficiente *Kappa* de 91,2%.

Palavras-chave: Sentinel-1, SAR, Dupla Polarização, Landsat-8, Classificação Multitemporal.

Abstract

The aim of this study is to evaluate the potential of Sentinel-1 SAR (Synthetic Aperture RADAR) images with dual polarization (VV/VH) for the identification of different crops in the agricultural area of Vila Franca de Xira. Throughout the work, the potential of using additional information, derived from these images, to improve the performance of the Landsat-8 images classification was evaluated. In order to identify the different crops present in the study area, Landsat-8 and Sentinel-1 time series covering the growing season (from May to July 2015) were used. The information derived from the Sentinel-1 images consisted of backscattering coefficients for the VV and VH polarization, polarization ratios and differences. Initially, the classification algorithm and parameter's combination (optical and SAR) which retrieved the best results were evaluated. Different classification algorithms were tested, namely the Maximum Likelihood (ML), Neural Network (NN) and Support Vector Machine (SVM). Then, using the selected combination and classifier the multi-temporal classification was performed. The results were tested and validated using data from the Parcel Identification System (SIP – *Sistema de Identificação de Parcelas*) provided by the *Instituto de Financiamento de Agricultura e Pescas* (IFAP). Additionally, the crops phenology study was carried out based on the backscattering coefficients and the *Normalized Difference Vegetation Index* (NDVI). The addition of SAR information to the Landsat-8 spectral bands has improved the results. The combination that produced the best results was the junction of the Landsat-8 bands with the VH polarization backscattering, using the SVM classification algorithm. The multi-temporal classification performed with this combination enable an improvement of the results, with an overall accuracy of 94.1%, when compared to the 90.2% obtained with the bands of the date with the most crop development, and a Kappa coefficient of 91.2%.

Keywords: Sentinel-1, SAR, Dual Polarization, Landsat-8, Multi-temporal Classification.

Agradecimentos

Em primeiro lugar, à Prof. Dra. Ana Navarro, a orientadora desta dissertação, a disponibilidade e orientação prestadas, a partilha de conhecimentos e sugestões face aos problemas que surgiram durante a realização deste trabalho.

Ao IFAP, nomeadamente à Eng^a Célia Sousa, a cedência da informação relativa às culturas existentes na zona de estudo que constam do Sistema de Identificação de Parcelas.

Aos colegas e amigos de Engenharia Geográfica que me acompanharam nesta importante etapa.

À minha família e amigos, especialmente aos meus pais, às minhas irmãs e aos meus avós pelo apoio e incentivo incondicionais demonstrados ao longos destes anos.

Índice

Resumo.....	i
Abstract	iii
Agradecimentos.....	v
Lista de Abreviaturas e Acrónimos	xiii
1. Introdução	1
1.1. Enquadramento.....	1
1.2. Objetivos	3
1.3. Estrutura da tese	3
2. Estado da Arte	5
3. Conceitos Teóricos.....	9
3.1. Detecção Remota	9
3.2. Sensores óticos	11
3.2.1. Calibração radiométrica	12
3.2.2. Interação da radiação com a vegetação e Índice de Vegetação de Diferença Normalizada (NDVI).....	12
3.3. SAR.....	13
3.3.1. Conceito de RADAR.....	14
3.3.2. Geometria de aquisição das imagens RADAR e resolução espacial.....	15
3.3.3. Conceito de SAR.....	16
3.3.4. Calibração radiométrica e coeficiente de retrodispersão.....	17
3.3.5. Ruído de Speckle, multilooking e filtro especial.....	18
3.3.6. Distorções geométricas e correções de terreno	19
3.3.7. Polarização nos sistemas RADAR	20
3.4. Missão Sentinel-1.....	22
3.4.1. Características principais e modos de aquisição da missão Sentinel-1	24
3.4.2. Tipos de produtos e níveis de processamento	27
3.5. Classificação supervisionada.....	28
3.5.1. Máxima Verosimilhança (ML).....	29
3.5.2. Redes Neurais (NN)	30
3.5.3. Máquina de Suporte Vetorial (SVM)	32
3.5.4. Classificação baseada em objetos.....	34
3.5.5. Validação.....	34
4. Metodologia	37
4.1. Área de estudo.....	38

4.2.	Dados utilizados	39
4.3.	Processamento das imagens óticas e SAR	41
4.4.	Tratamento e seleção dos dados do SIP	42
4.6.	Classificação	45
5.	Resultados	47
5.1.	Estudo da fenologia das culturas	47
5.1.1.	Evolução temporal do NDVI.....	47
5.1.2.	Evolução temporal do coeficiente de retrodispersão VV e VH	49
5.2.	Classificação.....	52
6.	Conclusões e Perspetivas Futuras	57
6.1.	Principais Conclusões	57
6.2.	Perspetivas Futuras.....	57
	Referências Bibliográficas	59
	Anexos.....	65

Índice de Figuras

Figura 3.1 – Radiação eletromagnética [CCRS, 2015a].	9
Figura 3.2 – Espectro eletromagnético, adaptado de NASA [2013].	10
Figura 3.3 – (a) Reflexão especular. (b) Reflexão difusa [CCRS, 2015a].	10
Figura 3.4 – Princípio básico dos sistemas óticos, adaptado de CRISP [2001].	11
Figura 3.5 – (a) Modo <i>whiskbroom</i> . (b) Modo <i>pushbroom</i> [Catalão, 2013].	11
Figura 3.6 – Representação simplificada da aquisição de Imagens RADAR [Fonseca e Fernandes, 2004].	14
Figura 3.7 – Geometria de Aquisição da Imagem RADAR [Fonseca e Fernandes, 2004].	15
Figura 3.8 – <i>Synthetic Aperture</i> RADAR [Fonseca e Fernandes, 2004].	16
Figura 3.9 – Áreas de referência de retrodispersão, adaptado de Atwood <i>et al.</i> [2012].	18
Figura 3.10 – Distorção de distâncias nas imagens SAR, adaptado de ESA [2015c].	19
Figura 3.11 – Efeitos geométricos das imagens SAR, adaptado de ESA [2015a].	20
Figura 3.12 – Propagação da onda eletromagnética, adaptado de ESA [2015d].	21
Figura 3.13 – Polarização horizontal e vertical da onda plana eletromagnética [CCRS, 2015b].	21
Figura 3.14 – Sentinel-1 [ESA, 2013].	23
Figura 3.15 – Missões Sentinel previstas e as suas principais aplicações, com base em informação da ESA [2012].	24
Figura 3.16 – Constelação Sentinel-1 [ESA, 2013].	24
Figura 3.17 – Configuração dos diferentes modos de aquisição [ESA, 2012].	26
Figura 3.18 – Níveis dos produtos dos modos de aquisição da missão Sentinel-1 [ESA, 2013].	27
Figura 3.19 – Classificação dos píxeis da imagem em classes de um mapa temático, adaptado de Richards e Jia [2006].	29
Figura 3.20 – Elemento de processamento (EP) de uma rede neuronal, adaptado de Richards e Jia [2006].	30
Figura 3.21 – Rede Neuronal de multicamadas, adaptado de Richards e Jia [2006].	31
Figura 3.22 – SVM num espaço bidimensional, adaptado de Mountrakis, <i>et al.</i> [2011].	32
Figura 3.23 – Dados não linearmente separáveis, adaptado de Oommen <i>et al.</i> [2008].	33
Figura 4.1 – Fluxograma da metodologia utilizada.	37
Figura 4.2 – Aplicações informáticas e etapas em que foram utilizadas.	37
Figura 4.3 – (a) Área de Estudo. (b) Freguesia de Vila Franca de Xira.	38
Figura 4.4 – Valores de precipitação média e temperatura média mensais no período de estudo.	39
Figura 4.5 – Divisão dos limites de uma parcela de arroz devido à existência de um caminho na região central.	42

Figura 4.6 – Redefinição dos limites de uma parcela de milho.....	43
Figura 4.7 – Eliminação de uma parcela de tomate devido à ausência de vegetação.	43
Figura 4.8 – Fluxograma das operações efetuadas pelas <i>toolbox</i>	44
Figura 5.1 – (a) Evolução temporal do NDVI do arroz. (b) Evolução temporal do NDVI do milho. (c) Evolução temporal do NDVI do tomate. (d) Evolução temporal do NDVI das pastagens permanentes.....	48
Figura 5.2 – Tendência média do NDVI para cada tipo de cultura.....	49
Figura 5.3 – (a) Evolução temporal do σ_{VV}^0 do arroz. (b) Evolução temporal do σ_{VH}^0 do arroz. (c) Evolução temporal do σ_{VV}^0 do milho. (d) Evolução temporal do σ_{VH}^0 do milho. (e) Evolução temporal do σ_{VV}^0 do tomate. (f) Evolução temporal do σ_{VH}^0 do tomate. (g) Evolução temporal do σ_{VV}^0 das pastagens permanentes. (h) Evolução temporal do σ_{VH}^0 das pastagens permanentes. ...	50
Figura 5.4 – (a) Tendência media do σ_{VV}^0 das imagens de órbita ascendente. (b) Tendência media do σ_{VV}^0 das imagens de órbita descendente. (c) Tendência media do σ_{VH}^0 das imagens de órbita ascendente. (d) Tendência media do σ_{VH}^0 das imagens de órbita descendente.....	51
Figura 5.5 – Evolução da precisão global da classificação multitemporal.....	55
Figura 5.6 – Mapa de culturas.....	56

Índice de Tabelas

Tabela 3.1 – Bandas utilizadas em SAR, frequências e comprimentos de onda [Moreira <i>et al.</i> , 2013].	13
Tabela 3.2 – Modos de polarização, adaptado de CCRS [2015b].	22
Tabela 3.3 – Parâmetros dos modos de aquisição da missão Sentinel-1 [ESA, 2013].	26
Tabela 3.4 – Aplicações dos modos de aquisição da missão Sentinel-1 [ESA, 2013].	27
Tabela 3.5 – Desempenho da classificação segundo o coeficiente <i>Kappa</i> , adaptado de Landis e Koch [1977].	35
Tabela 4.1 – Datas e dias do ano das imagens Landsat-8 utilizadas.	39
Tabela 4.2 – Principais características das imagens Landsat-8 [USGS, 2015].	40
Tabela 4.3 – Datas e dias do ano das imagens Sentinel-1 utilizadas.	40
Tabela 4.4 – Principais características das imagens SLC do modo IW da missão Sentinel-1 [ESA, 2013].	41
Tabela 4.5 – Número de amostras de treino e validação para cada classe.	43
Tabela 4.6 – Combinações testadas na classificação.	45
Tabela 5.1 – Ângulos incidentes e tipo de órbita para cada imagem SAR.	49
Tabela 5.2 – Precisão Global e coeficientes <i>Kappa</i> para as combinações testadas.	52
Tabela 5.3 – Matriz de Confusão (%).	54
Tabela 5.4 – Precisões do Utilizador e Produtor (%).	54

Lista de Abreviaturas e Acrónimos

CSA	<i>Canadian Space Agency</i> (Agência Espacial Canadiana)
DOY	<i>Day Of the Year</i> (Dia do Ano)
DR	Deteção Remota
ENVISAT	<i>Environmental Satellite</i>
ERS	<i>European Remote Sensing</i>
ESA	<i>European Space Agency</i> (Agência Espacial Europeia)
ETRS89/PT-TM06	<i>European Terrestrial Reference System 1989/Portugal Transverse Mercator 2006</i>
EW	<i>Extra Wide Swath</i>
GRD	<i>Ground Range Detected</i>
IFAP	Instituto de Financiamento da Agricultura e Pescas
IW	<i>Interferometric Wide Swath</i>
LUTs	<i>Look Up Tables</i>
ML	<i>Maximum Likelihood</i> (Máxima Verosimilhança)
NDVI	<i>Normalized Difference Vegetation Index</i> (Índice de Vegetação de Diferença Normalizada)
NN	<i>Neural Network</i> (Redes Neurais)
OCN	<i>Ocean</i>
OCW	<i>Ocean Wind Field</i>
OLI	<i>Operational Land Imager</i>
OSW	<i>Ocean Swell Spectra</i>
PG	Precisão Global
PP	Precisão do Produtor

PU	Precisão do Utilizador
RADAR	<i>Radio Detection And Ranging</i>
RBF	<i>Radial Basis Function</i>
SAR	<i>Synthetic Aperture Radar</i>
ScanSAR	<i>Scanning SAR</i>
SIP	Sistema de Identificação de Parcelas
SLC	<i>Single Look Complex</i>
SM	<i>Stripmap</i>
SNAP	<i>Sentinel Application Plataform</i>
SPOT	<i>Satellite Pour l'Observation de la Terre</i>
SRTM	<i>Shuttle Radar Topography Mission</i>
SRV	<i>Surface Radial Velocity</i>
SVM	<i>Support Vector Machine</i> (Máquina de Suporte Vetorial)
TOPSAR	<i>Terrain Observation by Progressive Scans SAR</i>
USGS	<i>United States Geological Survey</i>
WSG84	<i>World Geodetic System 1984</i>
WV	<i>Wave</i>

1. Introdução

1.1. Enquadramento

Uma das principais áreas de aplicação da Detecção Remota (DR) é a agricultura. Esta ciência oferece um meio eficiente e confiável de adquirir a informação requerida para a identificação de culturas, a avaliação do estado das colheitas, a estimativa de produtividade, o mapeamento das características do solo e a monitorização de práticas agrícolas [CCRS, 2015a].

A discriminação de culturas é uma etapa crítica para a maioria dos sistemas de monitorização agrícola. A capacidade de identificar o tipo de cultura torna possível a estimação da área associada a cada tipo de cultura e obter variáveis estatísticas essenciais para o controle de culturas, nomeadamente em áreas subsidiadas, e o fornecimento de dados de entrada para modelos de previsão de produção agrícola [Blaes *et al.*, 2005].

Para a identificação precisa do solo em zonas agrícolas de grandes dimensões são necessárias imagens de DR com alta resolução espacial e temporal [Dusseux *et al.*, 2014]. Apesar das imagens óticas proporcionarem uma resolução espacial adequada, a resolução temporal fica muito aquém do necessário. A data e frequência de aquisição de imagens são críticas, dado que a identificação dos tipos de culturas depende da disponibilidade de imagens em fases específicas do seu ciclo de crescimento, o que nem sempre é possível com as imagens óticas devido às suas limitações no que diz respeito à frequência temporal das imagens e à existência de cobertura de nuvens. Estas limitações têm vindo a ser ultrapassadas pela utilização conjunta de imagens óticas e RADAR (*Radio Detection And Ranging*), assim como de produtos resultantes da fusão destes dois tipos de imagens [Fonseca e Fernandes, 2004].

Em estudos de aplicações agrícolas têm sido utilizadas imagens provenientes de diversas missões, tais como, as missões de média resolução espacial Landsat [McNairn *et al.*, 2009; Dusseux *et al.*, 2014; Stefanski *et al.*, 2014; Zheng *et al.*, 2015], e as missões de alta resolução espacial SPOT (*Satellite Pour l'Observation de la Terre*) [McNairn *et al.*, 2009; Dusseux *et al.*, 2014] e RapidEye [Forkuor *et al.*, 2014]. Particularmente, as imagens Landsat são bastante utilizadas devido à sua distribuição gratuita. Desde o início do lançamento do seu primeiro satélite, os dados do programa Landsat tornaram-se a primeira fonte de observação da Terra de média resolução espacial para uma ampla variedade de aplicações [Drusch *et al.*, 2012]. A mais recente missão Landsat-8 estende a aquisição de 40 anos do registo Landsat e possui capacidades melhoradas, incluindo novas bandas espectrais (*Coastal aerosol* e *Cirrus*) captadas pelo sensor OLI (*Operational Land Imager*) [Roy *et al.*, 2014].

Os sistemas de SAR (*Synthetic Aperture Radar*) contrariamente aos sistemas óticos passivos são sistemas ativos RADAR na região das micro-ondas do espectro eletromagnético, possuindo a capacidade de observar a superfície terrestre a qualquer altura do dia sob quaisquer condições meteorológicas [Lee e Pottier, 2009; Atwood *et al.*, 2012; Moreira *et al.*, 2013; Ouchi, 2013; Forkuor *et al.*, 2014; Jin *et al.*, 2014]. Tal, torna os sistemas RADAR altamente viáveis em termos de provisão de dados, especialmente durante os períodos em que os sensores óticos falham [Forkuor *et al.*, 2014]. Além disso, os sinais RADAR são sensíveis às propriedades do solo (humidade e rugosidade) e da vegetação (estrutura e biomassa), proporcionando informação adicional dos tipos de cobertura do solo, relativamente à obtida através de imagens óticas [Jin *et al.*, 2014].

Em estudos de identificação e monitorização de culturas agrícolas, tem sido utilizada uma vasta gama de imagens no domínio do SAR, tais como as imagens TerraSAR-X [Bargiel e Herrmann, 2011; Forkuor *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014a; Sonobe *et al.*, 2014b], as ENVISAT (*Environmental Satellite*) [Karjalainen *et al.*, 2008, McNairn *et al.*, 2009; Iyyappan *et al.*, 20014], as RADARSAT [McNairn *et al.*, 2009, Dusseux *et al.*, 2014] e as ERS (*European Remote Sensing*) [Stefanski *et al.*, 2014]. As novas imagens da missão da Agência Espacial Europeia (ESA – *European Space Agency*) Sentinel-1 são distribuídas gratuitamente e visam oferecer novas perspetivas para este tipo de aplicações.

As imagens da missão Sentinel-1 são adquiridas na banda C nos modos de polarização única (HH ou VV) ou dupla (HH/HV ou VV/VH) com uma alta resolução espacial e temporal, reunindo diversas características favoráveis à identificação de culturas agrícolas. O fato desta imagens serem adquiridas com uma alta resolução espacial e temporal revela-se importante neste tipo de aplicações, como referido anteriormente. O modo de dupla polarização VV/VH é mencionado em alguns estudos [McNairn *et al.*, 2009; Forkuor *et al.*, 2014] como útil na identificação de culturas. Os comprimentos de onda curtos, como é o caso da banda C, são comparáveis com a dimensão das folhas e dos caules das culturas de cereais [Karjalainen *et al.*, 2008]. Estes comprimentos de onda são refletidos a partir do topo da cobertura vegetal e são mais eficientes no reconhecimento de alvos de pequenas dimensões [Parker, 2012].

1.2. Objetivos

O principal foco deste estudo é a avaliação da potencialidade das imagens SAR Sentinel-1 para a identificação de culturas na zona agrícola de Vila Franca de Xira, através da combinação de informação derivada destas imagens com imagens óticas Landsat-8. Para tal, avaliou-se qual o algoritmo, Máxima Verosimilhança (ML – *Maximum Likelihood*), Redes Neurais (NN – *Neural Network*) e Máquina de Suporte Vetorial (SVM - *Support Vector Machine*), e que combinação de parâmetros (óticos e SAR) permitem produzir melhores resultados na classificação. Posteriormente, a partir da combinação e classificador selecionados realizou-se a classificação multitemporal.

