

BIG DATA, MACHINE LEARNING E MODELOS AGNÓSTICOS NA IDENTIFICAÇÃO DO BEM-ESTAR EM ESPAÇO URBANO

BETCO¹, Iuria; **ENCALADA-ABARCA**², Luis; **NOGUEIRA**³, Paulo; **ROCHA**⁴, Jorge

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

² Centro de Estudos Geográficos, Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa, Portugal, luisencalada@campus.ul.pt

³ Laboratório Associado Terra & Instituto de Saúde Ambiental, Faculdade de Medicina, Universidade de Lisboa, Portugal, pnogueira@medicina.ulisboa.pt

⁴ Centro de Estudos Geográficos e Laboratório Associado TERRA, Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa, Portugal, jorge.rocha@campus.ul.pt

RESUMO: Este estudo tem o intuito de compreender o impacto que o ambiente urbano tem na felicidade dos indivíduos na cidade de Lisboa no ano de 2019. A análise do bem-estar com recurso à rede social Twitter permite identificar os locais em que o bem-estar (sentimento positivo) e mal-estar (sentimento negativo) predominam. Contudo, as pessoas recebem diferentes tipos de informação sensorial de um espaço, tornando-se desafiador determinar quais os aspetos da experiência no ambiente urbano que afetam o bem-estar. Este estudo explora a utilização de um modelo de *machine learning* juntamente com uma abordagem de modelo-agnóstico de modo a aumentar a compreensão das condições dos ambientes urbanos que podem explicar as variáveis que influenciam o sentimento. Os resultados deste estudo demonstram que os lisboetas são felizes na proximidade de espaços verdes e em locais populares. Tendo-se concluído que os dados do Twitter são um bom *proxy* para a análise de sentimento e que os modelos agnósticos, principalmente o *SHAP*, desempenham um papel fundamental neste tipo de análise.

PALAVRAS-CHAVE: Bem-estar; análise de sentimento; morfologia urbana; *machine learning*

1. INTRODUÇÃO

À medida que o mundo se torna cada vez mais urbanizado, planeadores e profissionais de saúde vão ficando preocupados com os impactos dos ambientes urbanos no bem-estar mental dos residentes. Embora a qualidade de vida em geral tenha melhorado em todo o mundo, os problemas de saúde mental aumentaram, principalmente nos países industrialmente desenvolvidos. As populações modernas estão cada vez mais sobrealimentadas, paradoxalmente desnutridas, sedentárias,

privadas de sono e luz solar, e socialmente isoladas (Hidaka, 2012). O estilo de vida urbano tem contribuído para o atual estado de saúde mental (Reeves *et al.*, 2011).

A forma e as características da maioria dos locais da cidade moldam a nossa interação com os outros e com o ambiente como um todo, desencadeando processos emocionais, cognitivos, afetivos e comportamentais, a nível pessoal e de grupo (Romice *et al.*, 2016). As evidências empíricas demonstraram que os fatores ambientais podem impactar positiva e negativamente o bem-estar mental, mas existem poucas diretrizes para os planeadores das cidades sobre como aumentar ou evitar certos ambientes para o bem-estar mental (Hajrasoulih *et al.*, 2018), sendo fundamental determinar quais os fatores que podem contribuir para alcançar esse objetivo, de modo a projetar a cidade nesse sentido. A questão adicional é, em que medida cada fator é quantitativamente influente, e qual desses critérios terá a maior prioridade e importância (Fathi *et al.*, 2020).

A transformação do espaço urbano simultaneamente com a digitalização da sociedade, possibilita o conhecimento acerca do quanto o bem-estar individual é influenciado pelo ambiente construído envolvente (Romice *et al.*, 2016). Apesar de ter sido conduzida uma notável quantidade de pesquisas sobre as potenciais associações entre as áreas urbanas e a saúde ou bem-estar, ainda existem poucos estudos que investiguem a grande complexidade da saúde e do bem-estar urbanos. Mais concretamente, há falta de abordagens interdisciplinares que destaquem a complexidade das estruturas e dinâmicas urbanas e a sua possível influência na saúde e bem-estar urbanos (Krefis *et al.*, 2018).

