



ID 831: CLASSIFICAÇÃO DO USO E OCUPAÇÃO DO SOLO COM RECURSO AO MÉTODO TIME-WARPED DYNAMIC TIME WARPING⁹²

Cláudia M. VIANA¹; Jorge ROCHA²

¹Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa, claudiaviana@campus.ul.pt

²Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa, jorge.rocha@campus.ul.pt

RESUMO: O aumento da disponibilidade e do volume de dados provenientes de deteção remota permitem monitorizar e mapear as alterações do uso e ocupação do solo que ocorreram durante as últimas décadas. O principal objetivo deste estudo é classificar o uso e ocupação do solo, e analisar as mudanças espaço-temporais entre 2000 e 2017, com foco nos solos agrícolas, numa área localizada no distrito de Beja, Alentejo, Portugal. Para classificar e monitorizar a dinâmica do uso e ocupação do solo, utilizou-se o algoritmo de classificação Time-Warped Dynamic Time Warping (TWDTW) por forma a analisar as variações sazonais dos tipos de vegetação natural e cultivada. Através dos dados de imagens de deteção remota, foram identificadas cinco classes de uso e ocupação do solo: Terras Agrícolas Heterogéneas, Olival, Pastagens permanentes, Floresta e Água. A análise de desempenho e sensibilidade do método para cada classe apresentou um elevado intervalo de confiança já que, ao selecionarmos aleatoriamente 10% dos nossos pontos de amostra para criar padrões temporais, obteve-se uma exatidão global de pelo menos 71,5% na classificação do uso e ocupação do solo, com um nível de confiança de 95%. Os resultados da classificação revelam que em 18 anos houve consideráveis alterações no uso e ocupação do solo, destacando-se as alterações nos padrões temporais do Olival. Com este estudo concluiu-se que o algoritmo TWDTW é capaz de classificar convenientemente o uso e ocupação do solo, permitindo obter um quadro geral das principais transformações espaço-temporais ocorridas numa área caracterizada por distintas práticas agrícolas.

PALAVRAS-CHAVE: uso e ocupação do solo, deteção remota, Landsat, TWDTW, índices vegetação

1. INTRODUÇÃO

Um dos grandes desafios do século XXI será a produção de alimentos suficiente para abastecer toda a população mundial, prevista em nove biliões até 2050 (FAO, 2010). Por questões

⁹² Esta investigação foi financiada pela Fundação para a Ciência e a Tecnologia (FCT) [número SFRH/BD/115497/2016 atribuída a Cláudia M. Viana]. Agrademos ao GEOMODLAB (CEG/IGOT) por fornecer o equipamento e o software necessários para desenvolver este estudo.



ecológicas e de gestão sustentável torna-se crucial obter informações sobre a extensão e o estado do crescimento dos solos cultiváveis ao nível espaço-temporal. Na Europa Mediterrânea houve mudanças significativas nas áreas rurais e no setor agrícola (Vicente-Serrano and Heredia-Laclaustra, 2004), destacando-se a diminuição das áreas agrícolas em detrimento da floresta (Fuchs et al., 2015). Detetar estas mudanças é uma informação de importância crescente, tornando-se essencial uma observação oportuna e efetiva da distribuição destes solos.

Na literatura de deteção remota são mencionados vários classificadores de uso e ocupação do solo (Phiri and Morgenroth, 2017), como os classificadores não paramétricos, por exemplo, o *random forest* (RF) (Breiman, 2001) e o *support vector machine* (SVM) (Huang et al., 2002). Contudo, desafios permanecem em relação à classificação do uso e ocupação do solo baseada em séries temporais (Petitjean et al., 2012), sendo eles: (i) insuficientes amostras necessárias para treinar o algoritmo supervisionado, (ii) ausência de dados temporais e, (iii) irregularidade nas assinaturas fenológicas temporais dos diferentes tipos de uso e ocupação do solo (Maus et al., 2016b; Petitjean et al., 2012). No entanto, o método Dynamic Time Warping (DTW) demonstrou ser uma solução capaz de lidar com estes desafios (Baumann et al., 2017; Petitjean et al., 2012), pois o seu algoritmo compara uma assinatura temporal de um evento conhecido com uma série temporal desconhecida, reconhecendo todos os possíveis alinhamentos entre duas séries temporais e fornecendo medidas de dissimilaridade (Rabiner and Juang, 1993). Embora não considere o intervalo temporal ao tentar encontrar as melhores combinações de pares entre duas séries temporais (Maus et al., 2016b) este algoritmo foi aplicado para análise de séries temporais de imagens de satélite (Guan et al., 2016; Maus et al., 2016b; Petitjean et al., 2012).

