

MAPEAMENTO AQUÍCOLA NO BRASIL A PARTIR DE APRENDIZAGEM DE MÁQUINA NA PLATAFORMA GEE

Bruno Aparecido da Silva ¹
Marta Eichemberger Ummus ²
Ericson Hideki Hayakawa ³
Altair Bennert ⁴
Jeferson Luiz dos Santos ⁵

INTRODUÇÃO

No cenário internacional, percebe-se maior atenção à investigação geoespacial na aquicultura a partir do monitoramento e mapeamento da distribuição dos tanques aquícolas em áreas costeiras (DINIZ et al. 2021; SUN et al., 2020). Sendo indispensável, o mapeamento aquícola permite identificar as diferenças entre as características biofísicas e socioeconômicas locais, sendo crucial para a sustentabilidade da atividade aquícola (LI et al., 2023; NATH et al., 2000). Contudo, a ausência de informações detalhadas sobre a dinâmica espaço-temporal do setor aquícola (OTTINGER et al., 2018) pode inviabilizar a busca pela sustentabilidade.

Até recentemente, a utilização de técnicas tradicionais (LOBERTERNOS et al., 2016) não foram viáveis para a investigação geoespacial da aquicultura em grande escala (SUN et al., 2024). Alternativamente, a extração automatizada de tanques aquícolas, principalmente em regiões costeiras (HOU et al., 2022; SUN et al., 2024), tem sido um exemplo da mudança paradigmática nos mapeamentos aquícolas dos últimos anos.

O Brasil dispõe de reservas hídricas, extensão territorial e localização geográfica estratégica, fazendo do país um território potencial para o desenvolvimento da aquicultura (FRANCISCO et al., 2019; NOVO et al., 2022) e atualmente ocupa a 8ª colocação no ranking mundial de produção de peixes de águas continentais, projetando a ocupar a 2ª

¹ Doutor em Geografia – Bipark Educação e Universidade Estadual do Oeste do Paraná brunoborchertesilva@gmail.com;

² Analista pela Embrapa Pesca e Aquicultura, marta.ummus@embrapa.br;

³ Professor pelo Curso de Geografia da Universidade estadual do Oeste do Paraná, ericson.geo@gmail.com;

⁴ Doutorando pelo Curso de Geografia da Universidade estadual do Oeste do Paraná, bennert.geo@gmail.com;

⁵ Mestrando do Curso de Geografia da Universidade Estadual do Oeste do Paraná, jefer_santos@outlook.com;

colocação até 2032 (FAO, 2024). A escassez de informações geoespaciais, relevantes para a caracterização territorial da aquicultura, pode impossibilitar o acompanhamento da expansão aquícola, pautada na sustentabilidade (GREENSTREET et al., 2023). Diante desse cenário brasileiro, o objetivo deste artigo foi mapear áreas de aquicultura a partir do uso de algoritmo de *machine learning* no *Google Earth Engine* (GEE) e, com isso, desenvolver uma metodologia para extração automatizada de viveiros escavados no estado do Paraná, que é o principal estado produtor de tilápia do Nilo (*Oreochromis niloticus*) do Brasil. Para tanto, foram utilizadas imagens de satélite de alta resolução, índices espectrais, classificação orientada a pixel com algoritmo Random Forest e atributos geométricos para levantar dados inéditos e em grande escala sobre a aquicultura no Brasil.

MATERIAIS E MÉTODO

Área do Estudo

O estado do Paraná é líder na produção de peixes de cultivo no Brasil. Em 2023, foram produzidas 194.100 t (22,5 %) da produção total nacional das espécies (ANUÁRIO PEIXE BR 2023). A tilápia do Nilo é o peixe mais cultivado no Brasil e o Paraná é seu principal produtor. Em 2023 o estado foi responsável por mais de 34% da produção nacional dessa espécie. O Paraná está localizado na região Sul do Brasil (Figura 1). O estado ocupa a quinta posição no ranking do PIB nacional, com R\$ 549.973 mi (IBGE, 2024).

Método

A etapa inicial contou com a seleção e aquisição de imagens de satélite com alta resolução (4,77 m). As imagens são disponibilizadas pelo programa Norway's International Climate and Forest Initiative (NICFI), adquiridas pela Kongsberg Satellite Services (KSAT), Airbus e Planet (PLANET TEAM, 2017). A coleção de imagens do NICFI Planet foi acessada via *Google Earth Engine* (GEE). A coleção de imagens selecionadas foi submetida à função removedora de nuvens, criação de um mosaico a

partir do valor mediano de cada pixel das imagens de 2020 a 2023, recorte da área de interesse e extração de índices espectrais na plataforma GEE.