Com a rápida difusão das redes sociais *online*, como *Facebook*, *Twitter* e *Flickr*, as pessoas expressam o seu sentimento diário através de textos e imagens diretamente na rede *online* (Wang *et al.*, 2014). O conteúdo gerado pelos internautas nas redes sociais fornece informações sobre os utilizadores e o seu ambiente, permitindo aceder às preferências, opiniões e interações dos mesmos. Este facto contribui para a análise das opiniões e comportamentos das pessoas que, por sua vez, permite melhorar os serviços prestados aos utilizadores e ao seu ambiente real e virtual, através de tomadas de decisão informadas, gestão de crises, recomendações de produtos e previsões de tendências futuras (Aloufi *et al.*, 2017).

Com este estudo pretende-se identificar quais as variáveis do ambiente urbano da cidade de Lisboa que afetaram o bem-estar no ano de 2019, através do uso de comentários georreferenciados do *Twitter*, que possibilitam a obtenção de uma grande quantidade de informação espacial sobre os utilizadores.

2. METODOLOGIA

Os métodos estatísticos empíricos e convencionais fornecem informações úteis ao apoio de medidas eficazes de planeamento e gestão, bem como decisões mais informadas, contudo apresentam algumas limitações analíticas (*e.g.*, não conseguem captar totalmente comportamentos não lineares ou descartar os efeitos da heterogeneidade e da autocorrelação espacial) (Cartone & Postiglione, 2021; Demšar *et al.*, 2013).

O *Machine Learning* (ML) supera com sucesso as limitações dos métodos estatísticos. Apresenta vantagens, tais como a capacidade de lidar com dados de diferentes tipos, estruturas e quantidades (*i.e.*, *big data*), não sendo sensíveis à escala das variáveis (o que significa que não há necessidade de normalização da variável) (Viana *et al.*, 2021); por conseguinte, é possível combinar dados de diversas fontes para modelar relações não lineares complexas que descrevam a variação do sentimento em ambientes urbanos.

Apesar das potenciais vantagens, os algoritmos ML permanecem principalmente sob uma formulação de “caixa negra”, o que significa que sem mais intervenções, não é possível interpretar ou reconstituir diretamente como um modelo executa a inferência ou predição devido aos muitos pesos internos ou informações estruturais (Molnar, 2019).

Os modelos modelo-agnósticos foram propostos como métodos de interpretação para fornecer explicações sobre a função subjacente ao comportamento geral dos modelos ML (Murdoch *et al.*, 2019). A principal vantagem de uma abordagem de modelo-agnóstico é a sua flexibilidade, uma vez que pode lidar com a opacidade de qualquer tipo de modelo ML de caixa negra e recolher a interpretação, que é um aspeto crítico quando os resultados do modelo ML são usados para a tomada de decisão (Ribeiro *et al.*, 2016).

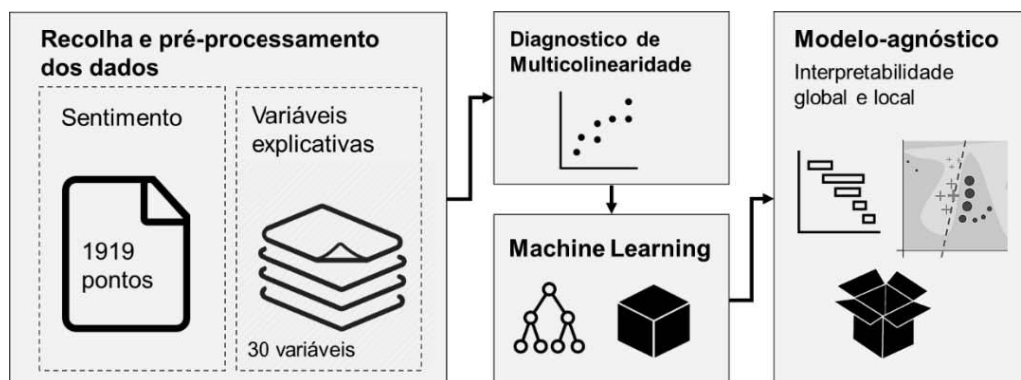
Este estudo explora a utilização de um modelo de ML juntamente com uma abordagem de modelo-agnóstico de modo a aumentar a compreensão das condições dos ambientes urbanos que podem explicar o bem-estar subjetivo hedónico. O modelo empírico é testado usando a cidade de Lisboa como base de trabalho.