O ciclo fenológico distintivo de cada classe de uso e ocupação do solo requer um equilíbrio entre a correspondência das formas e o alinhamento temporal (Reed et al., 1994) sendo esta a razão para Maus et al. (2016a) aprimorar o método DTW para torná-lo sensível às mudanças sazonais dos tipos de vegetação natural e cultivada. O recente método TWDTW inclui uma ponderação de tempo para considerar a sazonalidade permitindo distinguir as diferentes classes de uso e ocupação do solo (Belgiu and Csillik, 2018; Maus et al., 2016b).

Como Zhu and Woodcock (2014) enfatizam no seu estudo, a capacidade de identificar as mudanças de uso e ocupação do solo com precisão depende de um algoritmo que possa utilizar dados de alta resolução espacial e que seja baseado numa análise multitemporal. No entanto, devido a algumas limitações (por exemplo, fenologia, ângulo do sol, nuvens, erros de sensor, etc.), a análise multitemporal é tipicamente desenvolvida ao nível anual ou bienal (Zhu and Woodcock, 2014). Assim, e considerando os resultados aprimorados do método TWDTW, nesta



investigação aplicamos este método por forma a avaliar como se comporta quando aplicado a uma longa série temporal utilizando dados Landsat. O presente estudo pretende avaliar o método TWDTW para classificação de solos agrícola com base no Landsat *Normalized Difference Vegetation Index* (NDVI), Landsat *Bare-soil Index* (BI) e Landsat *Normalized Difference Water Index* (NDWI) para uma região localizada no Alentejo, Portugal.

2. ÁREA DE ESTUDO E DADOS

2.1. ÁREA DE ESTUDO

A aplicação do método TWDTW foi realizada numa área com cerca de 10 X 4 km² localizada no Alentejo entre os municípios da Vidigueira e Serpa, pertencentes ao distrito de Beja. Esta região é caracterizada pelos diferentes tipos de cultivo, como as extensas áreas de montado, oliveiras, campos de trigo e sobreiros, sendo o tipo de uso e ocupação do solo dominante o agro-silvo-pastoral misto. Os diferentes calendários de cultivo e geometrias de campo, justificadas pelas diferentes práticas agrícolas, diferenciam a paisagem desta região, com a existência de parcelas fragmentadas e parcelas maiores e compactas.

2.2. SELEÇÃO DE IMAGENS DE SATÉLITE E PRÉ-PROCESSAMENTO

A partir do site oficial do Serviço Geológico dos Estados Unidos (USGS) recolheu-se um conjunto de imagens de satélite Landsat (path 203 e row 34). Apenas imagens sem nuvens ou próximo de zero (<10%) foram usadas. Uma vez que utilizaram-se dados Landsat de Nível 2 nenhuma correção atmosférica foi realizada. Para compor a longa série temporal combinou-se um conjunto de imagens de dados Landsat 4-5 Nível 2 e Landsat 7 Nível 2, contando com um total de 67 cenas de estação quente (os dados correspondem ao final do mês de junho, julho, agosto ou início de setembro). Este período foi escolhido para reduzir a variabilidade inter-anual e facilitar a diferenciação das classes de uso e ocupação do solo.

3. METODOLOGIA

3.1. DERIVAÇÃO DOS ÍNDICES DE VEGETAÇÃO (NDVI, NDWI E BI)

Para simplificar a classificação do uso e ocupação do solo usando séries temporais de imagens de satélite, calculou-se três séries temporais de índices: (1) o *Normalized Difference Vegetation*



Index (NDVI), (2) o *Bare-soil Index* (BI) e (3) o *Normalized Difference Water Index* (NDWI).