Adicionalmente, efetuou-se o estudo da fenologia das culturas através dos coeficientes de retrodispersão e do Índice de Vegetação de Diferença Normalizada (NDVI – *Normalized Difference Vegetation Index*). Avaliou-se o comportamento das diferentes culturas para estas variáveis e verificou-se se era possível identificar as diferentes fases fenológicas.

1.3. Estrutura da tese

O presente documento encontra-se estruturado em seis capítulos, divididos em subcapítulos. No primeiro capítulo é efetuado um enquadramento ao trabalho realizado e são apresentados os objetivos a cumprir. O segundo capítulo destina-se ao estado de arte, abordado a metodologia utilizada e resultados obtidos na literatura revista de forma a fundamentar o trabalho realizado. No capítulo seguinte é realizada uma abordagem aos vários conceitos teóricos relevantes para a compreensão do trabalho desenvolvido. De seguida, no capítulo quatro é feita a caracterização da área de estudo e são apresentados os dados e metodologia utilizada para a realização do trabalho. No capítulo cinco são apresentados os resultados obtidos e é realizada uma análise aos mesmos. Por fim, no último capítulo são tecidas algumas conclusões relativas aos resultados obtidos e apresentadas algumas perspetivas de desenvolvimentos futuros.

2. Estado da Arte

Devido às vantagens que as imagens SAR proporcionam a aplicações de identificação e monitorização de culturas agrícolas, têm surgido diversos estudos que recorrem a séries temporais SAR [Karjalainen *et al.*, 2008; Bargiel e Herrmann, 2011; Iyyappan *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014a; Sonobe *et al.*, 2014b] ou a combinação de imagens óticas e SAR [McNairn *et al.*, 2009; Dusseux *et al.*, 2014; Forkuor *et al.*, 2014; Stefanski *et al.*, 2014] para estes fins.

Nos estudos direcionados a análises multisensor são reportadas melhorias significativas na precisão da classificação de culturas, quando integrados dados SAR e óticos. No estudo de McNairn *et al.* [2009], conclui-se que na presença de um número limitado (uma ou duas) de imagens óticas, a adição de duas imagens SAR na classificação permite uma melhoria na precisão global e precisões individuais das culturas. Os resultados obtidos por Dusseux *et al.* [2014] demonstram que a informação derivada das imagens SAR permite uma melhor precisão na discriminação de pastagens e culturas agrícolas, comparativamente aos resultados obtidos pelas variáveis óticas. Também é mencionado por Forkuor *et al.* [2014] que a integração de dados óticos e SAR permite uma melhoria nos resultados obtidos de 10% a 15%, quando comparados com os resultados resultantes da utilização de apenas dados óticos na classificação.

Diversos autores têm constatado que a utilização de imagens adquiridas em várias datas possibilita uma melhoria significativa na classificação de culturas [Karjalainen *et al.*, 2008; McNairn *et al.*, 2009, Long *et al.*, 2013], remetendo para a importância de análises multitemporais neste tipo de estudos. Long *et al.* [2013] referem que modelos multitemporais produzem melhores resultados que dados de uma única data, devido a estes adquirirem diversidade espectral devido às diferenças fenológicas. Karjalainen *et al.* [2008] verificam uma melhoria na precisão global através da adição cumulativa de novas imagens de datas distintas ao processo de classificação.

Geralmente, em estudos de aplicações agrícolas opta-se pela utilização de imagens SAR captadas em bandas de comprimentos de onda curtos, tais como, a banda X [Bargiel e Herrmann, 2011; Forkuor *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014a; Sonobe *et al.*, 2014b] e a banda C [Karjalainen *et al.*, 2008; McNairn *et al.*, 2009; Dusseux *et al.*, 2014; Iyyappan *et al.*, 2014; Stefanski *et al.*, 2014]. O uso destes comprimentos de onda neste tipo de aplicações é valorizado por alguns autores. Segundo Karjalainen *et al.* [2008], o comprimento de onda da banda C é comparável à dimensão das folhas e caules das culturas agrícolas. Adicionalmente, é referido por Parker [2012] que os comprimentos de onda curtos são refletidos a partir do topo da cobertura vegetal e são mais eficientes no reconhecimento de alvos de pequenas dimensões.

Nos estudos multisensor em que são integrados dados multiespectrais e SAR aplicam-se correções geométricas e radiométricas às imagens óticas de acordo com o tipo de sensor utilizado [McNairn *et al.*, 2009; Dusseux *et al.*, 2014; Forkuor *et al.*, 2014; Stefanski *et al.*, 2014]. O pré-processamento das imagens é uma etapa fundamental para garantir o co-registo de todas as imagens e para eliminar os efeitos das condições atmosféricas das diversas imagens adquiridas em épocas distintas.

Quanto às imagens SAR, as etapas mais relevantes do seu processamento são a calibração radiométrica [Karjalainen *et al.*, 2008; McNairn *et al.*, 2009; Bargiel e Herrmann, 2011; Dusseux *et al.*, 2014; Forkuor *et al.*, 2014; Iyyappan *et al.*, 2014; Sonobe *et al.*, 2014a; Sonobe *et al.*, 2014b; Stefanski *et al.*, 2014], o *multilooking* [Mirzae *et al.*, 2014], o filtro de *speckle* [McNairn *et al.*, 2009; Bargiel e Herrmann, 2011; Dusseux *et al.*, 2014; Forkuor *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014a; Stefanski *et al.*, 2014] e a correção de terreno [McNairn *et al.*, 2009; Dusseux *et al.*, 2014; Forkuor *et al.*, 2014; Sonobe *et al.*, 2014b; Stefanski *et al.*, 2014].

A partir das imagens óticas e SAR pode-se extrair diversa informação para a caracterização de culturas agrícolas. Adicionalmente à informação contida nas bandas multiespectrais [McNairn *et al.*, 2009; Forkuor *et al.*, 2014; Stefanski *et al.*, 2014], alguns autores recorrem a informação derivada destas bandas, tais como, o NDVI [Dusseux *et al.*, 2014; Forkuor *et al.*, 2014], variáveis biofísicas [Dusseux *et al.*, 2014], rácios e diferenças entre bandas [Forkuor *et al.*, 2014].

Relativamente às variáveis resultantes das imagens SAR, o coeficiente de retrodispersão, resultante da calibração radiométrica dos números digitais, é o parâmetro mais utilizado para aplicações de identificação de culturas e classificação do uso do solo [Karjalainen *et al.*, 2008; McNairn *et al.*, 2009; Bargiel e Herrmann, 2011; Dusseux *et al.*, 2014; Forkuor *et al.*, 2014; Jin *et al.*, 2014; Iyyappan *et al.*, 2014; Sonobe *et al.*, 2014a; Sonobe *et al.*, 2014b; Stefanski *et al.*, 2014]. A partir dos coeficientes de retrodispersão das polarizações podem-se obter outras variáveis, tais como, rácios [Dusseux *et al.*, 2014; Jin *et al.*, 2014] e diferenças entre polarizações [Jin *et al.*, 2014].

Vários autores utilizam informação derivada de polarimetria SAR, mais concretamente, elementos de matrizes de dispersão, como por exemplo a matriz de Kennaugh [Forkuor *et al.*, 2014] e parâmetros derivados das decomposições Cloude-Pottier [Dusseux *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014b] e Freeman-Durden [Dusseux *et al.*, 2014]. Ainda se podem recorrer a outros parâmetros, tais como, a coerência [Mirzae *et al.*, 2014; Sonobe *et al.*, 2014b] resultante de interferometria SAR e a bandas de análise de componentes principais [Mirzae *et al.*, 2014].

A potencialidade do modo de dupla polarização VV/VH é demonstrada por alguns autores. No trabalho de McNairn *et al.* [2009], a combinação de polarizações VV/VH revela-se a mais adequada para discriminar a maioria das culturas estudadas, quando comparada com outra combinação de polarizações. Forkuor *et al.* [2014] realizam uma análise comparativa das polarizações VV e VH, concluindo que a polarização VV permite uma melhor discriminação das culturas que a polarização VH.

Na literatura revista são utilizados diferentes algoritmos de classificação, nomeadamente, Máxima Verosimilhança [McNairn *et al.*, 2009; Bargiel e Herrmann, 2011; Iyyappan *et al.*, 2014], Redes Neurais [McNairn *et al.*, 2009; Iyyappan *et al.*, 2014], SVM [Dusseux *et al.*, 2014; Iyyappan *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014a], *Random Forest* [Forkuor *et al.*, 2014; Sonobe *et al.*, 2014a; Sonobe *et al.*, 2014b; Stefanski *et al.*, 2014], *Classification and Regression Tree* (CART) [Sonobe *et al.*, 2014a; Sonobe *et al.*, 2014b], Árvore de Decisão [McNairn *et al.*, 2009] e Vizinheiro mais Próximo [Karjalainen *et al.*, 2008].

McNairn *et al.* [2009] reportam que o algoritmo de Redes Neurais apresenta os piores resultados para todos os dados de entrada SAR e óticos, quando comparados com os resultados dos algoritmos de Árvore de Decisão e Máxima Verosimilhança. Semelhantemente a McNairn *et al.* [2009], Iyyappan *et al.* [2014] constataam que o classificador de Redes Neurais apresenta os resultados menos favoráveis, quando comparado com os algoritmos Máxima Verosimilhança e SVM, sendo que este último apresenta melhores resultados em todas as combinações de polarizações testadas. No estudo de Sonobe *et al.*, [2014a], o classificador SVM permite uma precisão global de 95% na classificação de culturas.

3. Conceitos Teóricos

No presente capítulo é realizada uma abordagem dos vários conceitos teóricos relevantes para a compreensão do trabalho desenvolvido. São apresentados os conceitos de Detecção Remota, sensores óticos, RADAR, SAR, classificação supervisionada e a missão Sentinel-1.

3.1. Detecção Remota

A DR é a ciência que trata de métodos de observação da Terra por sensores instalados em plataformas aéreas ou espaciais, permitindo a aquisição de informação sem contacto direto com os alvos à superfície. Isto é realizado através da deteção e armazenamento da energia refletida ou emitida pelos alvos em diferentes regiões espectrais, processamento, análise e aplicação desta informação [Fonseca e Fernandes, 2004; CCRS, 2015a; Ray, 2015]. As principais aplicações desta ciência são: a monitorização ambiental, a deteção e monitorização de mudanças globais, a agricultura, a exploração de recursos naturais, a meteorologia, a cartografia, e a vigilância e reconhecimento militar [Catalão, 2013].

O primeiro requisito para a DR é a existência de uma fonte de energia para iluminar o alvo. Esta energia é em forma de radiação eletromagnética, que consiste na propagação de dois campos (campo elétrico E e campo magnético M) ortogonais entre si que se deslocam à velocidade da luz c (Figura 3.1) [CCRS, 2015a].




Figura 3.1 – Radiação eletromagnética [CCRS, 2015a].

A radiação eletromagnética apresenta duas características importantes: o comprimento de onda e a frequência. O comprimento de onda corresponde ao comprimento de uma onda de ciclo, que pode ser medido como a distância entre duas cristas de onda sucessivas, sendo medido em nanómetros, micrómetros ou centímetros. A frequência refere-se ao número de ciclos de uma onda que passa num ponto fixo por unidade de tempo, sendo medida em hertz [CCRS, 2015a].

O espectro eletromagnético cobre uma vasta gama de comprimentos de onda (Figura 3.2), este vai desde os comprimentos de onda mais curtos (raios Gama e X) aos comprimentos de onda longos

(rádio e micro-ondas) [CCRS, 2015a]. Este é dividido em subintervalos (bandas espectrais) que permitem classificar a radiação eletromagnética [Fonseca e Fernandes, 2004].




Figura 3.2 – Espectro eletromagnético, adaptado de NASA [2013].

Quando a radiação não é absorvida ou dispersada pela atmosfera esta interage com a superfície terrestre através de três formas: absorção, transmissão e reflexão. A energia total incidente pode interagir com a superfície através de uma ou mais destas formas. As proporções de cada forma dependem do comprimento de onda da energia e o material e condição do alvo [CCRS, 2015a].

A absorção sucede-se quando a radiação é absorvida pelo alvo enquanto a transmissão ocorre quando a radiação atravessa o alvo. A reflexão acontece quando a radiação é refletida no alvo e é redirecionada, sendo esta a que tem maior interesse para a DR [CCRS, 2015a].

Existem dois tipos de reflexão, a especular (Figura 3.3a) e a difusa (Figura 3.3b). A primeira ocorre quando se trata de uma superfície lisa e a radiação refletida é dirigida numa única direção, apresentando um comportamento de espelho. A reflexão difusa acontece quando a superfície é rugosa e a energia é refletida uniformemente em quase todas as direções [CCRS, 2015a].




Figura 3.3 – (a) Reflexão especular. (b) Reflexão difusa [CCRS, 2015a]

3.2. Sensores óticos

Os sensores óticos utilizam as regiões do visível, infravermelho próximo e infravermelho de comprimento de onda curto para formarem imagens da superfície da Terra através da detecção da radiação eletromagnética solar refletida pelos alvos na superfície (Figura 3.4) [CRISP, 2001]. Estes são considerados sistemas passivos pois requerem energia solar [Fonseca e Fernandes, 2004]. Estes sistemas podem ser classificados como: pancromáticos, multiespectrais, superespectrais e hiperespectrais [CRISP, 2001].




Figura 3.4 – Princípio básico dos sistemas óticos, adaptado de CRISP [2001].

No caso dos sistemas multiespectrais, o sensor possui multicanais com algumas bandas espectrais. Cada canal é sensível à radiação de uma determinada banda de comprimento de onda, resultando numa imagem de multicamadas que contém tanto o brilho como a informação espectral (cor) dos alvos observados [CRISP, 2001].

Existem dois modos de varrimento dos sistemas óticos a considerar: *whiskbroom* (Figura 3.5a) e *pushbroom* (Figura 3.5b). No primeiro modo, são utilizados vários elementos detetores alinhados com a direção do movimento para efetuar o varrimento paralelo. No modo *pushbroom* é utilizado um vetor linear de sensores com milhares de elementos, alinhados *cross-track* que varrem a totalidade da largura da imagem em paralelo [Catalão, 2013].




Figura 3.5 – (a) Modo *whiskbroom*. (b) Modo *pushbroom* [Catalão, 2013].

3.2.1. Calibração radiométrica

A calibração radiométrica permite a comparação entre imagens adquiridas em datas diferentes ou por sensores distintos. Esta operação permite converter os números digitais da imagem em várias quantidades que permitem esta comparação, como é o caso da refletância espectral [Chander *et al.*, 2009]. A refletância espectral corresponde à razão entre o fluxo radiante (energia total radiada em todas as direções por unidade de tempo) refletido e o incidente [Catalão, 2013].

Segundo Mishra *et al.* [2014], para o caso das imagens do sensor OLI da missão Landsat-8, os números digitais são convertidos em refletância espectral ao nível do topo da atmosfera, ρ'_λ , a partir da Equação 3.1:

$$\rho'_\lambda = M_\rho \times Q_{cal} + A_\rho \quad (3.1)$$

onde, M_ρ e A_ρ são respetivamente os fatores multiplicativo e aditivo de uma dada banda e Q_{cal} ¹ o valor do píxel calibrado.

Aplicando uma correção para o ângulo zenital solar, θ_{SZA} , a refletância espectral ao nível do topo da atmosfera, ρ_λ , é obtida através da Equação 3.2 [Mishra *et al.*, 2014].

$$\rho_\lambda = \frac{\rho'_\lambda}{\cos(\theta_{SZA})} \quad (3.2)$$

Quando se comparam imagens de diferentes sensores, existem três vantagens em utilizar a refletância ao nível do topo da atmosfera. Em primeiro lugar, esta remove o efeito do cosseno dos diferentes ângulos zenitais solares devido às diferentes horas de aquisição das imagens. A refletância espectral também permite compensar os diferentes valores de irradiância solar exoatmosférica provenientes das várias bandas espectrais. Por último, esta corrige a variação da distância Terra-Sol entre as diferentes datas de aquisição [Chander *et al.*, 2009].

3.2.2. Interação da radiação com a vegetação e Índice de Vegetação de Diferença Normalizada (NDVI)

As folhas da vegetação apresentam um composto químico denominado de clorofila que absorve os comprimentos de onda vermelhos e azuis mas reflete os comprimentos de onda verdes. Dependendo da época do ano o teor do composto altera-se, resultando na variação da percentagem

¹ Estes valores correspondem aos números digitais presentes nos produtos Landsat de nível 1 [Chander *et al.*, 2009].

de absorção dos comprimentos de onda vermelhos. A estrutura interna das folhas saudáveis atua como um excelente refletor difuso dos comprimentos de onda infravermelhos [CCRS, 2015a].

Os índices de vegetação, como é o caso do NDVI, permitem discriminar diferentes tipos e estados de vegetação. Estes índices baseiam-se no facto da vegetação vigorosa apresentar refletâncias altas no infravermelho e refletâncias baixas na banda vermelha do visível, e a vegetação morta apresentar refletâncias equivalentes nestas bandas. Assim, as diferenças radiométricas, entre vegetação vigorosa e morta acentuam-se na razão entre as bandas, permitindo uma melhor diferenciação destes dois tipos de cobertura do solo [Fonseca e Fernandes, 2004].

Segundo Rouse *et al.* [1974], o NDVI é calculado a partir das refletâncias espectral ao nível do topo da atmosfera das bandas de vermelho (ρ_{red}) e infravermelho (ρ_{nir}) através da Equação 3.3:

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (3.3)$$

3.3. SAR

Atualmente, os sistemas SAR são uma técnica de DR bem desenvolvida e coerente, permitindo adquirir imagens 2D de grande escala e alta resolução espacial da superfície da terra. Estes são sistemas ativos RADAR que operam na região das micro-ondas do espectro eletromagnético, geralmente entre a banda P e a banda Ka [Lee e Pottier, 2009]. Na Tabela 3.1 estão listadas as bandas de frequência habitualmente utilizadas em SAR e os respetivos intervalos de comprimento de onda.

Tabela 3.1 – Bandas utilizadas em SAR, frequências e comprimentos de onda [Moreira *et al.*, 2013].

Banda	Frequência [GHz]	Comprimento de Onda [cm]
Ka	40 - 25	0,75 - 1,2
Ku	17,6 - 12	1,7 - 2,5
X	12 - 7,5	2,5 - 4
C	7,5 - 3,75	4 - 8
S	3,75 - 2	8 - 15
L	2 - 1	15 - 30
P	60 - 120	60 - 120

Contrariamente aos sistemas passivos óticos, os sistemas ativos RADAR possuem a sua própria fonte de energia. Estes sistemas transmitem ondas rádio na zona de micro-ondas do espectro eletromagnético e recebem os ecos refletidos a partir dos objetos na superfície terrestre. Devido às suas características inerentes, os sistemas SAR têm a capacidade de observar a superfície terrestre a qualquer altura do dia sob quaisquer condições meteorológicas [Lee e Pottier, 2009; Atwood *et al.*, 2012; Moreira *et al.*, 2013; Ouchi, 2013; Forkuor *et al.*, 2014; Jin *et al.*, 2014].