Atualmente, existem exemplos de modelos agnósticos interpretáveis globais e locais. Dos globais utilizou-se a Importância da Variável de Permutação (*Permutation Feature Importance – PFI*) e dos locais o *Local Interpretable Model-Agnostic Explanations* (LIME) e o *Shapley Additive ExPlanations* (SHAP) (Molnar, 2019).

O método PFI mede o aumento do erro de predição do modelo após os valores da variável serem permutados (Winkler *et al.*, 2015). Este método permitiu compreender quais as variáveis que contribuíram para os resultados subjacentes ao modelo ML e quantificar a sua importância. O método LIME tem como objetivo criar uma aproximação local do modelo complexo para um específico *input*, as explicações têm de ser confiáveis localmente apesar de não fazerem sentido globalmente (Molnar, 2019). Por último, SHAP é um método que explica as predições individuais baseado nos *Shapley values* da teoria dos jogos, calculando a contribuição de cada *feature* para a predição.

O modelo foi desenvolvido para compreender os múltiplos fatores que podem ajudar a explicar o sentimento e como tal o bem-estar subjetivo em ambientes urbanos (figura 1).

Figura 1. Metodologia do processo de modelação.



Este modelo inclui cinco fases principais: (1) recolha e pré-tratamento de dados espaciais, (2) análise de sentimento, (3) diagnóstico da multicolinearidade de dados, (4) construção do modelo ML, e (5) aplicação da abordagem modelo-agnóstica para a interpretação. O processo de trabalho encontra-se ilustrado na figura 1.

3. RESULTADOS E DISCUSSÃO

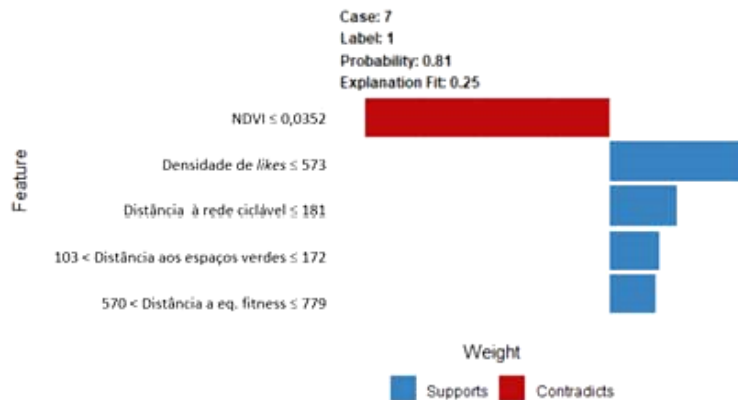
De modo a possibilitar a visualização da distribuição do sentimento na cidade de Lisboa, os resultados da análise de sentimento com recurso ao léxico *Emolex* foram importados para ambiente SIG e classificados segundo o sistema binário. Os dados binários do sentimento (1919 pontos) foram posteriormente inseridos no modelo ML (treinado com o algoritmo *Random Forest* e *Xgboost*) juntamente com as variáveis explicativas do ambiente urbano ($VIF < 5$). Posteriormente, utilizaram-se quatro abordagens de modelos agnósticos para interpretar o *output* do modelo.

