



USO DE IMAGENS SENTINEL-1 E SENTINEL-2 PARA O MAPEAMENTO DO TEOR DE ÁGUA DO SOLO À ESCALA DE UMA VINHA

Maria Paula MENDES¹, Magda MATIAS¹, Rui Carrilho GOMES¹ e Ana Paula FALCÃO¹

1. Investigação e Inovação em Engenharia Civil para a Sustentabilidade (CERIS), Instituto Superior Técnico da Universidade de Lisboa, DECIVIL, Av. Rovisco Pais 1049-001 Lisboa – Portugal

mpaulamendes@tecnico.ulisboa.pt, magda.matias@tecnico.ulisboa.pt, rui.carrilho.gomes@tecnico.ulisboa.pt e ana.p.falcao@tecnico.ulisboa.pt

RESUMO

O teor de água no solo (θ) foi reconhecido como uma variável climática essencial pela Organização Mundial de Meteorologia. Apresenta-se uma metodologia para estimar θ a partir das imagens dos satélites Sentinel-1 e Sentinel-2, à escala de uma vinha (área $\cong 48$ ha). As imagens do Sentinel-1 foram submetidas a uma etapa de pré-processamento para avaliação dos coeficientes de retroespalhamento e dos parâmetros do ângulo de incidência. Os resultados foram validados com medições *in situ* de θ nos primeiros 5 cm do solo. Para a estimação de θ utilizou-se o Random Forest. Os resultados obtidos foram animadores sendo possível classificar a humidade do solo da vinha para as três campanhas de monitorização.

Palavras-Chave: Humidade do solo; Sentinel-1; Sentinel-2; Seca; random forest.

1. INTRODUÇÃO

O teor de água no solo (θ) foi reconhecido como uma variável climática essencial pela Organização Mundial de Meteorologia. As secas agrícolas estão diretamente relacionadas com a falta de θ e, traduzem-se na redução do rendimento e crescimento das culturas. As condições antecedentes de θ desempenham um papel fundamental na geração de cheias (Wasko & Nathan, 2019). O θ é igualmente, importante para a aferição da recarga de um aquífero (Mathias et al., 2017). Contudo, existem muitas lacunas em relação aos dados existentes de θ , sendo estes dados difíceis de extrapolar espacialmente.

O uso de imagens de radar como a constelação Sentinel-1 (S1) (composta por dois satélites S1-A e S1-B) para aferição de θ é uma solução económica para a monitorização do θ devido ao acesso livre a estes dados, disponibilizados com uma elevada resolução espacial e temporal. As imagens de radar são adquiridas por sensores ativos, menos sensíveis às condições meteorológicas. No entanto, a retrodispersão das microondas é o resultado de características dos sensores (frequência, polarização, ângulo de incidência e órbita) e das propriedades da superfície do solo (gradiente de inclinação, rugosidade e humidade) (Heleno et al., 2011; Pestana, 2013). O uso do sinal do radar conjuntamente com as imagens multiespectrais, contribui para uma melhor estimativa do θ . Para solo nu, a reflectância da banda vermelha (RED) e infravermelho próximo (NIR) aumenta com a diminuição do θ . Por outro lado, em áreas com cobertura vegetal, a reflectância da banda RED é baixa e a reflectância da banda NIR é elevada (Amani et al., 2016; Petropoulos et al., 2015).

Os algoritmos de aprendizagem de máquina supervisionada (MLA) podem ser usados para resolver problemas de classificação onde o nosso conhecimento teórico é incompleto, pois podem reconhecer padrões não lineares entre características de diferentes origens e o θ . Apresenta-se uma metodologia, em que é mapeado a probabilidade de ocorrência de um valor de θ através do recurso a imagens dos satélites S1 e S2 (multiespectral), e o uso do MLA- o Random Forest (RF).

2. ENQUADRAMENTO

O estudo localiza-se na Companhia das Lezírias (CL) (38°48'44,00"N, 8°53'2,03"W, 20 metros) no concelho de Benavente. O trabalho de campo foi realizado na Vinha do Catapereiro (área \cong 48 ha), sendo delimitados dois locais (lotes A e C) para treinamento do RF com uma área média de 3 hectares (Fig. 1).