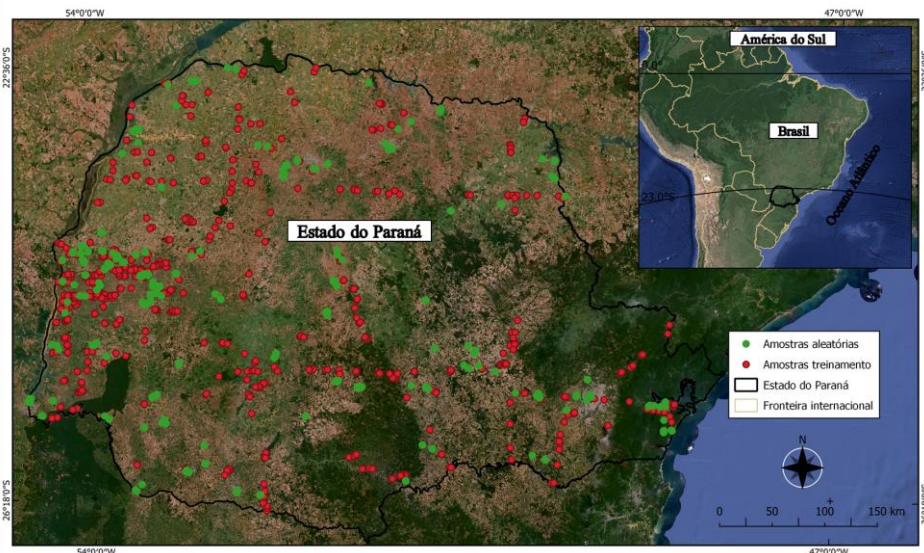


Figura 1 - Mapa de localização do Estado do Paraná com pontos de amostrais.

A etapa de processamento das imagens englobou a extração de índices espectrais na plataforma GEE: *Nominalized Difference Water Index* (NDWI), *Soil-Adjusted Vegetation Index* (SAVI), *Nominalized Difference Vegetation Index* (NDVI) e o *Enhanced Vegetation Index* (EVI). Com o objetivo de treinar o algoritmo e obter os pixels correspondentes às classes preditas, foram construídos dois conjuntos de dados amostrais no GEE (MATARIRA et al., 2022), incluindo 1.200 polígonos de treinamento, sendo 800 polígonos de água e 400 de não-água (Figura 1). Em seguida, foi realizada classificação supervisionada orientada a pixel a partir da combinação de amostras de treinamento, bandas espectrais (B, G, R, N), índices espectrais e algoritmo Random Forest (RF) (YU et al., 2022). No Brasil, pesquisadores têm usado esse algoritmo e tido êxito no mapeamento da paisagem em grande escala (SOUZA et al., 2020). Posterior à classificação, obteve-se a máscara com duas classes (água e não-água). Assim, seguiu-se com a remoção de pixels que não representariam tanques aquícolas (lagos, lagoas de decantação, reservatórios, rios, etc.), considerando as diferenças morfológicas (SUN et al., 2024) de área, perímetro e compacidade (SANTIAGO-MONTERO et al., 2009; XIA et al., 2020). A máscara final, contendo os viveiros aquícolas individuais, foi exportada para o QGIS 3.28.2 (2024) para avaliação estatística. Para avaliar a acurácia do

mapeamento dos viveiros, foi construída uma matriz de erros com classes de predição (aquicultura e não aquicultura) e classes de referência (aquicultura e não aquicultura), sendo a acurácia do usuário (AU), acurácia do produtor (AP) e acurácia global (AG) avaliadas (HOU et al., 2022; TIAN et al., 2022).

RESULTADOS E DISCUSSÃO

Acurácia do mapeamento

O mapeamento de viveiros escavados obteve acurácia global de 0,90. A acurácia do produtor para a classe aquicultura foi 0,95 e não aquicultura 0,80 (Figura 2c), representando baixo erro de omissão, aproximadamente 0,05 a 0,20 de classes não preditas pelo mapeamento, confirmando uma boa correspondência espacial (Figura 2d). A acurácia do usuário obteve acertos de 0,89 e 0,92 para aquicultura e não aquicultura, respectivamente. Esses valores indicaram erro médio de aproximadamente 10% de pixels que foram atribuídos à determinada classe, mas pertenciam a outra classe nas amostras de referência. Conforme indicado na Figura 2b, o índice NDWI foi a variável que teve maior contribuição (Figura 2b) na separação das classes.