Além disso, os sinais RADAR têm sensibilidade às propriedades do solo (humidade e rugosidade) e vegetação (estrutura e biomassa), proporcionando informação adicional dos tipos de cobertura do solo, relativamente à informação obtida através de imagens óticas [Jin *et al.*, 2014].

3.3.1. Conceito de RADAR

O princípio de geração de imagem dos sistemas RADAR é fundamentalmente diferente do que se verifica nos sistemas que operam nas zonas visível e infravermelho do espectro eletromagnético, resultando em imagens com características relativamente distintas. [Zyl e Kim, 2010].

Um sistema RADAR consta de um detetor que transmite um sinal eletromagnético de micro-ondas em direção ao alvo e deteta a porção reenviada do sinal. A intensidade do sinal reenviado é medida para discriminar os diferentes objetos e o intervalo de tempo entre os sinais transmitido e refletido permite determinar a distância ao alvo ou alcance (*range*) [Fonseca e Fernandes, 2004].

Este sistema é constituído essencialmente por um transmissor, um recetor, uma antena e um sistema eletrónico para processar e registar os dados. Como se pode verificar na Figura 3.6, a aquisição de dados faz-se do seguinte modo: o transmissor gera curtos pulsos sucessivos de micro-ondas (A), em intervalos regulares, que são focados pela antena num feixe. A antena recebe uma porção da energia transmitida, retrodispersada de vários objetos (B). Medindo o intervalo de tempo entre o pulso e a receção do eco retrodispersado de diferentes alvos, pode-se determinar a sua distância em relação ao sistema RADAR e a sua posição. Conforme a plataforma se desloca na sua trajetória, registando e processando os sinais retrodispersados, é construída uma imagem bidimensional [Fonseca e Fernandes, 2004].




Figura 3.6 – Representação simplificada da aquisição de Imagens RADAR [Fonseca e Fernandes, 2004].

3.3.2. Geometria de aquisição das Imagens RADAR e resolução espacial

Os sistemas RADAR operam utilizando uma geometria lateral (*side-looking*) (Figura 3.7). A plataforma progride na trajetória do satélite (A), com o nadir (B) a definir o traço de órbita na superfície terrestre. O feixe micro-ondas é transmitido obliquamente, num ângulo perpendicular à direção da trajetória, iluminando uma faixa (*swath*) (C) afastada do nadir. O alcance (D) refere-se à dimensão da faixa, perpendicular à direção da trajetória do satélite, enquanto que o azimuth (E) consiste na dimensão, ao longo da faixa, paralela à direção de trajetória. A porção da faixa da imagem mais próxima do traço nadiral da plataforma é designada por alcance próximo (*near range*), enquanto que a parte da faixa mais afastada do nadir é designada por alcance afastado (*far range*) [Fonseca e Fernandes, 2004].

O ângulo de incidência corresponde ao ângulo entre a vertical de lugar e o feixe RADAR. O ângulo de vista é o ângulo de iluminação da superfície. Em todas as incidências do alcance, o RADAR mede o comprimento da linha de vista entre o RADAR e cada alvo na superfície. Este é o alcance oblíquo (*slant range*) ou distância oblíqua [Fonseca e Fernandes, 2004].




Figura 3.7 – Geometria de Aquisição da Imagem RADAR [Fonseca e Fernandes, 2004].

Contrariamente ao que ocorre nos sistemas óticos, a resolução espacial RADAR é uma função das propriedades específicas da radiação de micro-ondas e dos efeitos geométricos. Considerando um RADAR de abertura real, a resolução depende do comprimento efetivo do pulso na direção do alcance oblíquo e da largura de iluminação da direção azimuthal. A resolução de alcance é

dependente da duração do pulso, enquanto a resolução azimutal no terreno é determinada pela abertura angular azimutal do feixe de micro-ondas emitido [Fonseca e Fernandes, 2004].

3.3.3. Conceito de SAR

Os sistemas SAR são uma implementação específica dos sistemas RADAR que utiliza o movimento da plataforma e processamento especializado de sinal para gerar imagens de alta resolução [Zyl e Kim, 2010]. Semelhantemente aos sistemas RADAR convencionais, as ondas eletromagnéticas são sequencialmente transmitidas e os ecos retrodispersados são registrados pela antena. No caso do SAR o tempo consecutivo da transmissão/recepção traduz-se em diferentes posições devido ao movimento da plataforma. Uma combinação coerente dos sinais recebidos permite construir uma abertura sintética que é mais longa que o comprimento da antena física [Moreira *et al.*, 2013].

A largura do feixe do RADAR é inversamente proporcional ao comprimento da antena (abertura), o que significa que uma antena com maior comprimento produz um feixe mais estreito e, logo, uma resolução azimutal mais fina [Fonseca e Fernandes, 2004].

Na Figura 3.8 é mostrado como se atinge este objetivo: quando um alvo (A) entra no feixe de RADAR (1), os ecos retrodispersados de cada pulso transmitido começam a ser registrados. Enquanto a plataforma se move na sua trajetória, são registrados todos os ecos do alvo, para cada pulso, durante todo o intervalo de tempo que o alvo está ao alcance do feixe. O ponto no qual o alvo deixa o feixe (2) determina o tamanho da antena simulada (B) ou sintetizada [Fonseca e Fernandes, 2004].




Figura 3.8 – Synthetic Aperture RADAR [Fonseca e Fernandes, 2004].

As imagens geradas por sistemas SAR correspondem a uma matriz bidimensional de píxeis formada por linhas e colunas, onde cada píxel está associado a uma pequena área da superfície da terra. A dimensão do píxel depende somente das características do sistema SAR. Cada píxel

guarda um número complexo (informação da amplitude e fase) associado à refletividade de todos os elementos dispersores contidos na resolução da célula SAR [Lee e Pottier, 2009].

3.3.4. Calibração radiométrica e coeficiente de retrodispersão

Para uma utilização adequada dos dados SAR, estes devem ser calibrados. Tal é particularmente importante em análises multitemporais [Koppe *et al.*, 2013]. Especialmente quando são utilizadas várias imagens com ângulos de inclinação e níveis de brilho relativamente diferentes [ESA, 2015a]. Segundo ESA [2015b], a calibração radiométrica converte os números digitais dos píxeis da imagem SAR em valores de retrodispersão radiometricamente calibrados. No caso das imagens SLC (*Single Look Complex*) da missão Sentinel-1, o número digital DN de um dado píxel i pode ser calibrado através da Equação 3.4:

$$value(i) = \frac{|DN_i|^2}{A_i^2} \quad (3.4)$$

Dependendo do tipo de coeficiente de retrodispersão que se pretende obter, $value(i)$ pode ser *beta naught* β_i^0 , *sigma naught* σ_i^0 ou *gamma naught* γ_i^0 . A informação necessária (A_i) para efetuar a conversão de DN numa das três convenções, encontra-se nas LUTs (*Look Up Tables*) de calibração dos produtos de Nível-1². As LUTs permitem fazer a conversão através da aplicação do intervalo de ganho dependente (*range dependent gain*) e incluem a constante de calibração absoluta necessária a esta operação. Para qualquer píxel i que se encontre entre dois pontos da LUT é feita uma interpolação bilinear para encontrar o valor correspondente a esse píxel [ESA, 2015a].

As três convenções de coeficiente de retrodispersão, β^0 , σ^0 e γ^0 têm em conta áreas de referência de retrodispersão distintas (Figura 3.9), sendo que β^0 considera o plano do alcance inclinado (com a área A_β), σ^0 tem em conta o terreno modelado por um elipsoide terrestre (com a área A_σ) e γ^0 refere-se ao plano perpendicular à direção de visada local (com a área A_γ). A intensidade depende do ângulo incidência θ , em cada uma das três convenções. Esta tendência é mais forte na abordagem β^0 , sendo reduzida mas ainda presente em σ^0 e ainda mais reduzida em γ^0 [Atwood *et al.*, 2012].

² Na secção 3.4.2 é realizada uma abordagem dos vários níveis produtos da missão Sentinel-1.




Figura 3.9 – Áreas de referência de retrodispensão, adaptado de Atwood *et al.* [2012].

Os valores resultantes da equação 3.4 encontram-se em *power scale* e podem ser convertidos em decibéis através da Equação 3.5 [ASF, 2015]:

$$dB = 10 \log_{10}(\text{power scale}) \quad (3.5)$$

3.3.5. Ruído de Speckle, multilooking e filtro especial

Todas as imagens RADAR têm um grau de *speckle*. Este ocorre devido à interferência construtiva e destrutiva aleatória dos múltiplos ecos de dispersão que ocorrem em cada célula. O *speckle* é essencialmente uma forma de ruído que degrada a qualidade da imagem e pode dificultar a sua interpretação. A redução do ruído de *speckle* pode ser conseguida através de *multilooking* ou de um filtro espacial [CCRS, 2015a].

O processo de *multilooking* refere-se à divisão do feixe RADAR em vários subfeixes e cada um dos subfeixes proporciona um *look* independente [CCRS, 2015a]. Este processo pode ser utilizado para produzir uma imagem com um píxel de dimensão nominal. Os múltiplos *looks* são gerados através da média das células, melhorando a resolução radiométrica mas degradando a resolução espacial. Como resultado, a imagem apresenta menos ruído e um espaçamento de píxel aproximadamente quadrado, tendo sido convertida de um alcance oblíquo para um alcance no terreno [ESA, 2015a].

O filtro espacial consiste no movimento de um elemento estruturante sobre a imagem, aplicando uma operação (exemplo: média) utilizando os valores dos píxeis sob o elemento estruturante e substituindo o píxel central da imagem pelo novo valor. O elemento estruturante percorre toda a imagem, obtendo-se uma imagem mais suave devido à redução do ruído. Tal como o processo de *multilooking*, a resolução espacial é degradada [CCRS, 2015a].

3.3.6. Distorções geométricas e correções de terreno

Devido às variações topográficas e à geometria de aquisição lateral do sensor, as distâncias representadas nas imagens SAR podem sofrer distorções. Estas distorções verificam-se nos objetos que não se encontram diretamente na posição nadiral do sensor. Na Figura 3.10 encontra-se representada a geometria destas distorções. O ponto B acima do elipsoide é representado na imagem SAR na posição B' , apesar da sua representação real ser a posição B'' . A distância Δr entre B' e B'' representa o efeito da distorção geométrica [ESA, 2015c].




Figura 3.10 – Distorção de distâncias nas imagens SAR, adaptado de ESA [2015c]

Para compensar as distorções geométricas são aplicadas correções de terreno que permitem que a representação geométrica da imagem seja o mais próximo possível da realidade [ESA, 2015c]. A correção de terreno geocodifica a imagem SAR através da correção das distorções geométricas, utilizando um modelo digital de terreno. Esta permite corrigir os efeitos associados às distorções geométricas, tais como, o encurtamento (*foreshortening*), o cavalgamento (*layover*) e a sombra [ESA, 2015a].

Quando o feixe RADAR atinge a base de um alvo que se desenvolve em altitude antes de atingir o seu topo, ocorre o efeito de encurtamento. Por outro lado, devido ao RADAR medir a distância oblíqua, o declive aparece comprimido e consequentemente é representado incorretamente. A intensidade do encurtamento varia de acordo com a relação entre o ângulo de inclinação da encosta e o ângulo de incidência do feixe RADAR [Fernandes e Fonseca, 2004].

O efeito de cavalgamento ocorre quando o feixe atinge o topo de um alvo antes de atingir a base. O sinal de retorno do topo do alvo é recebido antes do sinal proveniente da base. Devido a isto, o topo do alvo é deslocado na direção do RADAR em relação à sua posição verdadeira no solo. Tal como o encurtamento, o cavalgamento é maior para pequenos ângulos de incidência, no alcance próximo da faixa de aquisição da imagem [Fernandes e Fonseca, 2004].

As sombras ocorrem, na direção do alcance afastado, atrás de acidentes verticais ou declives muito acentuados. Dado que o feixe RADAR não ilumina a superfície, as zonas de sombra aparecem como zonas escuras na imagem, dado que não existe energia retrodispersada pela superfície terrestre [Fernandes e Fonseca, 2004]. Na Figura 3.11 podem-se verificar os três efeitos geométricos.




Figura 3.11 – Efeitos geométricos das imagens SAR, adaptado de ESA [2015a].

3.3.7. Polarização nos sistemas RADAR

Geralmente, quando uma onda eletromagnética é emitida de uma fonte, como uma antena RADAR, esta propaga-se em todas as direções disponíveis com uma intensidade e fase em cada direção. A uma distância considerável da antena, pode-se assumir que a frente de onda se encontra sobre um plano [CCRS, 2015b].

Por convenção, considera-se meramente a componente campo elétrico, sendo que ambas as componentes estão relacionadas entre si e é sempre possível determinar o campo magnético a partir do campo elétrico. Como tal, a onda eletromagnética pode ser caracterizada pelo comportamento do vetor de campo elétrico ao longo do tempo [CCRS, 2015b].

A propagação da onda plana eletromagnética (Figura 3.12) é descrita num espaço tridimensional com coordenadas dadas pelos três eixos x , y e z . O eixo z encontra-se na direção da propagação, enquanto x e y estão no plano perpendicular à direção de propagação. O vetor de campo elétrico

(a vermelho) é formado pela componente horizontal (a verde) e componente vertical (a azul) [CCRS, 2015b].




Figura 3.12 – Propagação da onda eletromagnética, adaptado de ESA [2015d].

A polarização é uma propriedade importante da onda plana do campo eletromagnético. Esta refere-se à orientação e forma do padrão traçado pela extremidade do vetor de campo elétrico no plano perpendicular à direção de propagação [CCRS, 2015b].

Muitos sistemas RADAR são concebidos para transmitir radiação micro-ondas com polarização horizontal (H) ou vertical (V) (Figura 3.13). Quando uma onda horizontalmente polarizada incide num alvo, a onda retrodispersada pode ter contribuições em ambas as polarizações horizontal ou vertical, o mesmo acontece no caso de uma onda incidente de polarização vertical. É a análise das combinações de polarizações transmitidas e recebidas que constitui a ciência da polarimetria RADAR [CCRS, 2015b].




Figura 3.13 – Polarização horizontal e vertical da onda plana eletromagnética [CCRS, 2015b].

Qualquer polarização em transmissão ou receção pode ser sintetizada utilizando as componentes H e V, que têm uma relação bem definida entre si. Por esta razão, sistemas que transmitem ambas as polarizações lineares são normalmente utilizados [CCRS, 2015b].

Com estes sistemas RADAR, podem existir quatro combinações de polarizações transmitidas e recebidas:

- HH – horizontal transmitida e horizontal recebida;
- VV – vertical transmitida e vertical recebida;
- HV – horizontal transmitida e vertical recebida;
- VH – vertical transmitida e horizontal recebida.

As duas primeiras combinações de polarização são referidas como “*like-polarized*” devido às polarizações de transmissão e recepção serem as mesmas. As duas últimas combinações são “*cross-polarized*” pois as polarizações de recepção e transmissão são ortogonais entre si [CCRS, 2015b].

Os sistemas RADAR podem ter uma, duas ou todas as quatro combinações de polarização transmitidas/recebidas. Na Tabela 3.2 podem-se visualizar os diferentes modos de polarização existentes nos sistemas RADAR [CCRS, 2015b].

Tabela 3.2 – Modos de polarização, adaptado de CCRS [2015b].

Modo	Polarizações
Polarização única	HH, VV, HV ou VH
Polarização dupla	HH/HV, VV/VH ou HH e VV
Polarização alternada	HH/HV, alternado com VV e VH
Totalmente polarizado	HH, VV, HV e VH

3.4. Missão Sentinel-1

A missão Sentinel-1 (Figura 3.14) é composta por uma constelação de dois satélites de órbita polar, Sentinel-1A (operacional) e Sentinel-1B (lançamento planeado para 2016), que operam na banda C de dia e de noite para a obtenção de imagens SAR, independentemente das condições meteorológicas.

Esta missão é projetada para funcionar num modo de operação pré-programado para evitar conflitos, obtendo imagens a nível global das massas terrestres, zonas costeiras e rotas marítimas com alta resolução temporal e espacial. Assim é garantida a confiabilidade de serviço requerido para serviços operacionais e a construção a longo prazo de um arquivo de dados consistente para aplicações baseadas em longas séries temporais. Os dados adquiridos por esta missão são disponibilizados gratuitamente de modo a promover o aumento da investigação científica, o crescimento de mercados de observação da terra e a criação de emprego [ESA, 2013].



Figura 3.14 – Sentinel-1 [ESA, 2013].

A presente missão tem como legado as missões da ESA ERS e ENVISAT e a missão da Agência Espacial do Canadá (CSA – *Canadian Space Agency*) RADARSAT, continuando a observação SAR da superfície terrestre na banda C [ESA, 2013].

A missão Sentinel-1 pretende beneficiar diversos serviços relacionados com variadas áreas, tais como a:

- Monitorização de extensão de gelo marinho do Ártico;
- Cartografia de gelo marinho;
- Vigilância do ambiente marinho;
- Detecção de navios para segurança marítima;
- Detecção de derrames de óleo;
- Monitorização de movimentos da superfície terrestre;
- Monitorização de florestas, água, solo e agricultura;
- Cartografia para ajuda humanitária e situações de crise.

Esta missão pertence à família de satélites a ser desenvolvida pela ESA para a iniciativa Copernicus. Esta é uma iniciativa conjunta da ESA e da Comissão Europeia e tem como objetivo a implementação de serviços de informação direcionados para o ambiente e para a segurança. As missões Sentinel possuem variadas tecnologias, tais como, imagens RADAR e multiespectrais para terra, oceano e monitorização atmosférica. Na Figura 3.15 podem-se observar as várias missões Sentinel previstas e as suas principais aplicações [ESA, 2013].



Figura 3.15 – Missões Sentinel previstas e as suas principais aplicações, com base em informação da ESA [2012].

3.4.1. Características principais e modos de aquisição da missão Sentinel-1

Os satélites Sentinel-1 possuem um tempo de vida de 7 anos (com recursos para 12 anos) e encontram-se numa órbita com 693 km de altitude. A órbita é sincronizada com o sol, quase-polar e circular. Ambos os satélites Sentinel-1A e Sentinel-1B partilham a mesma órbita plana com uma diferença de fase de 180° (Figura 3.16). Cada satélite tem um ciclo de 12 dias e 175 órbitas por ciclo. Estando os dois satélites da constelação operacionais a repetição de ciclo é de 6 dias. A constelação pretende ter uma frequência de repetição (ascendente/descendente) de 3 dias no equador e menos de um dia no Ártico [ESA, 2013].




Figura 3.16 – Constelação Sentinel-1 [ESA, 2013].