Para derivar estes índices usaram-se as fórmulas demonstradas no Quadro I.

Tabela 106 **Fórmulas para derivar os índices**

Índice de vegetação	Fórmula	Referência
NDVI	$NDVI = \frac{TM \text{ Band } 4 - TM \text{ Band } 3}{TM \text{ Band } 4 + TM \text{ Band } 3}$	(Rouse et al., 1973)
NDWI	$NDWI = \frac{TM \text{ Band } 4 - TM \text{ Band } 5}{TM \text{ Band } 4 + TM \text{ Band } 5}$	(McFeeters, 1996)
BI	$BI = \frac{(TM \text{ Band } 5 + TM \text{ Band } 3) - (TM \text{ Band } 4 + TM \text{ Band } 1)}{(TM \text{ Band } 5 + TM \text{ Band } 3) + (TM \text{ Band } 4 + TM \text{ Band } 1)}$	(Li and Chen, 2014)

3.2. AMOSTRAS DE TREINO

Para confirmar os diferentes estágios fenológicos da vegetação e identificar as mudanças temporais das classes de uso e ocupação do solo, foram gerados pontos aleatórios na área de estudo. Estes foram classificados com base em conhecimento empírico usando a interpretação visual de imagens Landsat, imagens de alta resolução do Google Earth e a cartografia oficial de uso do solo (escala de 1: 25.000). Foram identificadas 280 amostras no período de 2000-06-17 a 2017-09-20 divididas em cinco classes (“Terras Agrícolas Heterogéneas”, “Olival”, “Pastagens permanentes”, “Floresta” e “Água”).

4. RESULTADOS

4.1. ANÁLISE DAS MUDANÇAS NO USO E OCUPAÇÃO DO SOLO

Foi usada uma medida de distância para criar mapas categóricos do uso e ocupação do solo, onde o resultado da classificação é baseado no padrão mais similar para cada período de tempo. Os resultados da classificação para cada período podem ser visualizados a partir da Figura I. Estes resultados permitem compreender que houve algumas mudanças significativas, principalmente entre o período 2000-2008 com o aumento substancial de zonas de água e Terras Agrícolas Heterogéneas.



Figura 228 Classificação do uso e ocupação do solo para cada período de tempo (2000-2017)

A área acumulada para cada classe ao longo do tempo pode ser visualizada na Figura II. Destaca-se uma notória diminuição linear de áreas florestais entre 2000 e 2007, ocupando uma área de cerca de 11% em 2017. A classe “Água” teve um aumento linear de 2000 a 2007, passando de cerca de 1% da área total em 2000 para 7% em 2017, com um aumento significativo entre 2005-2006 (3%). No grupo de classes agrícolas, predominaram as áreas de “Terras Agrícolas Heterogêneas”, ocupando uma área total próxima a 43% de 2000 a 2017. As áreas de “Pastagens permanentes” apresentaram oscilações entre 2000 e 2007, ocupando uma área total de 25% a 27%, respetivamente. A área de “Olivais” registou uma diminuição linear da área total, perdendo cerca de 3% da área entre 2000 e 2017.




Figura 229 Percentagem de área para cada classe de uso e ocupação do solo de 2000 a 2017



4.2. COMPARAÇÕES DA PRECISÃO DE CLASSIFICAÇÃO ENTRE OS MÉTODOS TWDTW, SVM E RF

O método TWDTW alcançou o maior valor do coeficiente de kappa (58%), seguido pelo método SVM (50%). O método RF alcançou o menor valor (41%). Para os três métodos, a precisão do usuário e do produtor para a classe “Água” atingiu os valores mais altos (cerca de 100%). A classe “Florestas” obteve um valor de precisão alto para produtor para todos os métodos (acima de 87%), mas apenas o método TWDTW alcançou uma alta precisão de usuário (83%). Em relação às classes agrícolas, todos os métodos apresentaram baixa precisão do produtor (abaixo de 57%), com exceção da classe “Pastagens permanentes” ao utilizar o método TWDTW (78%). A maior precisão das classes agrícolas por parte dos usuários foi na classe “Pastagens permanentes” usando o método SVM (79%) e o método RF (71%). No entanto, a precisão do usuário obtida para esta classe utilizando o método TWDTW é muito menor (49%). Destaca-se o alto valor de precisão do usuário para o “Olival” usando o método TWDTW (73%) contra os 56% do método SVM e os 41% do método de RF.