Quantificação

O mapeamento identificou 42.369 viveiros escavados com área total de lâmina d'água de 11.515 ha. Os valores mín. e máx. de área e perímetro variaram entre 0,05-2,28 ha e 113,52-2748,68 m, respectivamente. Predominaram polígonos com área inferior a 0,7 ha e perímetro menor que 600 m (Figura 3a). Conforme analisado, os tanques apresentaram valores de 0,55 e 0,88 para compactidade, indicando forma predominantemente não circular tanques aquícolas. Por sua vez, o valor médio de compactidade foi de 0,70 (Figura 3c).

A Mesorregião Oeste (O) englobou 24% do total dos tanques do estado, seguida da Mesorregião Metropolitana de Curitiba (ME), com 16%, estas também representaram aproximadamente 40% da lâmina de água para aquicultura no estado. As mesorregiões Centro-Oriental (CEO), Noroeste (NO) e Centro-Occidental (CEOC) concentraram taxas de área e número de viveiros escavados, 6%, 5% e 4%, respectivamente. As demais

mesorregiões apresentaram percentuais de área e número de viveiros oscilando entre 8% e 12%. Na Mesorregião Oeste (O) predominaram tanques com os maiores valores de área (aproximadamente 0,6 ha), enquanto na Sudoeste (SO) dominaram viveiros com valores de área 0,2 ha (Figura 3d). Quanto aos valores de compactidade, notou-se uma baixa variação neste índice, uma vez que somente em três mesorregiões Norte-Central (NC), Centro-Occidental (CEOC) e Norte-Pioneiro (N) foram verificados valores inferiores ao quadro geral do estado, oscilando entre 0,57 e 0,74 de circularidade.

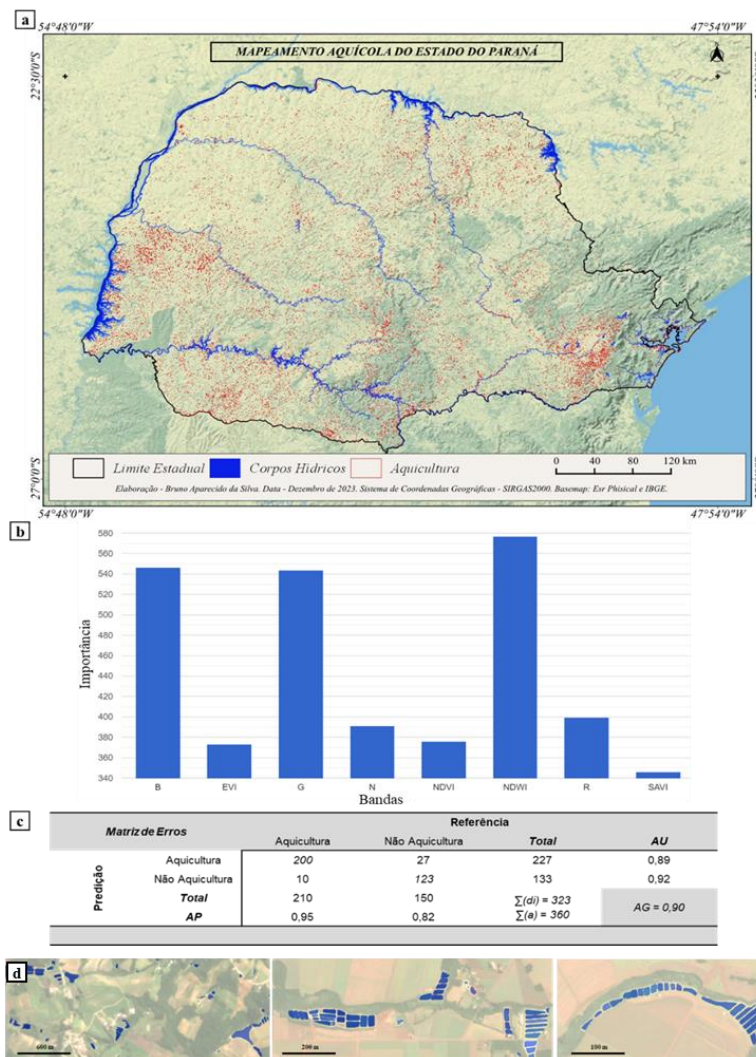


Figura 2 – Mapeamento aquícola: espacialização (a), variáveis importantes (b) e validação (c).