Os satélites Sentinel-1 têm incorporado um instrumento SAR que opera na banda C a uma frequência de 5.405 GHz. O sistema tem a capacidade de operar nos modos de dupla polarização

(HH/HV ou VV/VH) e polarização única (HH ou VV) e possui quatro modos de aquisição distintos: SM (*Stripmap Mode*), IW (*Interferometric Wide Swath Mode*), EW (Extra-Wide Swath Mode) e WV (*Wave Mode*). O modo SM adquire os dados com uma faixa de 80 km e uma resolução espacial de 5 m por 5 m. A faixa no terreno é iluminada por uma sequência contínua de pulsos enquanto o feixe da antena é direcionado para um ângulo de azimute fixo e um ângulo *off-nadir* aproximadamente fixo.

O modo SM pode operar com uma de seis elevações de feixe pré-definidas, cada uma com um ângulo incidente distinto. Este modo destina-se apenas a casos excepcionais, como apoio a ações de gestão de emergência [ESA, 2013].

O modo IW é o modo principal de aquisição de dados sobre a terra e satisfaz a maioria das necessidades dos serviços. Os dados são adquiridos com uma faixa de 250 km e uma resolução espacial de 5 m por 20 m. Este modo adquire as imagens em três subfaixas utilizando a técnica TOPSAR³ (*Terrain Observation with Progressive Scans SAR*) [ESA, 2013].

Semelhante ao modo IW, o modo EW utiliza a técnica TOPSAR para adquirir dados de uma área mais ampla utilizando cinco faixas. Este modo adquire dados sobre uma faixa de 400 km com uma resolução espacial de 20 m por 40 m. O modo EW é destinado particularmente para aplicações relacionadas com gelo, monitorização de derrames de óleo e serviços de segurança [ESA, 2013].

O modo WV adquire dados em vinhetas de 20 km por 20 km com uma resolução espacial de 5 m por 5 m, exclusivamente em modo de polarização única (VV ou HH). Este é semelhante aos modos *wave* das missões ERS e ENVISAT, contudo proporciona uma melhor resolução, com vinhetas de maiores dimensões e um novo padrão de aquisição [ESA, 2013].

³ TOPSAR corresponde a uma técnica *Scanning SAR* (ScanSAR), em que os dados são adquiridos em *bursts* através da alternância cíclica do feixe da antena entre múltiplas subfaixas adjacentes [ESA, 2013].

Na Figura 3.17 podem observar-se as diferentes configurações dos quatro modos de aquisição da missão Sentinel-1.




Figura 3.17 – Configuração dos diferentes modos de aquisição [ESA, 2012].

Seguidamente pode-se verificar uma tabela resumo (Tabela 3.3) com um resumo das características dos quatro modos de aquisição da missão Sentinel-1.

Tabela 3.3 – Parâmetros dos modos de aquisição da missão Sentinel-1 [ESA, 2013].

Modo	Ângulo Incidente	Resolução Espacial	Largura de Faixa	Polarização
SM	20° - 45°	5 × 5 m	80 km	HH/HV, VV/VH, HH, VV
IW	29° - 46°	5 × 20 m	250 km	HH/HV, VV/VH, HH, VV
EW	19° - 47°	20 × 40 m	400 km	HH/HV, VV/VH, HH, VV
WV	22° - 35° 35° - 38°	5 × 5 m	20 × 20 km	HH, VV

Os modos de aquisição satisfazem os requisitos de diversas aplicações, sendo que alguns modos se adequam mais eficazmente a umas do que outras (Tabela 3.4).

Tabela 3.4 – Aplicações dos modos de aquisição da missão Sentinel-1 [ESA, 2013].

Aplicação	Modo			
	SM	IW	EW	WV
Ártico e gelo marinho		×	×	
Vigilância de navios em mar aberto		×	×	
Monitorização de poluição de óleo		×	×	
Ventos marítimos				×
Florestas		×		
Agricultura		×		
Cartografia de deformação urbana		×		
Monitorização de inundações	×	×		
Análise de sismos	×	×		
Monitorização de deslizamento de terras e vulcões	×	×		

3.4.2. Tipos de produtos e níveis de processamento

Os produtos Sentinel-1 adquiridos através dos modos SM, IW e EW são distribuídos em três níveis de processamento: Nível-0, Nível-1 e Nível-2. Para o modo WV apenas são distribuídos produtos de Nível-2. Os produtos de Nível-1 podem ser SLC ou GRD (*Ground Range Detected*). Os produtos de Nível-2 OCN (*Ocean*) podem ter diferentes componentes dependentemente do modo de aquisição [ESA, 2013]. Como se pode visualizar na Figura 3.18, os produtos são identificados com base no seu modo de aquisição, tipo de produto e resolução.




Figura 3.18 – Níveis dos produtos dos modos de aquisição da missão Sentinel-1 [ESA, 2013].

Os produtos do Nível-0 consistem em dados SAR brutos comprimidos e não focados que se encontram disponíveis para utilizadores dos modos SM, IW e EW. Estes produtos são a base a partir da qual os produtos de alto nível são produzidos. Para os dados poderem ser utilizados têm de ser descomprimidos e processados utilizando uma aplicação de foco. Os dados de Nível-0 incluem ruído, calibração interna, pacotes de fonte de eco e informações de órbita e atitude [ESA, 2013].

Os produtos de Nível-1 estão geralmente disponíveis para a maioria dos utilizadores. Como referido anteriormente, os produtos de Nível-1 são produzidos como SLC e GRD. Os produtos SLC consistem em dados SAR focados, georreferenciados utilizando dados de órbita e atitude do satélite, e proporcionados em geometria de alcance inclinado em zero-Doppler. Estes produtos consistem em amostras complexas que preservam a informação de fase. Nos modos IW e EW cada subfaixa consiste numa série de *bursts*, em que cada *burst* é processado separadamente como uma imagem SLC única. Os produtos GRD consistem em dados SAR focados, projetados para um alcance no terreno utilizando o modelo de elipsoide terrestre e processados através de *multilooking*. Contrariamente aos produtos SLC, nos produtos GRD a informação de fase é perdida. O produto final possui píxeis de resolução aproximadamente quadrada com redução de *speckle*, degradando a resolução geométrica. Estes produtos são proporcionados em três resoluções: Resolução Total (*Full Resolution*), Alta Resolução (*High Resolution*) e Média Resolução (*Medium Resolution*) [ESA, 2013].

Os produtos de Nível-2 consistem em produtos geofísicos derivados dos produtos de Nível-1. Os produtos Nível-2 OCN podem ser OWI (*Ocean Wind Field*), OSW (*Ocean Swell spectra*) e RVL (*Surface Radial Velocity*). A disponibilidade destas três componentes é dependente do modo de aquisição [ESA, 2013].

3.5. Classificação supervisionada

A classificação supervisionada é um procedimento frequentemente utilizado para análises quantitativas de dados de DR. Esta utiliza algoritmos adequados para classificar os píxeis de uma imagem em classes, que pretendem representar diferentes tipos de uso do solo (Figura 3.19) [Richards e Jia, 2006].

Existem diversos algoritmos disponíveis para este fim, contudo independentemente do método utilizado os principais passos do processo incluem: a seleção das classes a representar, a recolha dos dados de treino (através de visitas de campo, mapas, fotografias aéreas ou fotointerpretação), a estimativa de parâmetros do classificador a ser utilizado através dos dados de treino, a utilização do algoritmo para classificação dos píxeis da imagem nas classes desejadas, a produção de mapas

temáticos ou tabelas de síntese dos resultados obtidos e a avaliação da precisão do produto final utilizando dados de validação [Richards e Jia, 2006].




Figura 3.19 – Classificação dos píxeis da imagem em classes de um mapa temático, adaptado de Richards e Jia [2006].

3.5.1. Máxima Verosimilhança (ML)

O algoritmo de classificação de ML é o método mais comum de classificação supervisionada utilizado em dados de Detecção Remota [Richards e Jia, 2006]. Este método paramétrico pressupõe que as estatísticas para cada classe em cada banda seguem uma distribuição normal para calcular a probabilidade de um dado píxel pertencer a uma classe específica. Cada píxel é atribuído à classe que apresenta maior probabilidade. [Exelis, 2015a]. Segundo Richards e Jia [2006], o algoritmo é implementado através do cálculo das equações discriminantes $g_i(x)$ para cada píxel (Equação 3.6):

$$g_i(x) = \ln p(w_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^T \Sigma_i^{-1} (x - m_i), \quad i = 1, \dots, M \quad (3.6)$$

onde w_i representa a classe espectral (em que M o número máximo de classes), x corresponde ao vetor coluna dos valores dos dados para um determinado píxel nas n bandas, $p(w_i)$ é a probabilidade da classe w_i ocorrer na imagem (considerada igual para todas as classes), $|\Sigma_i|$ corresponde ao determinante da matriz de covariância dos dados na classe w_i , Σ_i^{-1} é a inversa dessa matriz e m_i o vetor médio dos dados na classe w_i .

Através da aplicação da regra de decisão presente na Equação 3.7, comparam-se as diferentes funções discriminantes e determina-se a classe a que o píxel pertence. No desenvolvimento do processo todos os píxeis são classificados numa classe w_i , independentemente de quão pequenos sejam os valores de probabilidade, podendo resultar em classificações fracas. Nestas situações são aplicados limites de

probabilidade, fazendo com que píxeis com probabilidades máximas abaixo dos limites estabelecidos não sejam classificados. Na prática, os limites T_i são aplicados às funções discriminantes, adicionando-se uma premissa (Equação 3.8) à regra de decisão [Richards e Jia, 2006].

$$x \in w_i \quad \text{se} \quad g_i(x) > g_j(x) \quad \text{para todos} \quad j \neq i \quad (3.7)$$

$$\text{e} \quad g_i(x) > T_i \quad (3.8)$$

As vantagens de utilizar o classificador de ML resumem-se ao facto de este ter em conta a variância-covariância dentro das distribuições da classe e de este possuir uma performance mais elevada para dados normalmente distribuídos, que outros classificadores paramétricos. Contudo, para dados que não possuam uma distribuição normal os resultados podem não ser satisfatórios [Otukey e Blaschke, 2010].

3.5.2. Redes Neurais (NN)

Uma rede neuronal é um algoritmo não paramétrico em camadas composto por elementos de processamento, denominados de nós (Figura 3.20). O elemento principal de processamento tem em conta vários dados de entrada, dando origem a um único resultado. Geralmente, o número de dados de entrada é definido pela topologia da rede e pela dimensionalidade dos dados. Segundo Richards e Jia [2006], a operação associada a cada nó é descrita pela Equação 3.9:

$$o = f(w^t x + \theta) \quad (3.9)$$

onde θ é o limite, w o vetor de pesos, x o vetor de dados de entrada (valores das bandas para um determinado píxel) e f a função de ativação. A função f pretende ser diferenciável e promover a limitação de uma forma suave ou assintótica.




Figura 3.20 – Elemento de processamento (EP) de uma rede neuronal, adaptado de Richards e Jia [2006].

Convencionalmente, uma rede neuronal de multicamadas é projetada com uma camada de nós de entrada e uma camada de saída. Entre as camadas inicial e final, podem surgir uma ou mais camadas de nós ocultas ou de processamento. [Richards e Jia, 2006].

Na Figura 3.21 pode-se verificar uma abordagem simplificada de três camadas que são identificadas por i , j e k . A primeira camada destina-se à distribuição das componentes do vetor píxel de entrada a cada um dos elementos de processamento da segunda camada. A camada final

fornece a informação da identificação das classes [Richards e Jia, 2006]. O conjunto de pesos w_{ji} liga os elementos de processamento camada i aos elementos da camada j enquanto w_{kj} liga as camadas j e k [Richards e Jia, 2006].

Antes de ser executada a classificação, a rede sofre um processo de aprendizagem supervisionada, utilizando os dados de treino, através da técnica de retropropagação (*backpropagation*). De uma forma geral, a aprendizagem consiste no ajustamento dos pesos ao nível do nó para minimizar a diferença entre a ativação do nó de saída e o resultado. O erro é retropropagado através da rede e o ajustamento dos pesos é realizado através de um método recursivo [Exelis, 2015b].




Figura 3.21 – Rede Neuronal de multicamadas, adaptado de Richards e Jia [2006].

Quando se considera a utilização de uma abordagem de rede neuronal é necessário ter em conta alguns parâmetros. O número de camadas a utilizar deve ser selecionado, sendo suficiente de um modo geral, uma rede de três camadas [Richards e Jia, 2006].

A contribuição da margem de aprendizagem é outro parâmetro a ter em conta. Este determina a dimensão da contribuição dos pesos internos relativamente ao nível de ativação do nó e é utilizado para ajustar as mudanças dos pesos internos dos nós. A definição deste parâmetro como nulo não ajusta os pesos internos dos nós. O ajustamento dos pesos pode levar à obtenção de melhores resultados na classificação, contudo o número excessivo de pesos pode levar a generalizações fracas [Exelis, 2015b].

Existem outros parâmetros relevantes, tais como, a taxa de treino, a taxa de momento de treino, o critério de paragem e o número de iterações [Exelis, 2015b]. A taxa de treino determina a magnitude de ajustamento dos pesos. Uma taxa elevada acelera o treino, mas aumenta o risco de oscilações e a não convergência do resultado obtido [Exelis, 2015b]. Uma taxa de momento de treino superior a zero permite uma alta taxa de treino sem oscilações. Um valor elevado deste parâmetro permite treinar a rede através de passos maiores quando comparado com um valor baixo [Exelis, 2015b]. Para efetuar a paragem do treino da rede é utilizado um valor de erro quadrático mínimo. Se o erro quadrático for mais baixo que o critério de paragem estabelecido o treino finaliza, mesmo que o número de iterações definido não tenha sido atingido [Exelis, 2015b].

3.5.3. Máquina de Suporte Vetorial (SVM)

O classificador SVM é uma técnica supervisionada não paramétrica de aprendizagem estatística. Este algoritmo mapeia os dados de treino (instâncias identificadas) num espaço de dimensão maior e determina o hiperplano que separa os dados num número pré-definido discreto de classes [Mountrakis, *et al.*, 2011].

Existe um número infinito de hiperplanos que permitem separar os dados, contudo apenas um hiperplano maximiza a margem entre as classes. Este é o hiperplano ótimo e os pontos que limitam a largura da margem são os vetores de suporte [Oommen *et al.*, 2008]. Na Figura 3.22 é apresentado um cenário simplificado de uma classificação de duas classes num espaço bidimensional.




Figura 3.22 – SVM num espaço bidimensional, adaptado de Mountrakis, *et al.* [2011].

Segundo Oommen *et al.* [2008], num cenário que os dados apresentam separabilidade linear, o problema de otimização do algoritmo corresponde ao critério de maximização da margem. Contudo, como na maioria dos casos não existe uma separabilidade linear dos dados (Figura 3.23), o classificador SVM utiliza uma função de *kernel*. Esta função permite que os dados se dispersem de tal forma que um hiperplano linear possa ser ajustado. Assim, o algoritmo requer a resolução do problema de otimização que é uma combinação de dois critérios (maximização da margem e minimização do erro).




Figura 3.23 – Dados não linearmente separáveis, adaptado de Oommen *et al.* [2008].

Existem vários tipos de função de *kernel* (linear, polinomial, *Radial Basis Function* (RBF) e sigmoide). A função RBF tem resultados positivos para a maioria dos casos [Exelis, 2015c] e a sua representação matemática apresenta-se na Equação 3.10, onde γ é a largura do *kernel*, x é um vetor de suporte e x_i é um ponto dos dados de treino [Oommen *et al.*, 2008].

$$\phi = e^{-\gamma \|x - x_i\|^2} \quad (3.10)$$

O algoritmo de SVM utiliza o parâmetro de penalização, que possibilita um certo grau de erro na classificação. Este controla o compromisso entre permitir erros no treino e forçar margens rígidas. Quanto maior o seu valor, mais o parâmetro suprime a mudança de classes dos dados de treino, quando outros parâmetros sofrem alteração. O aumento do valor também aumenta o custo de pontos incorretamente classificados e cria um modelo mais preciso que pode não generalizar corretamente [Exelis, 2015c].

Outro parâmetro relevante é o limite de probabilidade que indica o nível de confiança que os segmentos mais próximos de um dado segmento representam a mesma classe. Valores altos para este parâmetro significam uma maior confiança, resultando somente na classificação dos segmentos mais próximos. Enquanto que valores mais baixos permitem que segmentos mais distantes sejam classificados, sendo a confiança de os segmentos vizinhos pertencerem à mesma classe é menor [Exelis, 2015c].

3.5.4. *Classificação baseada em objetos*

Podem ser considerar duas abordagens distintas de classificação de imagens de DR, a baseada em píxeis e a baseada em objetos. No primeiro caso, a classificação é baseada na análise das características espectrais dos píxeis. Contudo, este método negligencia a informação espacial ou contextual dos píxeis. Na segunda abordagem são classificados objetos em vez de píxeis, considerando a informação espacial e espectral para alcançar uma melhor precisão [Zhang e Jia, 2014].

Como tal, a classificação orientada por objetos assenta numa segmentação da imagem original em aglomerados de píxeis que apresentam características espectrais, espaciais e/ou texturais semelhantes. Os segmentos idealmente correspondem aos objetos do mundo real e uma segmentação eficiente assegura que os resultados da classificação sejam mais precisos [Exelis, 2015d]. Pelo fato de se passar a dispor de objetos é possível calcular bandas sintéticas de parâmetros espectrais, texturais ou espaciais úteis na discriminação das classes, em que os níveis de intensidade são associados a cada objeto [Fonseca e Fernandes, 2004].

3.5.5. *Validação*

A matriz de confusão é um método muito eficaz de representar a precisão de um mapa, em que as precisões individuais de cada classe são claramente descritas [Congalton e Green, 2009]. As colunas desta matriz representam as classes na amostra de referência, e as linhas representam as atribuições realizadas para cada classe da amostra, pelo procedimento utilizado. Desta matriz podem resultar a Precisão Global (PG), a Precisão do Utilizador (PU) e a Precisão do Produtor (PP).

A PG é a estatística mais simples que se pode determinar a partir da matriz de confusão, correspondendo à percentagem de elementos corretamente classificados. Esta é determinada pela razão entre o número de elementos de imagem corretamente classificados (soma da diagonal da matriz) e o número total de elementos da imagem da amostra de referência.

A PP e a PU baseiam-se no pressuposto de que o produtor do mapa temático tem maior preocupação com o rigor do método de atribuição e por outro lado, o utilizador preocupa-se mais com o rigor do mapa temático. A PP mede a probabilidade de um elemento da imagem de referência ser corretamente classificado. Esta corresponde à divisão do número de elementos da imagem corretamente classificados de uma classe (valor na diagonal para essa classe), pelo total de elementos da imagem dessa classe na amostra de referência (soma dos elementos da coluna). A PU é obtida através da divisão do número total de elementos de imagem corretamente

classificados de uma classe (valor na diagonal para essa classe), pelo total de elementos da imagem que foram atribuídos a essa classe (soma dos elementos da linha).