O RF foi treinado e validado com os teores de humidade do solo medidos “*in situ*” a 5 cm de profundidade, usando-se uma sonda TDR (Theta Probe tipo ML2x). Foram realizadas três campanhas de campo para medição de θ (5 de dezembro de 2017, 26 de janeiro de 2018 e 5 de maio de 2018). As variáveis descritivas usadas para modelar o θ correspondem a imagens de radar com polarização VV, imagens multiespectrais nas bandas do RED e do NIR, e num modelo de elevação digital do terreno (MED) da vinha. O MED foi gerado a partir de 216 pontos georreferenciados com um equipamento GPS Trimble diferencial. A altitude mais elevada é de cerca de 18,9 m, a mínima é de 10,4 m e a altitude média é de 16 m, os declives são suaves (declive médio igual a 1,1%).

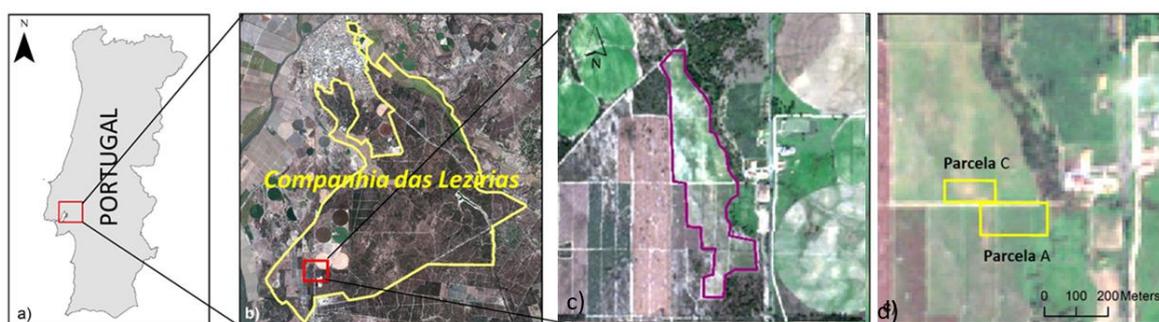


Fig. 1. Localização da Vinha do Catapereiro a) b) c) e das parcelas A e C d).

2.1. Episódios climáticos extremos

Segundo a classificação de Köppen, a área do estudo possui clima mediterrânico, com verões quentes e secos. 2017 foi um ano extremamente quente e seco, sendo a temperatura média do ar cerca de 1,1°C acima do que é normal e, a precipitação anual foi 60% abaixo do valor normal. Ao longo deste ano, a combinação de valores persistentes de precipitação abaixo do normal com temperaturas muito acima do normal, em particular a temperatura máxima, resultou em elevadas taxas de evapotranspiração e deficit significativo de θ . A Fig.2 mostra que, de fevereiro a junho de 2017, as temperaturas médias mensais foram superiores às normais. Além disso, de abril a outubro de 2017, a precipitação mensal foi muito baixa. Em dezembro, esta região ainda estava em seca severa e isso é muito explícito nos valores de θ medidos nas parcelas no campo.

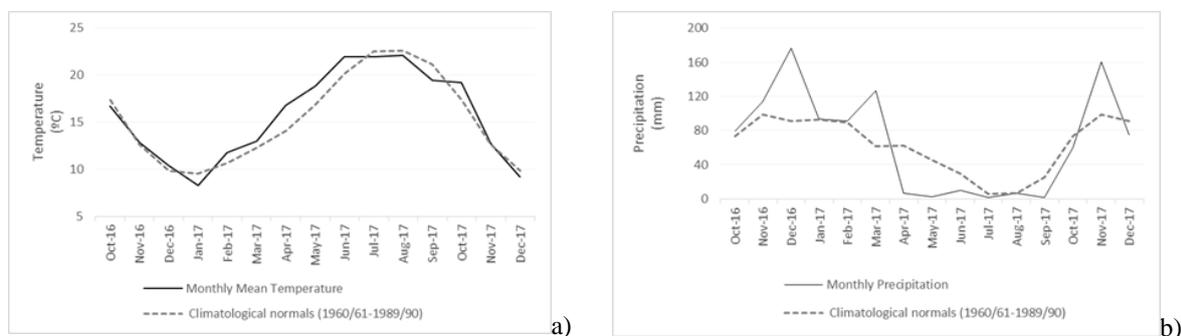


Fig. 2- a) Temperatura média mensal na estação de Barragem de Magos (38°59'38.01"N, 8°41'20.00"W) de outubro de 2016 a dezembro de 2017 (linha a cheio) e, as normais climatológicas para o período de 1960/61 a 1989/90 (linha a pontilhado); b) Precipitação mensal de outubro de 2016 a dezembro de 2017 (linha a cheio) e, as normais climatológicas para o período de 1960/61 a 1989/90 (linha a pontilhado).