A implementação da metodologia na plataforma GEE facilitou o acesso de dados de satélite na execução do mapeamento em grande escala, sendo possível reduzir o tempo

de mapeamento, por meio da simplificação do processamento da elevada quantidade de dados, conforme discutiram Matarira et al. (2022), Sun et al. (2020) e Xu et al. (2021). A eficácia da metodologia proposta, demonstrada pelos resultados alcançados, com elevada acurácia global (0,90), conforma o sucesso do mapeamento, mesmo não utilizando dados de radar, pois, de acordo com estudos realizados por Ottinger et al. (2017) e Xu et al. (2021), mesmo associando o radar a dados de sensores ópticos a acurácia global tem sido próxima a 0,90 em mapeamentos aquícolas.

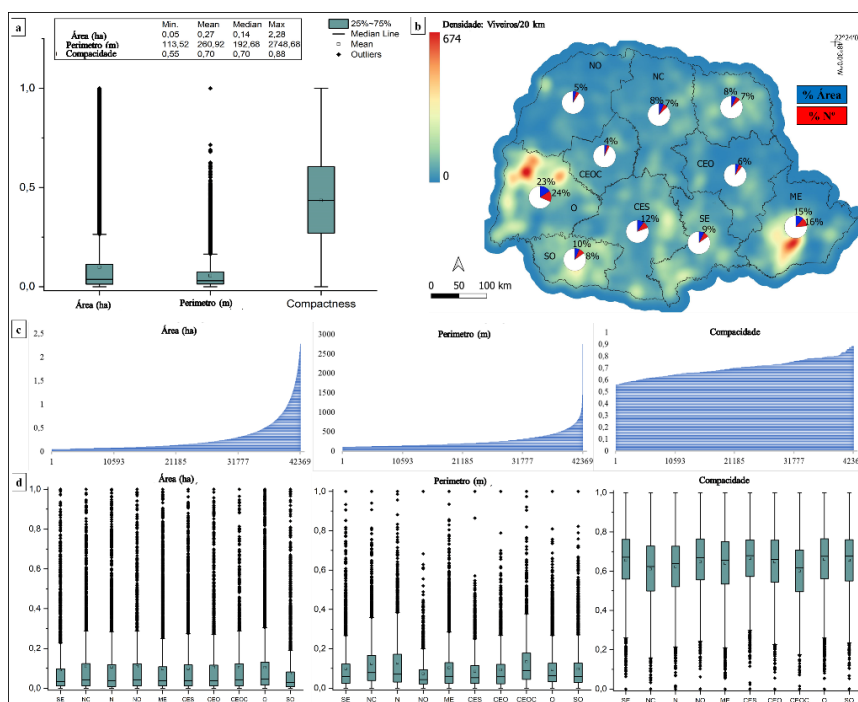


Figura 3. Estatística descritiva dos viveiros escavados mapeados. a, c) Gráficos representando características geométricas dos viveiros do estado do Paraná; b) Mapa de calor referente à distribuição dos viveiros no estado e o percentual de área e número de tanques por mesorregiões; d) Gráficos representando características geométricas dos viveiros do estado do Paraná por mesorregiões. Obs.: Nos gráficos de boxplot (a, d) os valores de área, perímetro e compacidade foram normalizados. SE - Sudeste, NC - Norte-Central, N - Norte-Pioneiro, NO - Noroeste, ME - Metropolitana, CES - Centro-Sul, CEO - Centro-Oriental, CEOC - Centro-Occidental, O - Oeste, SO - Sudoeste.

CONSIDERAÇÕES FINAIS

O presente estudo apresentou potencial para extrair viveiros escavados em áreas continentais interiores, conforme sustentado pelos resultados de acurácia global. Considerando que o fluxo de trabalho foi implementado na plataforma GEE, a partir do uso do RF e aplicação de operações geométricas para separar os viveiros escavados, a lacuna de informações espaciais e sistemáticas sobre a aquicultura em escala nacional poderia ser preenchida rapidamente por meio da aplicação da metodologia ora proposta. Pois, a metodologia possibilitou obter dados inéditos e de grande abrangência espacial e, com isso, realizou a caracterização quantitativa dos viveiros e avaliar o quadro espacial aquícola no principal estado produtor de tilápias do Brasil, à medida que mostrou áreas com maior concentração de propriedades aquícolas.