Um outro método que permite avaliar a precisão da classificação é o coeficiente *Kappa*. Segundo Congalton e Green [2009], este avalia a concordância entre os dados de referência e os dados classificados e determina-se a partir da matriz de confusão como se pode verificar na Equação 3.11:

$$Kappa = \frac{n \sum_i n_{ii} - \sum_i (n_{i+} n_{+i})}{n^2 - \sum_i (n_{i+} n_{+i})} \quad (3.11)$$

onde n é o número de píxeis classificados que foram comparados com os dados de referência, i é o número da classe, n_{ii} é o número de píxeis pertencentes à classe de referência i que foram classificados como classe i (diagonal da matriz), n_{+i} é o número total de píxeis classificados pertencentes à classe i e n_{i+} é o número total de píxeis de referência pertencentes à classe i . Segundo Landis e Koch [1977], pode avaliar-se o desempenho de uma classificação segundo os valores do coeficiente *Kappa* obtidos com base nas categorias apresentadas na Tabela 3.5.

Tabela 3.5 – Desempenho da classificação segundo o coeficiente *Kappa*, adaptado de Landis e Koch [1977].

Coeficiente <i>Kappa</i>	Desempenho
< 0%	Muito Fraco
0% - 20%	Fraco
21% - 40%	Razoável
41% - 60%	Moderado
61% - 80%	Considerável
81% - 100%	Muito bom

4. Metodologia

O presente capítulo destina-se à abordagem das diversas etapas da metodologia aplicadas para a realização do trabalho e à caracterização da zona de estudo e dos dados utilizados. A metodologia aplicada divide-se seis etapas: (1) o processamento das imagens Landsat-8 e Sentinel-1, (2) o estudo da fenologia das culturas (3) a integração das imagens das duas fontes, (4) o tratamento e seleção dos dados de treino e validação, (5) a classificação das imagens (6) e a validação dos resultados obtidos (Figura 4.1).




Figura 4.1 – Fluxograma da metodologia utilizada.

Para a realização da metodologia mencionada utilizaram-se diversas aplicações nomeadamente, ENVI 5.1®, Sentinel-1 *toolbox* 1.1.1®, ArcGIS 10.3® e MATLAB R2014b. Na Figura 4.2, apresentam-se as etapas da metodologia em que foi utilizado cada destas aplicações.




Figura 4.2 –Aplicações informáticas e etapas em que foram utilizadas

4.1. Área de estudo

A área de estudo selecionada corresponde à zona da lezíria e mouchões da freguesia de Vila Franca de Xira (Figura 4.3a) do concelho de Vila Franca de Xira⁴ do distrito de Lisboa. A freguesia de Vila Franca de Xira possui uma área de 21286 hectares e é constituída pela lezíria (1), o mouchão de Alhandra (2), o mouchão das Garças (3), o mouchão do Lombo do Tejo (4), o mouchão da Póvoa (5) e uma zona urbana (6) conforme representado na Figura 4.3b.




Figura 4.3 – (a) Área de Estudo. (b) Freguesia de Vila Franca de Xira.

De uma forma geral, o clima do concelho é mediterrânico, apresentando uma estação quente com muitas horas de sol em alternância com uma estação fresca durante a qual se sucedem desordenadamente dias de chuva e aberturas de sol [Plural, 2004]. Na Figura 4.4 está representado um gráfico da temperatura média e precipitação média mensais para o período temporal em estudo (de maio a julho de 2015), tendo em conta os dados registados pela estação meteorológica da Barragem de Magos no concelho de Salvaterra de Magos (estação mais próxima da lezíria). A temperatura média mensal assume valores entre 18,8 °C e 21,7 °C, verificando-se um aumento desta ao longo dos meses do período em estudo. Em relação à precipitação média mensal, esta sofre um decréscimo assumindo valores entre 1,8 mm e 10,5 mm.

⁴ As freguesias do concelho de Vila Franca de Xira estão representadas no Anexo I.




Figura 4.4 – Valores de precipitação média e temperatura média mensais no período de estudo.

Os solos da lezíria são muito férteis devido à sazonalidade das cheias que os enriquecem com matéria orgânica. Por consequente, a exploração agrícola é intensiva, e as principais culturas são temporárias, procedendo-se a dois ciclos de cultura durante o ano agrícola quando possível. Nas culturas temporárias destacam-se as culturas para grão, com especial relevo para as culturas anuais de regadio, tais como o trigo, o milho e o arroz. Na lezíria também surge a exploração de culturas industriais, tais como, o tomate e cultura de forrageiras, associada à exploração pecuária de gado bravo. Nos mouchões existe a presença de pastagens [Plural, 2004].

4.2. Dados utilizados

Tendo em conta o período em estudo (de maio a julho de 2015) selecionaram-se 5 imagens Landsat-8 (Tabela 4.1) da zona de Vila Franca de Xira não afetadas por nuvens. Estas imagens são disponibilizadas gratuitamente pela USGS (*United States Geological Survey*), associadas ao sistema de coordenadas WGS84 (*World Geodetic System 1984*) e são corrigidas geometricamente [Roy et al., 2014]. As suas principais características estão listadas na Tabela 4.2. Da informação disponibilizada, foram utilizadas as bandas do sensor OLI: 2 (Azul), 3 (Verde), 4 (Vermelho), 5 (Infravermelho Próximo), 6 e 7 (Infravermelho de comprimento de onda curto 1 e 2).

Tabela 4.1 – Datas e dias do ano das imagens Landsat-8 utilizadas.

Data	DOY ⁵
25 de maio de 2015	145
10 de junho de 2015	161
26 de junho de 2015	177
12 de julho de 2015	193
28 de julho de 2015	209

⁵ Doy (*Day Of the Year* – Dia do Ano).

Tabela 4.2 – Principais características das imagens Landsat-8 [USGS, 2015].

Missão	Bandas Espectrais	Comprimento de onda (µm)	Resolução Espacial (m)
Landsat-8	<i>Coastal aerosol</i>	0,43 - 0,45	30
	Azul	0,45 - 0,51	30
	Verde	0,53 - 0,59	30
	Vermelho	0,64 - 0,67	30
	Infravermelho Próximo	0,85 - 0,88	30
	Infravermelho de comprimento de onda curto 1	1,57 - 1,65	30
	Infravermelho de comprimento de onda curto 2	2,11 - 2,29	30
	Pancromática	0,50 - 0,68	15
	<i>Cirrus</i>	1,36 - 1,38	30
	Infravermelho Térmico 1	10,60 - 11,19	100 (30) ⁶
	Infravermelho Térmico 2	11,50 - 12,51	100 (30)

Adicionalmente, utilizaram-se 12 imagens SLC do modo de aquisição IW da missão Sentinel-1 com dupla polarização (VV/VH) (Tabela 4.3), disponibilizadas gratuitamente pela ESA. As suas principais características estão listadas na Tabela 4.4.

Tabela 4.3 – Datas e dias do ano das imagens Sentinel-1 utilizadas.

Data	DOY
18 de maio de 2015	138
24 de maio de 2015	144
30 de maio de 2015	150
5 de junho de 2015	156
11 de junho de 2015	162
17 de junho de 2015	168
23 de junho de 2015	174
5 de julho de 2015	186
11 de julho de 2015	192
17 de julho de 2015	198
23 de julho de 2015	204
29 de julho de 2015	210

⁶ As bandas de Infravermelho Térmico são adquiridas com uma resolução de 100 m, mas são reamostradas para 30 m no produto derivado [USGS, 2015].

Tabela 4.4 – Principais características das imagens SLC do modo IW da missão Sentinel-1 [ESA, 2013].

Banda	C
Resolução Espacial	5×20 m
Largura de Faixa	250 km
Modo	Dupla Polarização
Polarização	VV/VH
Ângulo Incidente	$20^\circ - 45^\circ$
Período de Revisita	6 dias

Para a obtenção dos dados de treino e validação utilizou-se a informação do Sistema de identificação de Parcelas do ano 2015 fornecido pelo Sistema de Identificação de Parcelas (SIP), fornecido pelo Instituto de Financiamento da Agricultura e Pescas (IFAP). Esta informação foi disponibilizada em formato vetorial no sistema de coordenadas Hayford-Gauss *Datum 73*.

4.3. Processamento das imagens óticas e SAR

No processamento das imagens Landsat-8, primeiramente selecionou-se uma subárea de cada uma das imagens de forma a limitar a zona de estudo. De seguida, procedeu-se à calibração radiométrica das imagens, obtendo-se os valores de refletância espectral ao nível do topo da atmosfera (Equações 3.1 e 3.2). A partir dos valores de refletância das bandas de vermelho e infravermelho calculou-se o NDVI (Equação 3.3) para cada uma das datas. Os procedimentos referidos realizaram-se através da aplicação ENVI 5.1®.

O processamento das imagens Sentinel-1 concretizou-se através das ferramentas da aplicação Sentinel-1 *toolbox* 1.1.1®. Em primeiro lugar, realizou-se a calibração radiométrica σ^0 (Equação 3.4) de forma a obter os coeficientes de retrodispersão para as polarizações VV e VH, e, de seguida procedeu-se à operação de *Deburst* e *Merge* para concatenar os *bursts* e fundir as subfaixas de cada imagem. Após estes dois procedimentos, selecionou-se uma subárea de forma a minimizar o esforço computacional. Para tornar o espaçamento do píxel aproximadamente quadrado e atenuar o ruído das imagens, aplicaram-se os processos de *multilooking* e um filtro de *speckle* Lee refinado. Aplicou-se ainda uma correção de terreno *Range-Doppler* para geocodificar as imagens, utilizando o modelo digital de elevação SRTM (*Shuttle Radar Topography Mission*). Nesta operação os dados foram georreferenciados relativamente ao sistema coordenado WGS84 e reamostrados para uma resolução de 15 m através de uma interpolação bilinear. Por fim, a partir dos coeficientes de retrodispersão σ_{VV}^0 e σ_{VH}^0 , calcularam-se o rácio e a diferença entre polarizações.

Após o processamento das imagens óticas e SAR procedeu-se à integração das duas fontes de dados. Em primeiro lugar, georreferenciaram-se todas as imagens no sistema de coordenadas ETS89/PT- TM06 (*European Terrestrial Reference System 1989/Portugal Transverse Mercator 2006*) e uniram-se todas as camadas de informação. Neste processo considerou-se apenas a zona comum abrangida pelas camadas das duas fontes e realizou-se a reamostragem dos dados óticos para uma resolução de 15 m de forma a garantir a compatibilidade com os dados SAR. Estas operações efetuaram-se no aplicação ENVI 5.1®.

4.4. Tratamento e seleção dos dados do SIP

O tratamento da informação do SIP, para o ano de 2015, foi realizado através da aplicação ArcGIS 10.3®. De início, transformaram-se as coordenadas para o sistema ETRS89/PT-TM06 e realizou-se um processo de seleção das culturas a estudar, tendo sido escolhidas as mais predominantes na zona da lezíria, nomeadamente, o arroz, o milho, o tomate e as pastagens permanentes.

Procedeu-se, de seguida à afinação dos limites das parcelas através da informação do NDVI na imagem de 28 de julho, dado a imagem desta data apresentar os valores mais elevados para este índice. Verificou-se que, em alguns casos os limites das parcelas não coincidiam com os valores de NDVI esperados. Nestes casos, a geometria dos polígonos era corrigida ou em último caso procedia-se à sua eliminação. Nas Figuras 4.5, 4.6 e 4.7 são exemplificados três exemplos representativos dos casos mais frequentes.




Figura 4.5 – Divisão dos limites de uma parcela de arroz devido à existência de um caminho na região central.




Figura 4.6 – Redefinição dos limites de uma parcela de milho.




Figura 4.7 – Eliminação de uma parcela de tomate devido à ausência de vegetação.

Após o tratamento da informação do SIP, aplicou-se um método de amostragem estratificada aleatória, tendo sido divididas 50% das parcelas para treino e as restantes 50% para validação (Tabela 4.5). Congalton e Green [2009] sugerem um número mínimo de 50 amostras para cada classe para mapas com uma dimensão inferior a 1 milhão de acres e com menos de 12 classes, que neste caso resultaria num total de 200 amostras para treino e para validação. Contudo, não foi possível associar 50 amostras a todas as classes devido a certas classes possuírem um número de parcelas inferior a 100, tendo resultado num total de 174 e 171 amostras de treino e validação, respetivamente (Anexo II).

Tabela 4.5 – Número de amostras de treino e validação para cada classe.

Classe	Dados de Treino	Dados de Validação
Arroz	62	61
Milho	24	23
Tomate	70	69
Pastagens Permanentes	18	18
Total	174	171

4.5. Construção dos gráficos de evolução do coeficiente de retrodispersão e NDVI

Com o objetivo de realizar o estudo da fenologia das culturas construíram-se gráficos de evolução do NDVI e do coeficiente de retrodispersão para as polarizações VV e VH. Este procedimento foi efetuado através de duas *toolbox* desenvolvidas em ArcGIS 10.3® e um programa em linguagem MATLAB.

O fluxograma das operações efetuadas pelas *toolbox*⁷ encontra-se na Figura 4.8. A primeira *toolbox* tem como dados de entrada as bandas das variáveis a estudar (ficheiros matriciais) e o SIP. Esta destina-se à extração da informação das bandas de coeficiente de retrodispersão e NDVI, ao cálculo das médias dos píxeis destas variáveis delimitados pelo polígono de cada parcela e à construção de tabelas em que os seus atributos correspondem às médias das variáveis calculadas para cada data. A segunda *toolbox* tem como objetivo a integração das tabelas das médias das variáveis calculadas pela primeira *toolbox*, construindo um ficheiro vetorial com a informação do SIP. Para cada mês da época em estudo, as *toolbox* foram executadas individualmente para os coeficientes de retrodispersão e posteriormente para o NDVI. Do procedimento resultam seis ficheiros vetoriais, sendo três destinados às médias dos coeficientes de retrodispersão para os meses de maio, junho e julho e os restantes destinados às médias do NDVI para os mesmos meses.




Figura 4.8 – Fluxograma das operações efetuadas pelas *toolbox*.

O programa em linguagem MATLAB possui como dados de entrada os ficheiros vetoriais resultantes da segunda *toolbox*. Este permite a extração da informação dos ficheiros, a conversão dos coeficientes de retrodispersão σ_{VV}^0 e σ_{VH}^0 para decibéis (Equação 3.5) e a representação gráfica da evolução do NDVI e dos coeficientes de retrodispersão para cada uma das parcelas de cada

⁷ Podem-se verificar no Anexo III as interfaces das *toolbox* desenvolvidas.

tipo de cultura. Adicionalmente o programa representa graficamente a tendência média para cada uma das culturas tendo em conta todas as parcelas identificadas com essa cultura.

4.6. Classificação

Primeiramente, de forma a reduzir a confusão entre as diversas culturas e outros tipos de vegetação e ainda melhorar a precisão da classificação [Forkuor *et al.*, 2014] aplicou-se uma máscara para delimitar apenas as parcelas agrícolas (Anexo IV).

Foram utilizadas as bandas Landsat-8 da data com maior desenvolvimento das culturas segundo o NDVI (28 de julho) e as bandas Sentinel-1 da data mais próxima (29 de julho) [Long *et al.*, 2013], com o objetivo de determinar qual a combinação de parâmetros óticos e SAR (Tabela 4.6) que proporciona uma melhor precisão na classificação.

Para avaliar se a utilização do NDVI era relevante para a melhoria dos resultados foram ainda comparadas as combinações (1) e (2) listadas na Tabela 4.6. Todas as combinações foram testadas recorrendo a três algoritmos de classificação, ML, NN e SVM, com o objetivo de verificar qual o classificador que produzia os melhores resultados.

Tabela 4.6 – Combinações testadas na classificação.

Combinação	Camadas de informação
(1)	Refletâncias espectrais
(2)	Refletâncias espectrais (sem Vermelho e Infravermelho) e NDVI
(3)	Refletâncias espectrais e σ_{VH}^0
(4)	Refletâncias espectrais e σ_{VV}^0
(5)	Refletâncias espectrais, σ_{VH}^0 e σ_{VV}^0
(6)	Refletâncias espectrais e $\sigma_{VH}^0/\sigma_{VV}^0$
(7)	Refletâncias espectrais e $\sigma_{VH}^0 - \sigma_{VV}^0$
(8)	Refletâncias espectrais, $\sigma_{VH}^0/\sigma_{VV}^0$ e $\sigma_{VH}^0 - \sigma_{VV}^0$

Devido a ter sido utilizada uma máscara, no algoritmo de ML, o limite de probabilidade foi estabelecido a zero, não havendo o risco dos píxeis serem associados a outros tipos de vegetação e permitindo que todos os píxeis fossem atribuídos a uma classe de cultura independentemente de quão pequenos sejam os valores de probabilidade.

Relativamente ao algoritmo de NN, na seleção do número de iterações, estabeleceu-se uma relação de compromisso entre o tempo de processamento e a precisão obtida.

Com o objetivo de realizar uma classificação SVM por objetos, procedeu-se à segmentação das imagens com base nas camadas das refletâncias espectrais e do NDVI. No processo de classificação

foram utilizados parâmetros espectrais (média, mínimo, máximo e desvio padrão), de textura (alcance, média, variância e entropia) e de geometria (área, comprimento, compacidade e circularidade).

Posteriormente, foi realizada uma classificação multitemporal através da combinação de parâmetros e do algoritmo de classificação que produziram os melhores resultados, utilizando um processo de adição cumulativo das bandas das várias datas da época em estudo. Por fim, para validar os resultados obtidos utilizou-se a matriz de confusão, a PP, a PU, a PG e o coeficiente *Kappa*.

5. Resultados

5.1. Estudo da fenologia das culturas

5.1.1. Evolução temporal do NDVI

Na Figura 5.1 apresentam-se os gráficos da evolução temporal do NDVI da amostra total de parcelas para as quatro culturas estudadas. De uma forma geral, verifica-se que o período de estudo abrange as fases fenológicas de crescimento rápido e início da maturação das culturas. O crescimento rápido das culturas está associado ao aumento dos valores de NDVI e a maturação à estabilização destes valores. Em alguns casos verifica-se que algumas parcelas das diversas culturas se encontram em fase de senescência/colheita, caracterizada pela diminuição do NDVI.

Relativamente à cultura de arroz (Figura 5.1a), verifica-se que a maioria das parcelas apresenta um comportamento semelhante ao longo do período de estudo. Da análise do gráfico, supõe-se que a fase de crescimento rápido tenha tido início numa data próxima a 25 de maio (DOY = 145), contudo não se pode afirmar com certeza devido à inexistência de imagens Landsat-8 sem cobertura nebulosa para as datas anteriores a este dia. Estima-se que a fase de crescimento rápido tenha terminado aproximadamente no dia 26 de junho (DOY = 177). Após esta fase, a maior parte das parcelas permaneceu em período de maturação. No entanto, entre o dia 25 de maio (DOY = 145) e o dia 26 de junho (DOY = 177) constata-se que algumas parcelas de arroz se encontram ainda na fase de senescência relativa à plantação anterior. Consequentemente, estas parcelas apresentam uma fase de crescimento mais tardia que as restantes.