Os *outputs* da modelação RF foram examinados primeiramente utilizando o método PFI, que apresenta as dez variáveis mais influentes na explicação do sentimento. As variáveis mais influentes (com uma pontuação de importância >50) foram a distância a equipamentos *fitness*, distância à rede ciclável, energia solar e a popularidade dos locais (traduzida por uma grande concentração de *likes* em fotos do *Flickr*).

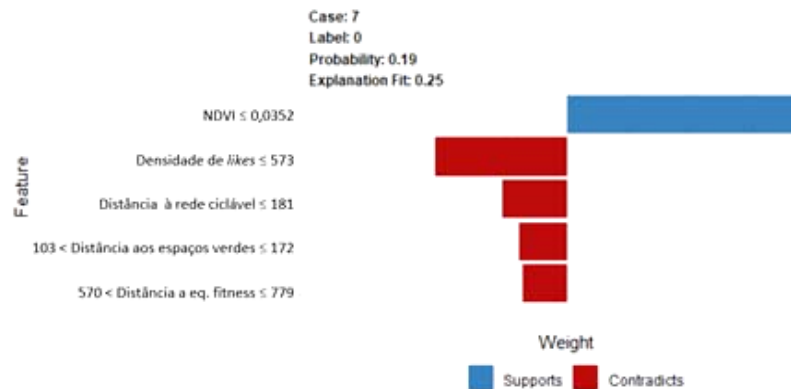
O método LIME foi utilizado para a interpretação local do modelo de caixa negra *Random Forest*, fornecendo uma explicação ao nível da observação (Elshawi *et al.*, 2019). Efetuou-se uma representação visual da primeira observação individual dos dados do subconjunto local, por ser a que melhor justifica os resultados (figura 2). Cada gráfico apresenta a probabilidade predita de cada observação como sentimento positivo ou negativo. Da mesma forma, apresenta as cinco variáveis que mais contribuem para a explicação da predição do modelo no local de cada observação e se estas variáveis aumentam (suportam) ou diminuem (contradizem) a probabilidade de sentimento (Salami *et al.*, 2020).

Figura 2. Interpretação do LIME para a instância 7 como sentimento positivo (a) e negativo (b).

(a)



(b)

