



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.

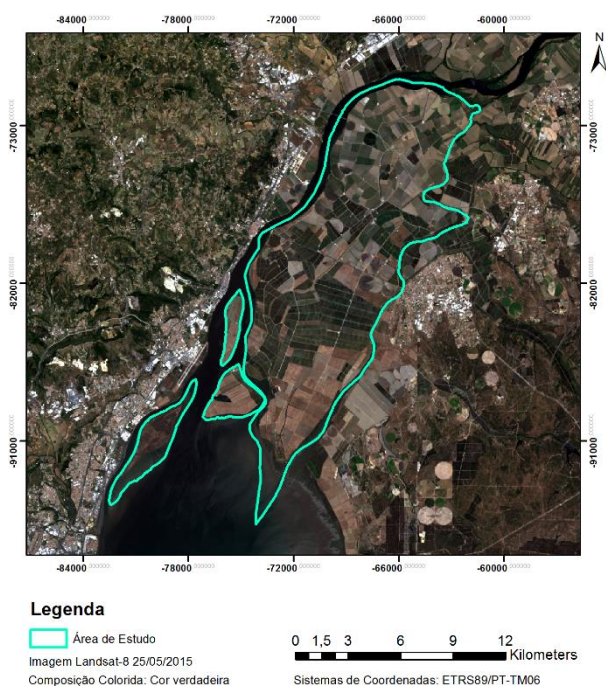


Figura 1 – Área de Estudo

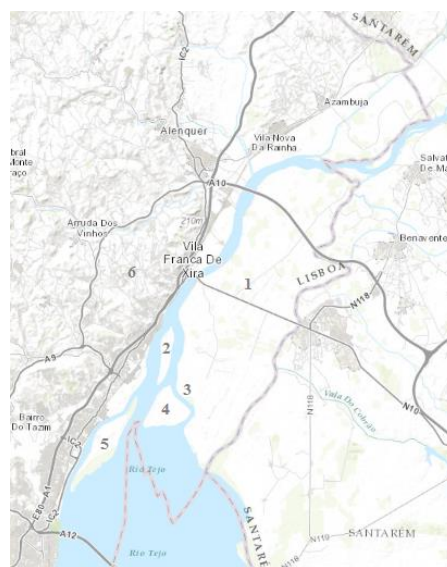


Figura 2 – Freguesia de Vila Franca de Xira

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).

2.2 Imagens de Deteção 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 3).

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 pixel 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 de cada classe para treino e as restantes 50% para validação. 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.

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 1) 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.

Quadro 1 – 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^{0}_{VH}
(4)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2) e σ^{0}_{VV}
(5)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2), σ^{0}_{VH} e σ^{0}_{VV}
(6)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2 e $\sigma^{0}_{VH}/\sigma^{0}_{VV}$
(7)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2 e $\sigma^{0}_{VH} - \sigma^{0}_{VV}$
(8)	Refletâncias espectrais (R, G, B, NIR, SWIR 1 e SWIR 2), $\sigma^{0}_{VH}/\sigma^{0}_{VV}$ e $\sigma^{0}_{VH} - \sigma^{0}_{VV}$

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.

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 2).

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 3 podem-se verificar a matriz de confusão e exatidões do utilizador e produtor para cada cultura.

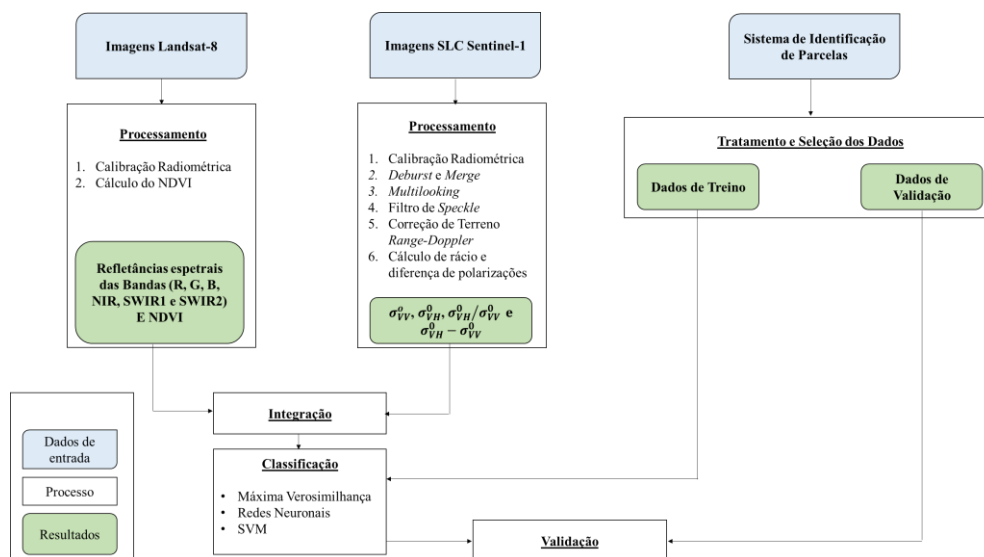


Figura 3 – Fluxograma da metodologia aplicada

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 2 – 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
	Kappa (%)	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	-	-
	Kappa (%)	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
	Kappa (%)	82,6	77,3	85,1	73,2	78,6	74,7	77,0	80,7

Quadro 3 – 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 4 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 5 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 4 – Evolução da Exatidão Global da classificação multitemporal.

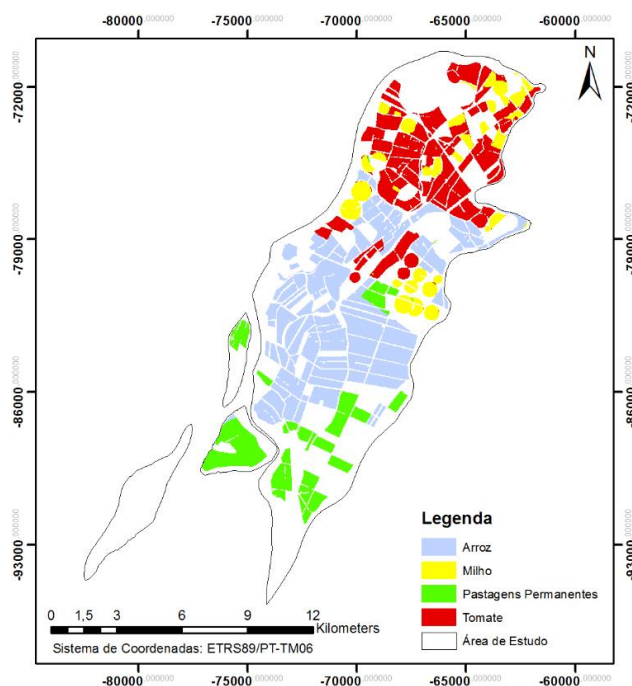


Figura 5 – Mapa de culturas.

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.; Zougrana, 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://ejournal.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.; Kovalsky, V.; Lee, Z.P.; Lyburner, 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*.