A maioria das parcelas da cultura de milho (Figura 5.1b), a maioria apresenta um comportamento semelhante, tendo o início da fase de crescimento rápido próximo do dia 25 de maio (DOY = 145) e o fim desta fase próximo de 26 de junho (DOY = 177). Constata-se a existência de parcelas com início da fase de crescimento mais tardio que as restantes, sendo que na data de 28 de julho (DOY = 209) ainda não se encontram na fase de maturação como as restantes parcelas.

Em relação à cultura de tomate (Figura 5.1c), a maioria das parcelas apresenta o início da fase de crescimento rápido próximo do dia 25 de maio (DOY = 145) e o final próximo do dia 26 de junho (DOY = 177), seguindo-se a fase maturação. À semelhança das culturas de arroz e milho, também algumas parcelas de tomate apresentam um comportamento distinto, com a fase de senescência numa data próxima ao dia 12 de julho (DOY = 193), indicando um início da fase de crescimento rápido anterior ao dia 25 de maio.




Figura 5.1 – (a) Evolução temporal do NDVI do arroz. (b) Evolução temporal do NDVI do milho. (c) Evolução temporal do NDVI do tomate. (d) Evolução temporal do NDVI das pastagens permanentes.

Quanto às pastagens (Figura 5.1d), estas não apresentam as fases mencionadas para as restantes culturas, dado serem constituídas por vegetação permanente que não é colhida nem plantada. Como se pode verificar, os valores de NDVI sofrem uma ligeira descida próxima de 10 de junho (DOY = 161) e permanecem quase constantes até ao final da época de estudo.

Na Figura 5.2 encontram-se representadas as linhas de tendência média do NDVI para cada uma das culturas, verificando-se que as culturas de milho e tomate apresentam um comportamento semelhante. Estas duas culturas apresentam um valor médio inicial de NDVI de cerca de 0,3 (DOY = 145) e um valor médio final de cerca de 0,7 (DOY = 209). A cultura de arroz apresenta um comportamento ligeiramente diferente, apresentando valores de NDVI mais baixos até meados da fase de maturação. Por fim, as pastagens permanentes apresentam, no início da época de estudo, um valor médio de NDVI de 0,30 e no final um valor de 0,25, não se verificando uma alteração significativa como já se tinha verificado na figura 5.1d.




Figura 5.2 – Tendência média do NDVI para cada tipo de cultura.

5.1.2. Evolução temporal do coeficiente de retrodispersão VV e VH

Na Figura 5.3 apresentam-se os gráficos de evolução do coeficiente de retrodispersão em VV e VH da amostra total de parcelas para cada uma das culturas. De forma geral, verificam-se grandes variações nos valores entre as diferentes imagens, sendo mais notório nas culturas de arroz e milho. Este facto impossibilita a identificação das fases fenológicas das culturas através da análise destes gráficos. Supõe-se que estas variações estejam relacionadas a um efeito presente nas imagens que pode estar associado ao ângulo incidente ou ao tipo de órbita de cada imagem. Como tal, foram analisadas estas duas características das imagens utilizadas (Tabela 5.1).

Tabela 5.1 – Ângulos incidentes e tipo de órbita para cada imagem SAR.

DOY	Ângulo Incidente (°)	Tipo de Órbita
138	39,01	Descendente
144	38,98	Ascendente
150	39,01	Descendente
156	38,89	Ascendente
162	39,01	Descendente
168	38,98	Ascendente
174	39,02	Descendente
186	39,02	Descendente
192	38,89	Ascendente
198	38,95	Descendente
204	38,90	Ascendente
210	38,95	Descendente




Figura 5.3 – (a) Evolução temporal do σ_{VV}^0 do arroz. (b) Evolução temporal do σ_{VH}^0 do arroz. (c) Evolução temporal do σ_{VV}^0 do milho. (d) Evolução temporal do σ_{VH}^0 do milho. (e) Evolução temporal do σ_{VV}^0 do tomate. (f) Evolução temporal do σ_{VH}^0 do tomate. (g) Evolução temporal do σ_{VV}^0 das pastagens permanentes. (h) Evolução temporal do σ_{VH}^0 das pastagens permanentes.

Constatou-se que os ângulos incidentes não apresentavam variações significativas entre as várias imagens, contudo verificou-se que as variações de valores nos coeficientes de retrodispersão poderiam estar associadas à mudança de tipo de órbita das imagens. Consequentemente, tendo em conta o tipo de órbita de aquisição das imagens, procedeu-se separadamente à análise das tendências médias de σ_{VV}^0 e σ_{VH}^0 (Figura 5.4).




Figura 5.4 – (a) Tendência média do σ_{VV}^0 das imagens de órbita ascendente. (b) Tendência média do σ_{VV}^0 das imagens de órbita descendente. (c) Tendência média do σ_{VH}^0 das imagens de órbita ascendente. (d) Tendência média do σ_{VH}^0 das imagens de órbita descendente.

Da análise dos gráficos, pode-se afirmar que estes não são conclusivos. De uma forma geral, as culturas apresentam valores mais elevados no coeficiente de retrodispersão em VV que em VH, indicando uma maior resposta a σ_{VV}^0 por parte das culturas. No início da fase de crescimento rápido constata-se que as diferenças entre os valores do coeficiente de retrodispersão das diferentes culturas são reduzidas. Este fato é evidente nas culturas de tomate, milho e pastagens permanentes para σ_{VH}^0 e em todas as culturas para σ_{VV}^0 e deve-se à pouca cobertura vegetal

existente nesta fase, sendo o solo a contribuição mais significativa para o coeficiente de retrodispersão. Após as primeiras datas, as diferenças tornam-se mais pronunciadas devido às mudanças da estrutura interna das plantas e do seu teor de humidade para os diferentes tipos de cultura [McNairn *et al.*, 2009]. No entanto, para a maioria das imagens os valores do coeficiente de retrodispersão em VV são semelhantes para as culturas de arroz e milho. Relativamente ao coeficiente de retrodispersão em VH verifica-se que os diferentes comportamentos das culturas são mais evidentes que em VV, indicando que este poderá ser mais eficaz na discriminação das diferentes culturas.

5.2. Classificação

Relativamente ao algoritmo NN, concluiu-se que 50 iterações permitiam estabelecer um bom compromisso entre tempo de processamento e a precisão. Os restantes parâmetros foram estabelecidos com os valores sugeridos por definição, utilizando-se uma rede de três camadas, uma taxa de treino de 0,2, uma taxa de momento de treino de 0 e um critério de paragem (erro médio quadrático) de 0,1

Quanto ao algoritmo de SVM utilizou-se a função de *kernel* RBF e também se optou por utilizar os valores para os parâmetros estabelecidos por definição, utilizando-se um γ de 0,091, um parâmetro de penalização de 100 e um limite de probabilidade 0, respetivamente.

Na Tabela 6.2 apresentam-se a PG e o coeficiente *Kappa* para cada combinação de parâmetros testada usando as imagens Landsat-8 e Sentinel-1 da data com maior desenvolvimento das culturas segundo o NDVI, respetivamente 28 e 29 de julho. Relativamente ao algoritmo de Redes Neurais não são apresentados os resultados para as combinações (7) e (8) devido às precisões obtidas estarem muito aquém das esperadas.

Tabela 5.2 – Precisão Global e coeficientes *Kappa* para as combinações testadas.

Algoritmo		Combinação							
		1	2	3	4	5	6	7	8
MV	PG (%)	86,8	85,5	88,0	87,5	87,8	86,7	87,2	87,2
	Kappa (%)	80,5	78,7	82,3	81,5	82,0	80,3	81,0	81,1
NN	PG (%)	87,8	76,3	88,3	80,6	79,9	77,2	-	-
	Kappa (%)	82,0	63,1	82,2	70,3	68,3	63,9	-	-
SVM	PG (%)	88,6	84,9	90,2	82,9	86,1	83,5	85	87,3
	Kappa (%)	82,6	77,3	85,1	73,2	78,6	74,7	77	80,7

Comparando os resultados obtidos pelas combinações (1) e (2), pode-se concluir que a utilização do NDVI degrada a precisão dos resultados nos três algoritmos, não tendo sido utilizado este índice nas restantes combinações.

A adição do coeficiente de retrodispersão em VH (3) proporciona melhores resultados que a adição deste coeficiente na polarização VV (4), contrariamente aos resultados obtidos por Forkuor *et al.* [2014], que indicaram que a polarização VV permitiu uma melhor discriminação das culturas que a polarização VH. Contudo, os resultados encontram-se de acordo com as conclusões obtidas através da análise da tendência média do coeficiente de retrodispersão, que indicaram que os diferentes comportamentos das culturas são mais evidentes no coeficiente de retrodispersão em VH, tornando esta variável mais eficaz na discriminação das culturas.

A combinação (3) é a que apresenta a precisão mais elevada para todos os algoritmos utilizados, apresentando os melhores resultados no algoritmo de SVM com uma PG de 90,2% e um coeficiente *Kappa* de 85,1% (a negrito na Tabela 5.2). Estes resultados estão de acordo com os estudos de Iyyappan *et al.* [2014] e Sonobe *et al.* [2014b] que obtiveram resultados bastante positivos através do método de SVM. Tal como Iyyappan *et al.* [2014], verifica-se que o NN apresenta os resultados menos favoráveis, quando comparado com os algoritmos de ML e SVM. De uma forma geral, a utilização das bandas SAR permitiu uma melhoria na classificação, estando de acordo com os resultados obtidos por McNairn *et al.* [2009], Dusseux *et al.* [2014] e Forkuor *et al.* [2014] que verificaram melhorias na classificação através da combinação de informação ótica e SAR.

Na classificação multitemporal, com base na combinação (3) e no algoritmo SVM, verifica-se uma melhoria de aproximadamente 4% quando comparado com os resultados obtidos através da classificação das bandas óticas e SAR da data com maior desenvolvimento das culturas (28 e 29 de julho). Tal como nos estudos de Karjalainen *et al.* [2008], McNairn *et al.* [2009] e Long *et al.* [2013] é demonstrada uma melhoria na classificação de culturas quando são utilizadas imagens adquiridas em várias datas. Os resultados demonstram uma precisão global de 94,1% e um coeficiente *Kappa* de 91,2% que indica um desempenho da classificação *Muito bom* (Tabela 3.5). Na Tabela 5.3 está representada a matriz de confusão e na Tabela 5.4 estão indicadas as precisões do utilizador e produtor para cada cultura.

Tabela 5.3 – Matriz de Confusão (%).

Classe	Arroz	Milho	Pastagens Permanentes	Tomate	Total
Arroz	99,6	6,8	0	0,1	47,0
Milho	0,1	70,1	0	2	12,4
Pastagens Permanentes	0,2	0,4	99,9	0,2	9,7
Tomate	0,1	22,7	0,1	97,6	31,0
Total	100,0	100,0	100,0	100,0	100,0

Tabela 5.4 – Precisões do Utilizador e Produtor (%).

Classe	Precisão do Utilizador (%)	Precisão do Produtor (%)
Arroz	97,5	99,6
Milho	94,9	70,1
Pastagens Permanentes	97,7	100
Tomate	87,6	97,6

Realizando uma análise pormenorizada das duas tabelas, do ponto de vista do produtor pode-se concluir que:

- 99,6% das parcelas de arroz foram classificadas corretamente e as restantes parcelas foram erradamente classificadas como pastagens, milho e tomate;
- 70,1% das parcelas de milho foram classificadas corretamente e a restante percentagem de parcelas foi erradamente classificada como tomate (22,7%), arroz (6,8%) e pastagens permanentes (0,4%);
- 99,9% das parcelas de pastagens permanentes foram classificadas corretamente e os restantes 0,1% das parcelas foram classificados incorretamente como tomate;
- 97,6% das parcelas de tomate foram classificadas corretamente e a restante percentagem das parcelas foi associada incorretamente às restantes culturas.

Do ponto de vista do utilizador pode-se concluir que:

- 97,5 % das parcelas de arroz identificadas no mapa são na realidade parcelas de arroz, pertencendo as restantes parcelas à cultura de milho e tomate;
- 94,9 % das parcelas classificadas no mapa como milho são realmente milho, estando as restantes associadas na realidade a culturas de tomate e arroz;
- 97,7% das parcelas classificadas no mapa como pastagens permanentes pertencem verdadeiramente a esta classe, no entanto as restantes são na realidade parcelas com os restantes tipos de cultura;

- 87,6 % das parcelas de tomate existentes no mapa final pertencem verdadeiramente a esta classe, sendo as restantes parcelas de milho, em maior quantidade, e de arroz e pastagens permanentes, em menor quantidade .

De uma forma geral, as precisões do produtor apresentam valores acima dos 90%, com exceção da cultura de milho, devendo-se maioritariamente à confusão existente entre as culturas de milho e tomate. As precisões do utilizador também apresentam valores elevados, sendo que o valor menor de 87,6% pertence à cultura de tomate.

Na Figura 5.5 é representada a evolução temporal da precisão global da classificação multitemporal. Verificou-se uma melhoria na precisão global à medida que foram adicionadas novas imagens ao processo de classificação, sendo que na primeira data se obteve uma precisão de 88,6% e na última data uma precisão de 94,1%, como referido anteriormente, o que traduz num aumento de aproximadamente 6% na precisão global do mapa produzido. Estes resultados podem ainda ser consultados em Saraiva e Navarro [em publicação] (Anexo V).




Figura 5.5 – Evolução da precisão global da classificação multitemporal.

Na Figura 5.6 apresenta-se o mapa de culturas resultante da classificação multitemporal.




Figura 5.6 – Mapa de culturas.

6. Conclusões e Perspetivas Futuras

6.1. Principais Conclusões

Neste estudo foi avaliada a potencialidade das imagens Sentinel-1 para a identificação de culturas, através da combinação de informação derivada destas imagens com imagens óticas Landsat-8. Foi avaliado qual o algoritmo (ML, NN e SVM) e que combinação de parâmetros (óticos e SAR) permitiam produzir melhores resultados na classificação. Posteriormente, a partir da combinação e classificador selecionados realizou-se a classificação multitemporal. Adicionalmente, efetuou-se o estudo da fenologia das culturas através dos coeficientes de retrodispersão nas polarizações VV e VH e do NDVI.

Através da análise da evolução do NDVI foi possível identificar as fases fenológicas das culturas e verificou-se que as culturas de milho e tomate têm comportamentos muito semelhantes segundo este índice. Da análise da evolução dos coeficientes de retrodispersão em VV e VH, não foi possível identificar as fases fenológicas. Conclui-se que as culturas apresentam uma maior resposta ao coeficiente de retrodispersão em VV que em VH. No entanto, a partir da análise do coeficiente de retrodispersão em VH são mais evidentes os diferentes comportamentos das culturas, indicando que este permite uma discriminação mais eficaz das culturas que este coeficiente em VV.

Perante os resultados obtidos, pode-se afirmar que a integração das imagens Sentinel-1 com as Landsat-8 permitiu uma melhoria nos resultados obtidos na classificação de culturas. A combinação das bandas óticas com o coeficiente de retrodispersão na polarização VH permitiu a obter a precisão global mais elevada, utilizando o algoritmo de classificação SVM. A classificação multitemporal permitiu um aumento de cerca de 4% na precisão global obtida, quando comparada com obtida através da classificação das bandas óticas e SAR da data com valores de NDVI mais elevados.

6.2. Perspetivas Futuras

Prevê-se que a integração das imagens SAR Sentinel-1 e as imagens óticas Sentinel-2 oferecerá novas perspetivas para os estudos de identificação de culturas e monitorização agrícola. As imagens Sentinel-2 serão distribuídas gratuitamente e proporcionarão uma melhor resolução espacial (10 m face aos 30 m das bandas Landsat-8) e temporal (10/5 dias face aos 16 dias do Landsat-8), podendo permitir a obtenção de melhores resultados na classificação de culturas. O

curto período de revisita da missão Sentinel-2 permitirá obter as fases fenológicas das culturas com maior precisão.

Segundo os resultados obtidos em diversos estudos [Dusseux *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014b], a inclusão de informação polarimétrica extraída a partir das imagens Sentinel-1 poderá ser útil na discriminação de diferentes tipos de culturas. Mais concretamente, a utilização de elementos de matrizes de dispersão e de decomposições polarimétricas. As matrizes de dispersão contêm informação relevante sobre os processos de dispersão, sendo que a sua utilização pode assistir no desenvolvimento de assinaturas de dispersão únicas para diferentes alvos e melhorar a sua discriminação [Forkuor *et al.*, 2014]. As decomposições polarimétricas através da análise dos dados complexos identificam características que descrevem o tipo e a contribuição dos mecanismos de dispersão, providenciando uma exploração significativa e pormenorizada da polarimetria SAR com a inclusão da informação da fase que é descartada em estudos que utilizam exclusivamente os coeficientes de retrodispersão [Jin *et al.*, 2014].

A disponibilização de imagens de satélite gratuitas e de aplicações de código aberto para processamento de imagens por parte da ESA, permitirá o surgimento de mais estudos nesta área e noutras áreas da DR. Estão previstos dois melhoramentos para a Sentinel-1 *toolbox* relativamente às ferramentas de polarimetria (previsto para setembro de 2015) e classificação (previsto para janeiro de 2016) [ESA, 2014], possivelmente possibilitando a sua aplicação às imagens Sentinel-1. Tal como para a missão Sentinel-1, estão a ser desenvolvidas outras aplicações direcionadas para as restantes missões Sentinel. A Sentinel-2 *toolbox* é composta por um conjunto de ferramentas de visualização, de análise e de processamento para a exploração dos produtos óticos da missão Sentinel-2 e outras missões (RapidEye, SPOT, Landsat, etc...). Recentemente, está a ser implementada uma nova arquitetura denominada de SNAP (*Sentinel Application Platform*) que tem como objetivo englobar todas as Sentinel *toolbox* numa única aplicação [ESA, 2015e].

Referências Bibliográficas

- ASF (2015) “ASF MapReady User Manual”, https://media.asf.alaska.edu/uploads/pdf/mapready_manual_3.1.22.pdf, acessado em maio de 2015.
- Atwood, D.K., D. Small, e R. Gens (2012) “Improving PolSAR Land Cover Classification With Radiometric Correction of the Coherency Matrix.” *IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing*, Vol. 5, Nº 3, pp. 848-856.
- Bargiel, D. e S. Herrmann (2011) “Multi-Temporal Land-Cover Classification of Agricultural Areas in Two European Regions with High Resolution Spotlight TerraSAR-X Data.” *Remote Sensing*, Vol. 3, Nº 5, pp. 860-877.
- Blaes, X., L. Vanhalle e P. Defourny (2005) “Efficiency of crop identification based on optical and SAR image time series.” *Remote Sensing of Environment*, Vol. 96, Nº 3, pp. 352-365.
- Catalão, J. (2013) *Apontamentos de Princípios e Aplicações de Detecção Remota*. Texto não publicado, Departamento de Engenharia Geográfica, Geofísica e Energia da Faculdade de Ciências da Universidade de Lisboa, Lisboa.
- CCRS (2015a) “Tutorial: Fundamentals of Remote Sensing”, <http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/satellite-imagery-products/educational-resources/9309>, acessado em março de 2015.
- CCRS (2015b) “Tutorial: Radar Polarimetry”, <http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/satellite-imagery-products/educational-resources/9579>, acessado em março de 2015.
- Chander, G., B.L. Markham e D.L. Helder (2009) “Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors” *Remote Sensing of Environment*, Vol. 113, Nº 5, pp. 893-903.
- Congalton, R. G., K. Green (2009) *Assessing the accuracy of remotely sensed data: principles and practices*. CRC Press, 2ª edição. Boca Raton, FL, Estados Unidos da América.
- CRISP (2001) “Optical Remote Sensing”, <http://www.crisp.nus.edu.sg/~research/tutorial/optical.htm>, acessado em agosto de 2015.
- Drusch, M., U.D. Bello, S. Carlier, O. Colin, V. Fernandez, F. Gascon, B. Hoersch, C. Isola, P. Laberinti, P. Martimort, A. Meygret, F. Spoto, O. Sy, F. Marchese e P. Bargellini (2012)

“Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services” *Remote Sensing of Environment*, Vol. 120, pp. 25-36.