5. DISCUSSÃO

Neste estudo, investigou-se o desempenho do método TWDTW (Maus et al., 2016a, 2016b) na classificação dos solos agrícolas de uma longa série temporal baseada em períodos sazonais usando três índices espectrais normalizados derivados de dados Landsat. O método foi aplicado numa área de estudo localizada no sudeste de Portugal, caracterizada por um ecossistema agro-silvo-pastoral misto que inclui olivais, pastagens permanentes, agricultura extensiva e áreas florestais. Os resultados obtidos mostram que o algoritmo TWDTW é capaz de classificar o uso e ocupação do solo no espaço e no tempo, uma vez que identificou as classes de uso predominantes de uma área heterogênea. Das cinco classes identificadas no processo de classificação, a “Água” alcançou o maior valor de precisão do usuário e do produtor, e a “Floresta” obteve alta precisão do usuário, mas a precisão do produtor foi baixa. Das três classes agrícolas, as “Pastagens permanentes” apresentam a maior precisão do produtor, mas uma baixa precisão do usuário. Ambos, “Olival” e “Terras agrícolas heterogêneas” alcançaram baixa precisão de usuário e produtor. No entanto, os resultados obtidos, juntamente com os resultados de (Belgiu and Csillik, 2018; Maus et al., 2016b) apontam o potencial deste método na classificação dos diferentes tipos de culturas. Quando comparados com outros métodos de classificação bem estabelecidos na literatura de detecção remota, como o RF (Breiman, 2001) e o



SVM (Huang et al., 2002), o método TWDTW alcançou o maior valor de coeficiente kappa, confirmando o seu potencial para classificar os solos agrícolas num ecossistema complexo.

Além disso, este estudo pretendeu avaliar o desempenho do método TWDTW para a classificação de solos agrícolas usando uma série temporal de 18 anos, o que significou falta de amostras de treino, já que seria muito improvável que para cada um desses anos existissem dados. Esta restrição resultou num número reduzido de amostras de treino, distribuídas irregularmente ao longo do tempo, e pode não ser 100% preciso, uma vez que não foram obtidas por meio de trabalho de campo. Como a classificação é extremamente dependente da qualidade dos padrões espectro-temporais, e estes são gerados usando as amostras de treino, o bom desempenho deste método pode ficar comprometido. Mesmo assim, e considerando esta restrição, o TWDTW obteve uma precisão geral razoável de 71,5%.

6. CONCLUSÕES

Os solos agrícolas estão ameaçados por uma enorme pressão económica que tem influenciado fortemente as práticas agrícolas. Para obter informações sobre a extensão dos solos cultiváveis, tanto em escalas espaciais quanto temporais, é fundamental avaliar os métodos atuais de classificação de imagens para distintas regiões. Neste estudo, o método TWDTW foi utilizado para classificar uma área heterogénea localizada no sudeste de Portugal, permitindo compreender as principais mudanças ocorridas ao longo de 18 anos. Esta longa série anual baseada em anos, derivada de dados Landsat, facilitou as comparações significativas das mudanças interanuais na atividade dos tipos de solos agrícolas, uma vez que cada tipo de uso e ocupação tem um ciclo fenológico distinto associado à vegetação e que estas podem variar de ano para ano. No entanto, este trabalho permitiu obter um retrato geral das transições de uso e ocupação do solo ocorridas de ano para ano numa área de estudo onde predomina um tipo de cultivo bastante heterogéneo.