3. MÉTODOS

3.1. Random Forest, seleção de atributos e medidas de desempenho

O RF é um método que agrupa árvores de decisão (AD), crescendo cada uma das árvores a partir de um subgrupo do conjunto de treinamento, escolhido aleatoriamente e, com reposição e, onde os atributos (variáveis preditivas) são escolhidos aleatoriamente (Breiman, 2001). As AD podem dividir-se em árvores de classificação (AC) e de regressão (AR). Na AC, a árvore cresce desde a raiz a um nó terminal ou folha baseado em medidas como o Índice de Gini que determinam a “pureza da árvore”, otimizando as divisões. No RF cada AC representa um voto numa classe e a classificação final baseia-se na maioria dos votos (Breiman et al., 1984). No RF “embedded” normalmente o subconjunto que não é selecionado para o crescimento da AC (denominado “out-of-bag”, oob) é utilizado para avaliação do desempenho e para a construção de uma medida da importância dos atributos. A importância de um atributo também é medida com base na melhoria no critério da divisão num nó de uma árvore, e esta importância é acumulada para todas as árvores para cada atributo (Rodríguez-Galiano et al., 2018). Além do erro de classificação (erro oob), a medida F é usada, sendo a média harmónica da precisão (i.e., a probabilidade de sucesso na identificação da classe certa de um fenómeno) e da exatidão (i.e., a probabilidade de fenómeno previsto como sendo da classe positiva ser um verdadeiro positivo).

3.2. Detecção Remota

Durante o período de monitorização foram descarregadas 15 cenas, 11 do Sentinel-1 A e B, Nível 1, interferometria ampla (IW) e Single Look Complex (SLC) e quatro cenas do Sentinel-2 MultiSpectral Instrument (MSI). Polarizações VV e ângulos de incidência local variando de 30° a 46° foram extraídas do processo de correção de imagens SAR. Essas correções foram realizadas no software SNAP fornecido pela ESA, onde a calibração radiométrica, seguida de Deburst, processo Multilooking, filtro Refined Lee e, correção do Range Doppler Terrain foram executadas. Seguidamente, os dados SAR com resolução de aproximadamente 10 m foram projetados nas coordenadas WGS 1984 UTM e, em seguida, reprojutados no sistema de referência PT-TM06/ETRS89.

4. RESULTADOS

O RF teve as melhores medidas de desempenho ($F = 0,82$; oob = 12,6%) durante dez/17 para a classificação das duas classes binárias (abaixo e acima de um θ igual a 14%). Este valor de corte de 14% foi escolhido por ser o valor mediano, medido “in situ”, mais baixo para as três datas monitorizadas. De acordo, com os resultados da importância dos atributos, o MED foi o atributo que melhor definiu as áreas com teores de humidade mais elevadas e baixas para as três campanhas. Em dez/17, os valores de NIR e RED foram mais importantes para a classificação de probabilidade de ocorrência de classes acima dos 14%, do que as imagens do SAR. Em jan/18, o RF ainda teve um bom desempenho ($F = 0,73$; oob = 19,7%), tendo sido selecionadas as seguintes variáveis pelo algoritmo: MED, duas imagens SAR (S1BEA99-ascendente e S1AA139-descendente) e o NIR. Finalmente, em mai/18 o RF não teve um bom desempenho ($F = 0,35$; oob = 12,6%), estando a vinha já no seu período de floração. Neste caso, apenas uma das classes foi bem classificada ($\theta > 14\%$).

A Fig. 3 apresenta os mapas de classificação obtidos pelo RF, em que se pode ver que em jan de 2018 se obteve a maior extensão na vinha com humidades do solo inferiores a 14% ($\approx 35,7\%$ da área total).

5. CONCLUSÕES

A metodologia testada demonstrou que durante o período de senescência da vinha (dez/17 e jan/18) foi quando o RF teve o melhor desempenho. Tal deve-se em parte aos dados de treinamento, principalmente ao equilíbrio das duas classes em relação ao valor de corte. O uso conjunto das imagens de radar e multispectral permitiu a classificação da humidade do solo à escala de uma vinha, sendo possível delimitar as áreas com menor teor de humidade e caracterizar o seu comportamento temporal ao longo das três campanhas. Estes resultados são animadores pretendendo-se seguir esta linha de investigação para definir os períodos de seca agrícola.