Dusseux, P., T. Corpetti, L. Hubert-Moy, e S. Corgne (2014) “Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring.” *Remote Sensing*, Vol. 6, Nº 7, pp. 6163-6182. ESA (2012) “Sentinel-1: ESA’s Radar Observatory Mission for GMES Operational Services”, https://earth.esa.int/documents/247904/349449/S1_SP-1322_1.pdf, acessado em fevereiro de 2015.

ESA (2013) “Sentinel-1 User Handbook”, https://sentinel.esa.int/documents/247904/685163/Sentinel-1_User_Handbook/06fa0b55-9eca-47ff-a45f-242012951564, acessado em fevereiro de 2015.

ESA (2014) “5th ESA Advanced Training Course on Land Remote Sensing”, http://seom.esa.int/landtraining2014/files/D4P1a_S1TBX.pdf, acessado em setembro de 2015.

ESA (2015a) “Sentinel-1 Toolbox: SAR Basics Tutorial”, <http://sentinel1.s3.amazonaws.com/docs/S1TBX%20SAR%20Basics%20Tutorial.pdf>, acessado em março 2015.

ESA (2015b) “Application of Radiometric Calibration LUT” <https://sentinel.esa.int/web/sentinel/home>, acessado em fevereiro de 2015.

ESA (2015c) “Help Topics S1TBX” Documentação técnica.

ESA (2015d) “Part I – Tutorial on Radar Polarimetry: What is Polarisation?”, https://earth.esa.int/documents/653194/656796/What_Is_Polarization.pdf, acessado em março de 2015.

ESA (2015e) “SNAP”, <http://step.esa.int/main/toolboxes/snap/>, acessado em setembro de 2015.

Exelis (2015a) “Maximum Likelihood”, <http://www.exelisvis.com/docs/MaximumLikelihood.html>, acessado em julho de 2015.

Exelis (2015b) “Neural Net”, <http://www.exelisvis.com/docs/NeuralNet.html>, acessado em Julho de 2015.

Exelis (2015c) “Support Vector Machine Background”, <http://www.exelisvis.com/docs/BackgroundSVM.html>, acessado em julho de 2015.

Exelis (2015d) “Feature Extraction with Example-Based Classification Tutorial”. <http://www.exelisvis.com/portals/0/pdfs/envi/FXExampleBasedTutorial.pdf>, acessado em junho de 2015.

- Fonseca, A.D., J.C. Fernandes (2004) *Detecção Remota*. Lidel, Lisboa, Portugal.
- Forkuor, G., C. Corand, M. Thiel, T. Ulmann e E. Zoungrana (2014) “Integration of Optical and Synthetic Aperture Radar Imagery for Improving Crop Mapping in Northwestern Benin, West Africa.” *Remote Sensing*, Vol. 6, N° 7, pp. 6472-6499.
- Iyyappan, M., S. Ramakrishnan e S. Raju (2014) “Study of Discrimination Between Plantation and Dense Scrub Based on Backscattering Behavior of C Band SAR Data” *IPRS The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XL-9, pp. 755-760.
- Jin, H., G. Mountrakis e S.V. Stehman (2014) “Assessing integration of intensity, polarimetric scattering, interferometric coherence and spatial texture metrics in PALSAR-derived land cover classification.” *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 98, pp. 70-84.
- Karjalainen, M., H. Kaartinen e J. Hyypä (2008) “Agricultural Monitoring Using Envisat Alternating Polarization SAR images” *Photogrammetric Engineering & Remote Sensing*, Vol. 74, N° 1, pp. 117-126.
- Koppe, W., M. L. Gnyp, C. Hütt, Y. Yao, Y. Miao, X. Chen, e G. Bareth (2013) “Rice monitoring with multi-temporal and dual-polarimetric TerraSAR-X data.” *International Journal of Applied Earth Observation and Geoinformation*, Vol. 21, pp. 568-576.
- Landis, J. R. e G.G. Koch (1977) “The measurement of observer agreement for categorical data” *Biometrics*, Vol. 33, N° 1, pp. 159-174.
- Lee, J.S. e E. Pottier (2009) *Polarimetric Radar Imaging: From Basics to Applications*. CRS Press, Boca Raton, FL.
- Long, J.A, R.L. Lawrence., M.C. Greenwood, L. Marshall, e P.R. Miller (2013) “Object-oriented crop classification using multitemporal ETM+ SLC-off imagery and random forest” *GIScience & Remote Sensing*, Vol. 50, N° 4, pp.418-436.
- McNairn, H., C. Champagne, J. Shang, D. Holmstrom, e G. Reichert (2009) “Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories” *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 64, N° 5, pp. 434-449.
- Mirzae, S., M. Motagh, H. Arefi e M. Nooryazdan (2014) “Classification of agricultural fields using time series of dual polarimetry TerraSAR-X images” *IPRS The International Archives*


- of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XL-2/W3, pp. 191-196.
- Mishra, N., M.O. Haque, L. Leigh, D. Aaron, D. Helder e B. Markham (2014) “Radiometric Cross Calibration of Landsat 8 Operational Land Imager (OLI) and Landsat 7 Enhanced Thematic Mapper Plus (ETM+)” *Remote Sensing*, Vol. 6, Nº 12, pp. 12619-12638.
- Moreira, A., P. Prats-Iraola, M. Younis, G. Krieger, I. Hajnsek e K.P. Papathanassiou (2013) “A tutorial on Synthetic Aperture Radar” *IEEE Geoscience and Remote Sensing Magazine*, Vol.1, Nº 1, pp. 6-43.
- Mountrakis, G., J. Im e C. Ogole (2011) “Support vector machines in remote sensing: A review” *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 66, Nº 3, pp. 247-259.
- NASA (2013) “The Electromagnetic Spectrum”, <http://imagine.gsfc.nasa.gov/science/toolbox/emspectrum1.html>, acessado em agosto de 2015.
- Oommen, T., D. Misra, N.K. Twarakavi, A. Prakash, B. Sahoo e S. Bandopadhyay (2008) “An Objective Analysis of Support Vector Machine Based Classification for Remote Sensing” *Mathematical geosciences*, Vol. 40, Nº 4, pp.409-424.
- Otukei, J.R., T. Blaschke (2010) “Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms” *International Journal of Applied Earth Observation and Geoinformation*, Vol. 12, pp. S27-S31.
- Ouchi, K. (2013) “Recent Trend and Advance of Synthetic Aperture Radar with Selected Topics” *Remote Sensing*, Vol. 5, Nº 2, pp. 716-807.
- Parker, W.V (2012) “Discover the Benefits of RADAR imaging”, <http://eijournal.com/print/articles/discover-the-benefits-of-radar-imaging>, acessado em junho de 2015.
- Plural (2004) “1ª Revisão do Plano Municipal de Vila Franca de Xira”, http://www.cm-vfxira.pt/uploads/document/file/67/Plano_Director_Municipal.pdf, acessado em Julho de 2015
- Ray, S.S (2015) “Basics of Remote Sensing”, http://www.iasri.res.in/ebook/TE-FCPI_sampling/BASICS%20OF%20REMOTE%20SENSING.pdf, acessado em agosto de 2015.
- Richards, J.A. e X. Jia (2006) *Remote Sensing Digital Image Analysis, An Introduction*. 4ª edição, Springer, Berlim, Alemanha.

- Rouse, J.W., R.H. Hass, D.W. Deering e J.A. Schell (1974) *Monitoring The Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation*. NASA/GSFC, Type III, Final Report, Greenbelt, MD.
- Roy, D.P., M.A. Wulder, T.R. Loveland, C.E. Woodcock, M.C. Anderson, D. Helder, J.R. Irons, D.M. Johnson, R. Kennedy, T.A. Scambos, C.B. Schaaf, J.R. Schott, Y. Sheng, E.F. Vermote, A.S. Belward, R. Bindschadler, W.B. Cohen, F. Gao, J.D. Hipple, P. Hostert, J. Huntington, C.O. Justice, A. Kilic, V. Kovalskyy, Z.P. Lee, L. Lymburner, J.G. Masek, J. McCorkel, Y. Shuai, R. Trezza, J. Vogelmann, R.H. Wynne e Z. Zhu (2014) “Landsat-8: Science and product vision for terrestrial global change research” *Remote Sensing of Environment*, Vol. 145, pp. 154-172.
- Saraiva, C. e A. Navarro (em publicação) “Avaliação do Potencial das Imagens Sentinel-1 para Identificação de culturas Agrícolas”, *Actas da VIII Conferência Nacional de Cartografia e Geodesia (VIII CNCG)*, Academia Militar, Lisboa, 29-30 outubro.
- Sonobe, R., H. Tani, X. Wang, N. Kobayashi e H. Shimamura (2014a) “Random forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data” *Remote Sensing Letters*, Vol. 5, Nº 2, pp. 157-164.
- Sonobe, R., H. Tani, X. Wang, N. Kobayashi e H. Shimamura (2014b) “Discrimination of crop types with TerraSAR-X-derived information” *Physics and Chemistry of the Earth*, Partes A/B/C.
- Stefanski, J., O. Chaskovskyy, e B. Waske (2014) “Mapping and monitoring of land use changes in post-Soviet western Ukraine using remote sensing data.” *Applied Geography*, Vol. 55, pp. 155-164.
- USGS (2015), http://landsat.usgs.gov/band_designations_landsat_satellites.php, acessado em março de 2015.
- Zhang, J., L. Jia (2014) “A Comparison of Pixel-Based and Object-Based Land Cover Classification Methods in an Arid/Semi-arid Environment of Northwestern China” *Third International Workshop on Earth Observation and Remote Sensing Applications*, IEEE, Changsha, China, 11- 14 junho, pp. 403-407.
- Zheng, B., S.W. Myint, P.S. Thenkabail e R.M. Aggarwal (2015) “A support vector machine to identify irrigated crop types using time-series Landsat NDVI data”, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 34, pp. 103-112.

Zyl, J.V., Y. Kim (2011) *Synthetic Aperture Radar Polarimetry*. John Wiley & Sons, Hoboken, NJ.

Anexos

Anexo I – Freguesias do Concelho de Vila Franca de Xira




Legenda


Freguesia

- União das freguesias de Alhandra, São João dos Montes e Calhandriz
- União das freguesias de Alverca do Ribatejo e Sobralinho
- União das freguesias de Castanheira do Ribatejo e Cachoeiras
- União das freguesias de Póvoa de Santa Iria e Forte da Casa
- Vialonga
- Vila Franca de Xira


Anexo II – Dados de Treino e Validação



Anexo III – Interface das *toolbox*



1ª toolbox



2ª toolbox

Anexo IV – Máscara para delimitar as culturas



Anexo V – Artigo submetido e aceite na VIII Conferência Nacional de Cartografia e Geodesia – Informação Geoespacial para as Gerações Futuras: Oportunidades e Desafios



Avaliação do Potencial das Imagens Sentinel-1 para Identificação de Culturas Agrícolas

Cátia SARAIVA¹ e Ana NAVARRO²

¹ Faculdade de Ciências, Universidade de Lisboa

² Instituto Dom Luiz, Faculdade de Ciências, Universidade de Lisboa

(catia_sofia2005@hotmail.com; acferreira@fc.ul.pt)

Palavras-chave: Sentinel-1, SAR, Dupla Polarização, Landsat-8, Classificação Multitemporal

Resumo: O presente estudo tem como finalidade avaliar a potencialidade das imagens SAR (*Synthetic Aperture RADAR*) do satélite Sentinel-1 com dupla polarização (VV/VH) para a identificação de culturas na zona agrícola de Vila Franca de Xira (Iezíria e mouchões). Ao longo do trabalho é analisado em que medida a utilização de canais adicionais de informação derivada destas imagens pode melhorar os resultados obtidos da classificação de imagens do satélite Landsat-8. Para identificar as diferentes culturas presentes na zona estudo, utilizaram-se séries temporais das imagens Landsat-8 e Sentinel-1, abrangendo a época de crescimento das culturas (de maio a julho de 2015). A informação derivada das imagens do satélite Sentinel-1 consistiu nos coeficientes de retrodispersão nas polarizações VV e VH, quocientes entre polarizações e diferenças entre polarizações. Numa primeira fase, avaliou-se qual o algoritmo e combinação de parâmetros (óticos e SAR) que permitiram obter os melhores resultados na classificação. Foram testados diferentes algoritmos de classificação nomeadamente, Máxima Verosimilhança (ML – *Maximum Likelihood*), Redes Neurais (NN – *Neural Network*) e Máquina de Suporte Vetorial (SVM – *Support Vector Machine*). Posteriormente, a partir da combinação e classificador selecionados realizou-se a classificação multitemporal. Os resultados foram testados e validados com informação do Sistema de Identificação de Parcelas (SIP) fornecido pelo Instituto de Financiamento da Agricultura e Pescas (IFAP). Verificou-se que a adição de informação SAR às bandas espectrais Landsat-8 permitiu melhorar os resultados obtidos. A combinação que permitiu obter os melhores resultados foi a junção das bandas Landsat-8 em conjunto com o coeficiente de retrodispersão para a polarização VH, utilizando o algoritmo de classificação SVM. A classificação multitemporal desta combinação permitiu melhorar resultados, tendo sido obtida uma exatidão global de 94,1%, face aos 90,2% obtidos apenas com as bandas correspondentes à data com maior desenvolvimento das culturas, e um coeficiente *Kappa* de 91,2%.



1. Introdução

Uma das principais áreas de aplicação da Detecção Remota (DR) é a agricultura. Esta ciência oferece um meio eficiente e confiável de adquirir a informação requerida para a identificação de culturas, a avaliação do estado das colheitas, a estimativa de produtividade, o mapeamento das características do solo e a monitorização de práticas agrícolas (CCRS, 2015).

A discriminação de culturas é uma etapa crítica para a maioria dos sistemas de monitorização agrícola. A capacidade de identificar o tipo de cultura torna possível a estimação da área associada a cada tipo de cultura e obter variáveis estatísticas essenciais para o controle de culturas, nomeadamente em áreas subsidiadas, e o fornecimento de dados de entrada para modelos de previsão de produção agrícola (Blaes *et al.*, 2005).

Para a identificação precisa do solo em zonas agrícolas de grandes dimensões são necessárias imagens de DR com alta resolução espacial e temporal (Dusseux *et al.*, 2014). Apesar das imagens óticas proporcionarem uma resolução espacial adequada, a resolução temporal fica aquém do necessário. A data e frequência de aquisição de imagens são críticas, dado que a identificação dos tipos de culturas depende da disponibilidade de imagens em fases específicas do seu ciclo de crescimento, o que nem sempre é possível com as imagens óticas devido às suas limitações no que diz respeito à frequência temporal das imagens e à existência de cobertura de nuvens. Estas limitações têm vindo a ser ultrapassadas pela utilização conjunta de imagens óticas e RADAR (*Radio Detection And Ranging*), assim como de produtos resultantes da fusão destes dois tipos de imagens (Fonseca e Fernandes, 2004).

Os sistemas de SAR contrariamente aos sistemas óticos passivos são sistemas ativos RADAR na região das micro-ondas do espectro eletromagnético, possuindo a capacidade de observar a superfície terrestre a qualquer altura do dia sob quaisquer condições meteorológicas (Forkuor *et al.*, 2014; Jin *et al.*, 2014). Tal, torna os sistemas RADAR altamente viáveis em termos de provisão de dados, especialmente durante os períodos em que os sensores óticos falham (Forkuor *et al.*, 2014). Além disso, os sinais RADAR são sensíveis às propriedades do solo (humidade e rugosidade) e da vegetação (estrutura e biomassa), proporcionando informação adicional dos tipos de cobertura do solo, relativamente à obtida através de imagens óticas (Jin *et al.*, 2014).

Devido às vantagens que as imagens SAR proporcionam a aplicações de identificação e monitorização de culturas agrícolas, têm surgido diversos estudos que recorrem a séries temporais SAR (Karjalainen *et al.*, 2008; Bargiel e Herrmann, 2011; Iyyappan *et al.*, 2014; Mirzae *et al.*, 2014; Sonobe *et al.*, 2014) ou a combinação de imagens óticas e SAR (McNairn *et al.*, 2009; Dusseux *et al.*, 2014; Forkuor *et al.*, 2014) para estes fins. Nestes estudos, com recurso a análises multisensor, têm sido reportadas melhorias significativas na exatidão da classificação das diferentes culturas.

As imagens da missão Sentinel-1 são adquiridas na banda C nos modos de polarização única (HH ou VV) ou dupla (HH/HV ou VV/VH) com uma alta resolução espacial e temporal, reunindo diversas características favoráveis à identificação de culturas agrícolas. O fato destas imagens serem adquiridas com uma alta resolução espacial e temporal revela-se importante neste tipo de aplicações, como referido anteriormente. O modo de dupla polarização VV/VH é mencionado em alguns estudos (McNairn *et al.*, 2009; Forkuor *et al.*, 2014) como útil na identificação de culturas. Os comprimentos de onda curtos, como é o caso da banda C, são comparáveis com a dimensão das folhas e dos caules das culturas de cereais (Karjalainen *et al.*, 2008). Estes comprimentos de onda são refletidos a partir do topo da cobertura vegetal e são mais eficientes no reconhecimento de alvos de pequenas dimensões (Parker, 2012).

O principal foco deste estudo é a avaliação da potencialidade das imagens SAR Sentinel-1 para a identificação de culturas na zona agrícola de Vila Franca de Xira, através da combinação de informação derivada destas imagens com imagens óticas Landsat-8. Para tal, avaliou-se qual o algoritmo, Máxima Verosimilhança (ML – *Maximum Likelihood*), Redes Neurais (NN – *Neural Network*) e Máquina de Suporte Vetorial (SVM – *Support Vector Machine*), e que combinação de parâmetros (óticos e SAR) permitem produzir melhores resultados na classificação. Posteriormente, a partir da combinação e classificador selecionados realizou-se a classificação multitemporal. Adicionalmente, efetuou-se o estudo da fenologia das culturas através dos coeficientes de retrodispersão e do Índice de Vegetação de Diferença Normalizada (NDVI – *Normalized Difference Vegetation Index*).