7. BIBLIOGRAFIA

Baumann, M., Ozdogan, M., Richardson, A.D., Radeloff, V.C., 2017. Phenology from Landsat when data is scarce: Using MODIS and Dynamic Time-Warping to combine multi-year Landsat imagery to derive annual phenology curves. *Int. J. Appl. Earth Obs. Geoinf.* 54, 72–83. <https://doi.org/10.1016/J.JAG.2016.09.005>

Belgiu, M., Csillik, O., 2018. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sens. Environ.* 204, 509–523. <https://doi.org/10.1016/j.rse.2017.10.005>



Breiman, L., 2001. Random Forests. *Mach. Learn.* 45, 5–32.
<https://doi.org/10.1023/A:1010933404324>

FAO, 2010. The State of Food Insecurity in the World: Addressing food insecurity in protracted crises, Notes. <https://doi.org/10.1519/JSC.0b013e3181b8666e>

Fuchs, R., Herold, M., Verburg, P.H., Clevers, J.G.P.W., Eberle, J., 2015. Gross changes in reconstructions of historic land cover/use for Europe between 1900 and 2010. *Glob. Chang. Biol.* 21, 299–313. <https://doi.org/10.1111/gcb.12714>

Guan, X., Huang, C., Liu, G., Meng, X., Liu, Q., 2016. Mapping rice cropping systems in Vietnam using an NDVI-based time-series similarity measurement based on DTW distance. *Remote Sens.* 8. <https://doi.org/10.3390/rs8010019>

Huang, C., Davis, L.S., Townshend, J.R.G., 2002. An assessment of support vector machines for land cover classification. *Int. J. Remote Sens.* 23, 725–749.
<https://doi.org/10.1080/01431160110040323>

Li, S., Chen, X., 2014. A new bare-soil index for rapid mapping developing areas using landsat 8 data. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.* 40, 139–144.
<https://doi.org/10.5194/isprsarchives-XL-4-139-2014>

Maus, V., Câmara, G., Appel, M., Pebesma, E., 2016a. dtwSat: Time-Weighted Dynamic Time Warping for Satellite Image Time Series Analysis in R. *J. Stat. Softw.*

Maus, V., Camara, G., Cartaxo, R., Sanchez, A., Ramos, F.M., Ribeiro, G.Q., 2016b. A Time-Weighted Dynamic Time Warping Method for Land-Use and Land-Cover Mapping. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 9(8), 3729–3739.
<https://doi.org/10.1109/JSTARS.2016.2517118>

McFeeters, S.K., 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *Int. J. Remote Sens.* 17, 1425–1432.

Petitjean, F., Inglada, J., Gancarski, P., 2012. Satellite Image Time Series Analysis Under Time Warping. *Geosci. Remote Sensing, IEEE Trans.* 50, 3081–3095.
<https://doi.org/10.1109/TGRS.2011.2179050>

Petitjean, F., Weber, J., 2014. Efficient Satellite Image Time Series Analysis Under Time Warping. *Geosci. Remote Sens. Lett. IEEE* 11, 1143–1147.
<https://doi.org/10.1109/LGRS.2013.2288358>



- Phiri, D., Morgenroth, J., 2017. Developments in Landsat land cover classification methods: A review. *Remote Sens.* 9. <https://doi.org/10.3390/rs9090967>
- Rabiner, L., Juang, B., 1993. *Fundamentals of Speech Recognition*. Inc., New Jersey.
- Reed, B.C., Brown, J.F., VanderZee, D., Loveland, T.R., Merchant, J.W., Ohlen, D.O., 1994. Measuring phenological variability from satellite imagery. *J. Veg. Sci.* 5, 703–714. <https://doi.org/10.2307/3235884>
- Rouse, J.W., Hass, R.H., Schell, J.A., Deering, D.W., 1973. Monitoring vegetation systems in the great plains with ERTS. *Third Earth Resour. Technol. Satell. Symp.* 1, 309–317. <https://doi.org/citeulike-article-id:12009708>
- Vicente-Serrano, S.M., Heredia-Laclaustra, A., 2004. NAO influence on NDVI trends in the Iberian peninsula (1982-2000). *Int. J. Remote Sens.* 25, 2871–2879. <https://doi.org/10.1080/01431160410001685009>
- Zhu, Z., Woodcock, C.E., 2014. Continuous change detection and classification of land cover using all available Landsat data. *Remote Sens. Environ.* 144, 152–171. <https://doi.org/10.1016/J.RSE.2014.01.011>