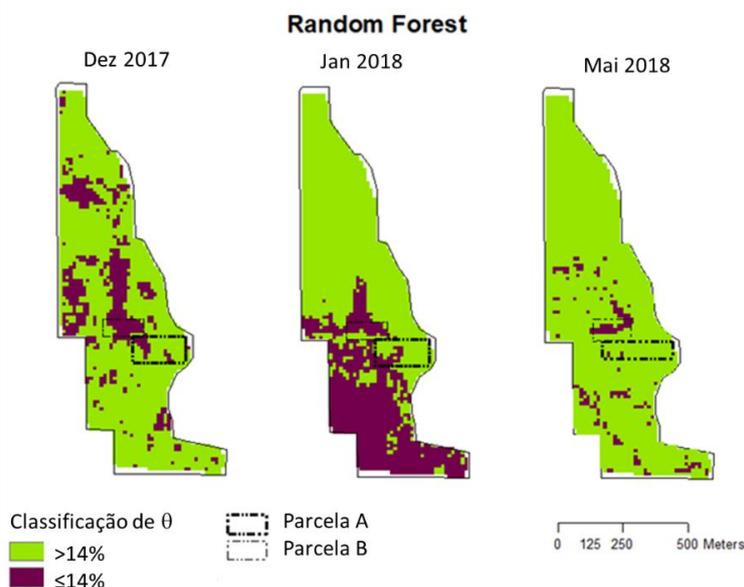


Fig. 3) Resultados da classificação para as três campanhas (Dez-17, Jan-18 e Mai-18).

AGRADECIMENTOS

Os autores agradecem ao CERIS pelo financiamento do projeto de investigação exploratório AQUIREMOTE, 2017.

REFERÊNCIAS BIBLIOGRÁFICAS

- Amani, M., Parsian, S., MirMazloumi, S. M., & Aieneh, O. (2016). Two new soil moisture indices based on the NIR-red triangle space of Landsat-8 data. *International Journal of Applied Earth Observation and Geoinformation*, 50, 176–186. <https://doi.org/10.1016/j.jag.2016.03.018>
- Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. A. (1984). *Classification and Regression Trees*. Taylor & Francis. Retrieved from <https://books.google.pt/books?id=JwQx-WOmSyQC>
- Breiman, Leo. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Heleno, S. I. N., Oliveira, L. G. S., Henriques, M. J., Falcão, A. P., Lima, J. N. P., Cooksley, G., et al. (2011). Persistent Scatterers Interferometry detects and measures ground subsidence in Lisbon. *Remote Sensing of Environment*, 115(8), 2152–2167. <https://doi.org/https://doi.org/10.1016/j.rse.2011.04.021>
- Mathias, S. A., Sorensen, J. P. R., & Butler, A. P. (2017). Soil moisture data as a constraint for groundwater recharge estimation. *Journal of Hydrology*, 552, 258–266. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2017.06.040>
- Pestana, R. et al. (2013). Calibration Of 2D Hydraulic Inundation Models In The Floodplain Region Of The Lower Tagus River. In *ESA Living Planet Symposium 2013* (Vol. 2013SP-722, p. 5). Edinburgh: ESA.
- Petropoulos, G. P., Ireland, G., & Barrett, B. (2015). Surface soil moisture retrievals from remote sensing: Current status, products & future trends. *Physics and Chemistry of the Earth, Parts A/B/C*, 83–84, 36–56. <https://doi.org/https://doi.org/10.1016/j.pce.2015.02.009>
- Rodriguez-Galiano, V., Luque-Espinar, J. A., Chica-Olmo, M., & Mendes, M. P. (2018). Feature selection approaches for predictive modelling of groundwater nitrate pollution: An evaluation of filters, embedded and wrapper methods. *Science of the Total Environment*, 624. <https://doi.org/10.1016/j.scitotenv.2017.12.152>
- Wasko, C., & Nathan, R. (2019). Influence of changes in rainfall and soil moisture on trends in flooding. *Journal of Hydrology*, 575(May), 432–441. <https://doi.org/10.1016/j.jhydrol.2019.05.054>