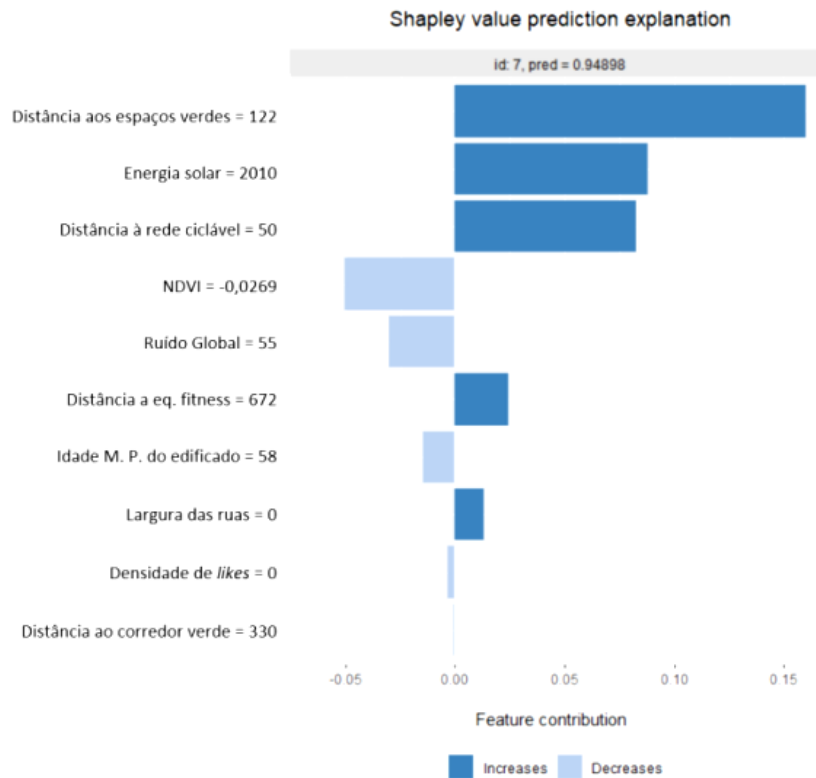


A figura 2a apresenta a explicação da predição da observação 7 como sentimento positivo (*label* = 1), com uma forte probabilidade de 0,81. Com estes resultados, podemos deduzir que, para o caso 7 a probabilidade de ser um sentimento positivo é de 81%. Neste caso, a explicação LIME foi criada com base nas cinco variáveis: NDVI, densidade de *likes* (popularidade do local), distância à rede ciclável, distância aos espaços verdes e distância aos equipamentos *fitness*. Estas contribuem positivamente para a explicação do sentimento positivo, à exceção do NDVI que contradiz a felicidade. Os valores de NDVI inferiores a 0,0352 referem-se a áreas com pouca ou nenhuma clorofila (*e.g.*, áreas artificializadas), estando negativamente correlacionadas com o sentimento positivo.

Para a interpretação local do modelo de caixa negra *Xgboost* utilizou-se o *Kernel SHAP*, representou-se graficamente a observação individual 7 dos dados do subconjunto local. A figura 3 apresenta a probabilidade predita da observação como

sentimento positivo e as variáveis que mais contribuíram para essa predição local. Indicando também se essas variáveis aumentam (suportam) ou diminuem (contradizem) a probabilidade de sentimento positivo.

Figura 3. Interpretação *Kernel SHAP* para a instância 7 como sentimento positivo.



A figura 3 mostra a explicação *Shapley* da observação 7 com base nas 10 variáveis explicativas, sendo que a distância aos espaços verdes, energia solar, distância à rede ciclável, NDVI e ruído global são as variáveis que mais contribuíram para a predição do sentimento (positivo). As explicações mostram que valores de distância a espaços verdes de 122 metros suportam o sentimento positivo, contrariamente aos valores de NDVI de -0,0269 e de ruído global de 55 dB que contradizem.

4. LIMITAÇÕES & CONCLUSÕES

Os modelos agnósticos, principalmente o SHAP que é baseado na teoria dos jogos, desempenham um papel fundamental neste tipo de análise. Para além de explicar as predições individuais dos modelos de *machine learning*, também permite

obter explicações globais válidas agregando as previsões individuais. A partir dos resultados é possível concluir que as variáveis que se relacionam mais com o sentimento são a distância a equipamentos *fitness*, a distância aos espaços verdes, a popularidade dos locais e a distância á rede ciclável.

Os sentimentos expressos pelo indivíduo no local da publicação poderão não ser inerentes ao mesmo, mas dever-se a outros acontecimentos. O estado mental, as experiências ou vivências do indivíduo ao longo do seu período de vida também poderão influenciar a sua perceção do local. Os dados enviesados resultantes da análise de sentimento com recurso ao *EmoLex*, ao serem utilizados no modelo ML preditivo, poderão ter influenciado os resultados. Contudo, este tipo de estudos são uma mais-valia para os planeadores, políticos, profissionais de saúde, que com a ajuda das interpretações do modelo de ML podem tomar decisões, possibilitando desenvolver novas estratégias para reduzir as desigualdades e promover melhor a saúde e o bem-estar urbanos. Estes profissionais possuem um conhecimento prévio sobre o bem-estar em ambiente urbano que podem utilizar para determinar se aceitam ou rejeitam uma predição.