2. Metodologia

2.1 Área de estudo

A área de estudo selecionada corresponde à zona da lezíria e Mouchões da freguesia de Vila Franca de Xira (Figura 1) do concelho de Vila Franca de Xira do distrito de Lisboa. A freguesia de Vila Franca de Xira possui uma área de 21286 hectares e é constituída pela lezíria (1), o mouchão de Alhandra (2), o mouchão das Garças (3), o mouchão do Lombo do Tejo (4), o mouchão da Póvoa (5) e uma zona urbana (6) conforme representado na Figura 2.




Figura 1 – Área de Estudo




Figura 2 – Freguesia de Vila Franca de Xira

De uma forma geral, o clima do concelho é mediterrânico, apresentando uma estação quente com muitas horas de sol em alternância com uma estação fresca durante a qual se sucedem desordenadamente dias de chuva e abertas de sol (Plural, 2004). Na Figura 3 está representado um gráfico da temperatura média e precipitação média mensais do período de estudo (de maio a julho de 2015), tendo em conta os dados registados pela estação meteorológica de Barragem de Magos do concelho de Salvaterra de Magos (estação mais próxima da lezíria). A temperatura média mensal assume valores entre 18,8 °C e 21,7 °C, verificando-se um aumento desta ao longo dos meses do período de estudo. Em relação à precipitação média mensal, esta sofre um decréscimo assumindo valores entre 1,8 mm e 10,5 mm.

Os solos da lezíria são muito férteis, devido à sazonalidade das cheias que os enriquecem com matéria orgânica. Por consequente, a exploração agrícola é intensiva, e as principais culturas são temporárias, e quando é possível procede-se a dois ciclos de cultura durante o ano agrícola. Nas culturas temporárias destacam-se as culturas para grão, com especial relevo para as culturas anuais de regadio, tais como o trigo, o milho e o arroz. Na lezíria também surge a exploração de culturas industriais, tais como, o tomate e cultura de forrageiras, que é associada à exploração pecuária de gado bravo. Nos mouchões existe a presença de pastagens (Plural, 2004).




Figura 3 – Valores de precipitação média e temperatura média mensais no período de estudo

2.2 Imagens de Detecção Remota

Tendo em conta o período de estudo (de maio a julho de 2015) selecionaram-se 5 imagens Landsat-8 (25 de maio, 10 de junho, 26 de junho, 12 de julho e 20 de julho) da zona de Vila Franca de Xira não afetadas por nuvens. Estas imagens são disponibilizadas gratuitamente pela USGS (*United States Geological Survey*), associadas ao sistema de coordenadas WGS84 (*World Geodetic System 1984*) e são corrigidas geometricamente (Roy *et al.*, 2014). Da informação disponibilizada, foram utilizadas as bandas: 2 (Azul), 3 (Verde), 4 (Vermelho), 5 (Infravermelho Próximo), 6 e 7 (Infravermelho de comprimento de onda curto 1 e 2). As bandas utilizadas apresentam uma resolução espacial de 30 m.

Adicionalmente, utilizaram-se 12 imagens SLC (*Side Look Complex*) do modo de aquisição *Interferometric Wide Swath Mode* (IW) da missão Sentinel-1 com dupla polarização VV/VH, disponibilizadas gratuitamente pela *European Space Agency* (ESA). Estas são adquiridas na banda C no modo de dupla polarização VV/VH com uma resolução espacial de 5X20 m, uma largura de faixa de 250 km e um ângulo de incidência entre 20° e 45°.

2.3 Métodos Aplicados

A metodologia aplicada dividiu-se 5 etapas: (1) o processamento das imagens Landsat-8 e Sentinel-1, (2) a integração das imagens das duas fontes, (3) o tratamento e seleção dos dados de treino e validação, (4) a classificação das imagens (5) e a validação dos resultados obtidos (Figura 4).

No processamento das imagens Landsat-8, primeiramente selecionou-se uma subárea de cada uma das imagens de forma a limitar a zona de estudo. De seguida, procedeu-se à calibração radiométrica das imagens, obtendo-se os valores de refletância espectral ao nível do topo da atmosfera para as bandas R, G, B, NIR, SWIR1 e SWIR2 (Mirshra *et al.*, 2014). A partir dos valores de refletância das bandas de vermelho e infravermelho calculou-se o NDVI para cada uma das datas (Rouse *et al.*, 1974). Os procedimentos referidos realizaram-se recorrendo ao *software* ENVI 5.1®.

O processamento das imagens Sentinel-1 concretizou-se através das ferramentas do *software* Sentinel-1 toolbox 1.1.1®. Segundo o procedimento indicado pela ESA (2015), realizou-se a calibração radiométrica σ^0 de forma a obter os coeficientes de retrodispersão para as polarizações VH e VV, e, de seguida procedeu-se à operação de *Deburst* e *Merge* para concatenar os *bursts* e fundir as subfaixas de cada imagem. Após estes dois procedimentos, selecionou-se uma subárea de forma a minimizar o esforço computacional. Para tornar o espaçamento do píxel aproximadamente quadrado e atenuar o ruído das imagens aplicaram-se os processos de *multilooking* e um filtro de *speckle* Lee refinado. Aplicou-se ainda uma correção de terreno *Range-Doppler* para geocodificar as imagens, utilizando o modelo digital de elevação SRTM (*Shuttle Radar Topography Mission*). Nesta operação os dados foram georreferenciados relativamente ao sistema coordenado WGS84 e reamostrados para uma resolução de 15 m através



de uma interpolação bilinear. Por fim, a partir dos coeficientes de retrodispersão σ_{VH}^0 e σ_{VV}^0 , calcularam-se o rácio e a diferença entre polarizações.

Após o processamento das imagens óticas e SAR procedeu-se à integração das duas fontes de dados. Em primeiro lugar, transformaram-se todas as imagens para o sistema de coordenadas ETRS89/PT-TM06 (*European Terrestrial Reference System 1989/Portugal Transverse Mercator 2006*) e uniram-se todas as camadas de informação. Neste processo considerou-se apenas a zona comum abrangida pelas camadas das duas fontes e realizou-se a reamostragem dos dados óticos para uma resolução de 15 m de forma a garantir a compatibilidade com os dados SAR.

Para a obtenção dos dados de treino e validação utilizou-se a informação do Sistema de identificação de Parcelas (SIP) fornecido pelo Instituto de Financiamento da Agricultura e Pescas (IFAP). Estes foram disponibilizados em formato vetorial no sistema de coordenadas *Hayford-Gauss Datum 73*, tendo sido efetuada a transformação das coordenadas para o sistema ETRS89/PT-TM06. A partir desta informação realizou-se um processo de seleção das culturas a estudar, tendo sido escolhidas as mais predominantes na zona da lezíria, nomeadamente, o arroz, o milho, o tomate e as pastagens permanentes. Procedeu-se à afinação dos limites das parcelas através da informação do NDVI na imagem de 28 de julho, devido a esta data apresentar os valores mais elevados para este índice. Após o tratamento da informação do SIP, realizou-se um método de amostragem estratificada aleatória, tendo sido divididas 50% das parcelas para treino e as restantes 50% para validação (Quadro 1). Congalton e Green (2009) sugerem um número mínimo de 50 amostras para cada classe para mapas com uma dimensão inferior a 1 milhão de acres e com menos de 12 classes, que neste caso resultaria num total de 200 amostras para treino e para validação. Contudo, não foi possível associar 50 amostras a todas as classes devido a certas classes possuírem um número de parcelas inferior a 100, tendo resultado num total de 174 e 171 amostras de treino e validação, respetivamente.

Quadro 1 – Número de amostras de treino e validação para cada classe

Classe	Dados de Treino	Dados de Validação
Arroz	62	61
Milho	24	23
Tomate	70	69
Pastagens Permanentes	18	18
Total	174	171

De forma a reduzir a confusão entre as diversas culturas e outros tipos de vegetação e ainda melhorar a exatidão da classificação (Forkuor, *et al.* 2014) aplicou-se uma máscara para delimitar apenas as parcelas agrícolas. Foram utilizadas as bandas Landsat-8 da data com maior desenvolvimento das culturas segundo o NDVI (28 de julho) e as bandas Sentinel-1 da data mais próxima (29 de julho), com o objetivo de determinar qual a combinação de parâmetros óticos e SAR (Quadro 2) que proporciona uma melhor exatidão na classificação. Para avaliar se a utilização do NDVI era relevante para a melhoria dos resultados foram ainda comparadas as combinações (1) e (2) listadas no Quadro 2. Todas as combinações foram testadas recorrendo a três algoritmos de classificação, Máxima Verosimilhança, Redes Neurais e SVM, com o objetivo de verificar qual o classificador que produzia os melhores resultados.

Para o algoritmo de redes neurais foi utilizada uma rede de três camadas, uma taxa de treino de 0,2, uma taxa de momento de treino de 0, um critério de paragem (erro médio quadrático) de 0,1 e 50 iterações.

O primeiro passo da aplicação do classificador de SVM foi a segmentação das imagens com base nas camadas das reflectâncias espectrais e nos NDVI. Utilizou-se a função *kernel* RBF com um valor de *gamma* de 0,091 e estabeleceram-se os parâmetros de penalização e o limite de probabilidade a 100 e 0, respetivamente. Foram utilizados parâmetros espectrais (média, mínimo, máximo e desvio padrão), de textura (alcance, média, variância e entropia) e de geometria (área, comprimento, compacidade e circularidade).

Posteriormente, foi realizada a classificação multitemporal através da combinação e algoritmo de classificação que apresentaram melhores resultados.

Quadro 2 – Combinações testadas

Combinação	Camadas de informação
(1)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2)
(2)	Refletâncias espectrais (G,B, SWIR1, SWIR 2) e NDVI
(3)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2) e σ_{VH}^0
(4)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2) e σ_{VV}^0
(5)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2), σ_{VH}^0 e σ_{VV}^0
(6)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2 e $\sigma_{VH}^0 / \sigma_{VV}^0$
(7)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2 e $\sigma_{VH}^0 - \sigma_{VV}^0$
(8)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2), $\sigma_{VH}^0 / \sigma_{VV}^0$ e $\sigma_{VH}^0 - \sigma_{VV}^0$




Figura 4 – Fluxograma da metodologia aplicada

3. Resultados

Para validar os resultados obtidos utilizou-se a matriz de confusão, a exatidão do produtor (EP), a exatidão do utilizador (EU), a exatidão global (EG) e o coeficiente *Kappa*.

No Quadro 3 pode-se verificar a EG e o coeficiente *Kappa* para cada combinação testada. Relativamente ao algoritmo de Redes Neurais não são apresentados os resultados para as combinações (7) e (8) devido às exatidões obtidas estarem muito aquém das esperadas.

De forma geral, a utilização das bandas SAR permitiu uma melhoria na classificação. A combinação que proporcionou melhores resultados foi a (3), que combina as bandas Landsat-8 com o coeficiente de retrodispersão VH, utilizando o algoritmo de classificação SVM. Esta apresentou uma EG de 90,2% e um coeficiente *Kappa* de 85,1 (a negrito no Quadro 3).



Para a classificação multitemporal obteve-se uma exatidão global de 94,1% e um coeficiente *Kappa* de 91,2%, verificando-se uma melhoria significativa quando comparado com os resultados obtidos através da classificação da imagem com os valores de NDVI mais elevados. No Quadro 4 podem-se verificar a matriz de confusão e exatidões do utilizador e produtor para cada cultura.

As exatidões do produtor para a generalidade das culturas apresentaram valores acima dos 90%, com exceção da cultura de Milho que apresenta um valor de 70,1%, devendo-se à confusão existente entre as culturas de Milho e Tomate. As exatidões do utilizador também apresentam valores elevados, sendo o valor menor de 87,6% pertencente à cultura de Tomate.

Quadro 3 – Exatidão Global e coeficiente *Kappa* para as combinações testadas.

Classificador		Combinação							
		(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
ML	EG (%)	86,8	85,5	88,0	87,5	87,8	86,7	87,2	87,2
	<i>Kappa</i> (%)	80,5	78,7	82,3	81,5	82,0	80,3	81,0	81,1
NN	EG (%)	87,8	76,3	88,3	80,6	79,9	77,2	-	-
	<i>Kappa</i> (%)	82,0	63,1	82,2	70,3	68,3	63,9	-	-
SVM	EG (%)	88,6	84,9	90,2	82,9	86,1	83,5	85,0	87,3
	<i>Kappa</i> (%)	82,6	77,3	85,1	73,2	78,6	74,7	77,0	80,7

Quadro 4 – Matriz de Confusão (%), Exatidões do Utilizador e Produtor.

Classe	Arroz	Milho	Pastagens Permanentes	Tomate	Total	EU (%)
Arroz	99,6	6,8	0,0	0,1	47,0	97,5
Milho	0,1	70,1	0,0	2,0	12,4	94,9
Pastagens Permanentes	0,2	0,4	99,9	0,2	9,7	97,7
Tomate	0,1	22,7	0,1	97,6	31,0	87,6
Total	100,0	100,0	100,0	100,0	100,0	
EP (%)	99,6	70,1	100,0	97,6		

Na Figura 5 é representada a evolução temporal da exatidão global da classificação multitemporal. Verificou-se uma melhoria na exatidão global à medida que foram adicionadas novas imagens ao processo de classificação, sendo que na primeira data obteve-se uma exatidão de 88,6% e na última data uma exatidão de 94,1%, como referido anteriormente. Na Figura 6 é apresentado o mapa de culturas obtido através da classificação multitemporal.

4. Conclusões

Perante os resultados obtidos, pode-se afirmar que a integração de dados Sentinel-1 e Landsat-8 permite uma melhoria nos resultados obtidos na classificação de culturas. A combinação das bandas óticas e o coeficiente de retrodispersão na polarização VH permitiram a melhor exatidão, utilizando o algoritmo de classificação SVM. A classificação multitemporal proporcionou um aumento de cerca de 4% na exatidão global obtida, quando comparada com a obtida através da classificação das bandas da data com valores de NDVI mais elevados.

Agradecimentos

As autoras gostariam de agradecer ao IFAP, nomeadamente à Eng^a Célia Sousa, pela cedência da informação relativa às culturas existentes na zona de estudo que constam do Sistema de Identificação de Parcelas.




Figura 5 – Evolução da Exatidão Global da classificação multitemporal.




Figura 6 – Mapa de culturas.

Referências Bibliográficas

- Bargiel, D.; e Herrmann, S. (2011). "Multi-Temporal Land-Cover Classification of Agricultural Areas in Two European Regions with High Resolution Spotlight TerraSAR-X Data." *Remote Sensing*, Vol. 3, No 5, Págs. 860-877.
- Blaes, X.; Vanhalle, L.; Defourny, P. (2005). "Efficiency of crop identification based on optical and SAR image time series." *Remote Sensing of Environment*, Vol. 96, No 3, Págs. 352-365.
- CCRS (2015). "Tutorial: Fundamentals of Remote Sensing", <http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/satellite-imagery-products/educational-resources/9309>, consultada em março de 2015.
- Congalton, R. G.; Green, K. (2009). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC Press.
- Dusseux, P.; Corpetti, T.; Hubert-Moy, L.; Corgne, S. (2014). "Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring." *Remote Sensing*, Vol. 6, No 7, Págs. 6163-6182.
- ESA (2015). "Application of Radiometric Calibration LUT", <https://sentinel.esa.int/web/sentinel/sentinel-1-sar-wiki/-/wiki/Sentinel%20One/Application+of+Radiometric+Calibration+LUT>, consultada em março de 2015.
- Fonseca, A.D.; Fernandes J.C. (2004). *Detecção Remota*. Lidel.
- Forkuor, G.; Corand, C.; Thiel, M.; Ulmann, T.; Zoungrana, E. (2014). "Integration of Optical and Synthetic Aperture Radar Imagery for Improving Crop Mapping in Northwestern Benin, West Africa." *Remote Sensing*, Vol. 6, No 7, Págs 6472-6499.
- Iyyappan, M.; Ramakrishnan, S.; Raju, S. (2014). "Study of Discrimination Between Plantation and Dense Scrub Based on Backscattering Behavior of C Band SAR Data" *IPRS The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XL-9, Págs. 755-760.



- Jin, H.; Mountrakis, G.; Stehman, S.V. (2014). "Assessing integration of intensity, polarimetric scattering, interferometric coherence and spatial texture metrics in PALSAR-derived land cover classification." *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 98, Págs. 70-84.
- Karjalainen, M.; Kaartinen, H.; Hyypä, J. (2008). "Agricultural Monitoring Using Envisat Alternating Polarization SAR images" *Photogrammetric Engineering & Remote Sensing*, Vol. 74, No 1, Págs. 117-126.
- McNairn, H.; Champagne, C.; Shang, J.; Holmstrom, D.; Reichert, G. (2009). "Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories" *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 64, No 5, Págs. 434-449.
- Mirzae, S.; Motagh, M.; Arefi, H.; Nooryazdan, M. (2014). "Classification of agricultural fields using time series of dual polarimetry TerraSAR-X images" *IPRS The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XL-2/W3, Págs. 191-196.
- Mishra, N.; Haque, M.O.; Leigh, L.; Aaron, D.; Helder, D.; Markham, B. (2014). "Radiometric Cross Calibration of Landsat 8 Operational Land Imager (OLI) and Landsat 7 Enhanced Thematic Mapper Plus (ETM+)" *Remote Sensing*, Vol. 6, No 12, Págs. 12619-12638.
- Parker, W.V (2012). "Discover the Benefits of RADAR imaging", <http://eijournal.com/print/articles/discover-the-benefits-of-radar-imaging>, consultada em junho de 2015.
- Plural (2004). "1ª Revisão do Plano Municipal de Vila Franca de Xira", http://www.cm-vfxira.pt/uploads/document/file/67/Plano_Director_Municipal.pdf, consultada em julho de 2015
- Rouse, J.W.; Hass, R.H.; Deering, D.W. (1974) Monitoring The Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation NASA/GSFC, Type III, Final Report.
- Roy, D.P.; Wulder, M.A.; Loveland, T.R.; Woodcock, C.E.; Anderson, M.C.; Helder, D.; Irons, J.R.; Johnson, D.M.; Kennedy, R.; Scambos, T.A.; Schaaf, C.B.; Schott, J.R.; Sheng, Y.; Vermote, E.F.; Belward, A.S.; Bindschadler, R.; Cohen, W.B.; Gao, F.; Hipple, J.D.; Hostert, P.; Huntington, J.; Justice, C.O.; Kilic, A.; Kovalskyy, V.; Lee, Z.P.; Lymburner, L.; Masek, J.G.; McCorkel, J.; Shuai, Y.; Trezza, R.; Vogelmann, J.; Wynne, R.H.; Zhu, Z. (2014). "Landsat-8: Science and product vision for terrestrial global change research" *Remote Sensing of Environment*, Vol. 145, Págs. 154-172.
- Sonobe, R., Tani, H.; Wang, X.; Kobayashi, N.; Shimamura, H. (2014). "Discrimination of crop types with TerraSAR-X-derived information" *Physics and Chemistry of the Earth, Parts A/B/C*.