BIBLIOGRAFIA

- Aloufi, S., Zhu, S., & El Saddik, A. (2017). On the Prediction of Flickr Image Popularity by Analyzing Heterogeneous Social Sensory Data. *Sensors*, 17(3), 631. <https://doi.org/10.3390/s17030631>
- Cartone, A., & Postiglione, P. (2021). Principal component analysis for geographical data: the role of spatial effects in the definition of composite indicators. *Spatial Economic Analysis*, 16(2), 126-147. <https://doi.org/10.1080/17421772.2020.1775876>
- Demšar, U., Harris, P., Brunsdon, C., Fotheringham, A. S., & McLoone, S. (2013). Principal Component Analysis on Spatial Data: An Overview. *Annals of the Association of American Geographers*, 103(1), 106-128. <https://doi.org/10.1080/00045608.2012.689236>
- Elshawi, R., Al-Mallah, M. H., & Sakr, S. (2019). On the interpretability of machine learning-based model for predicting hypertension. *BMC Medical Informatics and Decision Making*, 19(1), 146. <https://doi.org/10.1186/s12911-019-0874-0>
- Fathi, S., Sajadzadeh, H., Sheshkal, F. M., Aram, F., Pinter, G., Felde, I., & Mosavi, A. (2020). The role of urban morphology design on enhancing physical activity and public health. *International Journal of Environmental Research and Public Health*, 17(7), 1-29. <https://doi.org/10.3390/ijerph17072359>
- Hajrasouli, A., del Rio, V., Francis, J., & Edmondson, J. (2018). Urban form and mental wellbeing. *Journal of Urban Design and Mental Health*, 5(1), 10.
- Hidaka, B. H. (2012). Depression as a disease of modernity: explanations for increasing prevalence. *National Institutes of Health*, 140(3), 205-214. <https://doi.org/10.1016/j.jad.2011.12.036.Depression>

- Krefis, A., Augustin, M., Schlünzen, K., Oßenbrügge, J., & Augustin, J. (2018). How Does the Urban Environment Affect Health and Well-Being? A Systematic Review. *Urban Science*, 2(1), 21. <https://doi.org/10.3390/urbansci2010021>
- Molnar, C. (2019). *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. G. Molnar.
- Murdoch, W. J., Singh, C., Kumbier, K., Abbasi-Asl, R., & Yu, B. (2019). Definitions, methods, and applications in interpretable machine learning. *Proceedings of the National Academy of Sciences*, 116(44), 22071-22080. <https://doi.org/10.1073/pnas.1900654116>
- Reeves, W. C., Strine, T. W., Pratt, L. A., Thompson, W., Ahluwalia, I., Dhingra, S. S., ... Safran, M. A. (2011). Mental Illness Surveillance Among Adults in the United States. *Supplements*, 60(03), 1-32
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). Model-Agnostic Interpretability of Machine Learning. *ICML Workshop on Human Interpretability in Machine Learning* (arXiv.1606.05386), New York. <https://doi.org/10.48550/arXiv.1606.05386>
- Romice, O., Thwaites, K., Porta, S., Greaves, M., Barbour, G., & Pasino, P. (2016). City form and wellbeing. In G. Fleury-Bahi, E. Pol & O. Navarro (Eds.), *The Handbook of Environmental Psychology and Quality of Life Research* (pp. 241-273). Springer. https://doi.org/10.1007/978-3-319-31416-7_14
- Salami, D., Sousa, C. A., Martins, M. do R. O., & Capinha, C. (2020). Predicting dengue importation into Europe, using machine learning and model-agnostic methods. *Scientific Reports*, 10, 9689. <https://doi.org/10.1038/s41598-020-66650-1>
- Viana, C. M., Santos, M., Freire, D., Abrantes, P., & Rocha, J. (2021). Evaluation of the factors explaining the use of agricultural land: A machine learning and model-agnostic approach. *Ecological Indicators*, 131, 108200. <https://doi.org/10.1016/j.ecolind.2021.108200>
- Wang, X., Jia, J., Cai, L., & Tang, J. (2014). Modeling Emotion Influence from Images in Social Networks. *IEEE Transactions on Affective Computing*, 6(3), 286-297. <https://doi.org/10.1109/TAFFC.2015.2400917>
- Winkler, A. M., Webster, M. A., Vidaurre, D., Nichols, T. E., & Smith, S. M. (2015). Multi-level block permutation. *NeuroImage*, 123, 253-268. <https://doi.org/10.1016/j.neuroimage.2015.05.092>