Palavras-chave: *Random forest*; índices espectrais, imagens Planet, tilápia, viveiros escavados.

AGRADECIMENTOS: A Fundação Araucária do Estado do Paraná - Termo de Convênio n. 215/2023, ao Biopark Educação. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001”. Ao CNPq (Processo 313757/2021-6).

REFERÊNCIAS

- Anuário Peixe BR, A. P. (2023). *Anuário Brasileiro da Piscicultura - PEIXE BR 2023* (p. 65). Associação Brasileira da Piscicultura.
- Diniz, C., Cortinhas, L., Pinheiro, M. L., Sadeck, L., Fernandes Filho, A., Baumann, L. R.F., Adami, M., Souza-Filho, P. & Walfir, M. (2021). A large-scale deep-learning approach for multi-temporal aqua and salt-culture mapping. *Remote Sensing*, v. 13, n. 8. <https://doi.org/10.3390/rs13081415>.
- FAO. (2024). The State of World Fisheries and Aquaculture 2024. Blue Transformation in action. Rome. <https://doi.org/10.4060/cd0683en>.
- Francisco, H. R., Corrêia, A. F., & Feiden, A. (2019). Classification of Areas Suitable for Fish Farming Using Geotechnology and Multi-Criteria Analysis. *ISPRS International Journal of Geo-Information*, 8(394), 1–19. <https://doi.org/10.3390/ijgi8090394>
- IBGE, I. B. de G. e E. (2024). *IBGE*. <https://www.ibge.gov.br/cidades-e-estados/pr.html>
- Greenstreet, L., Fan, J., Bai, Y., Ummus, M. E., Doria, C., Velho, P., Barros, N. O., Forsberg, B. R., Flecker, A., & Gomes, C. (2023). Detecting Aquaculture with Deep Learning in a Low-Data Setting. *SigKDD Fragile Earth Workshop*, 1(1), 6–10.
- Hou, Y., Zhao, G., Chen, X., & Yu, X. (2022). Improving Satellite Retrieval of Coastal Aquaculture Pond by Adding Water Quality Parameters. *Remote Sensing*, 14(14). <https://doi.org/10.3390/rs14143306>
- Li, B., Gong, A., Chen, Z., Pan, X., Li, L., Li, J., & Bao, W. (2023). An Object-Oriented

Method for Extracting Single-Object Aquaculture Ponds from 10 m Resolution Sentinel-2 Images on Google Earth Engine. *Remote Sensing*, 15(3). <https://doi.org/10.3390/rs15030856>

Loberternos, R. A., Porpetcho, W. P., Graciosa, J. C. A., Violanda, R. R., Diola, A. G., Dy, D. T., & Otadoy, R. E. S. (2016). An object-based workflow developed to extract aquaculture ponds from airborne LiDAR data: A test case in central Visayas, Philippines. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 41, 1147–1152. <https://doi.org/10.5194/isprsarchives-XLI-B8-1147-2016>

Matarira, D., Mutanga, O., & Naidu, M. (2022). Google Earth Engine for Informal Settlement Mapping: A Random Forest Classification Using Spectral and Textural Information. *Remote Sensing*, 14(20). <https://doi.org/10.3390/rs14205130>

Nath, S. S., Bolte, J. P., Ross, L. G., & Aguilar-Manjarrez, J. (2000). Applications of geographical information systems (GIS) for spatial decision support in aquaculture. *Aquacultural Engineering*, 23, 233–278. www.elsevier.nl/locate/aqua-online.

Novo, Y. C. C., Farias, A. R., Fonseca, M. F., & Magalhães, L. A. (2022). Mapping of aquaculture production units in the Paraná state through processing and interpretation of Sentinel satellite images (Paraná - Brazil). *RA'E GA - O Espaço Geográfico Em Análise*, 54, 103–108. <https://doi.org/10.5380/raega.v54i0.75775>

Ottinger, M., Clauss, K., & Kuenzer, C. (2017). Large-scale assessment of coastal aquaculture ponds with Sentinel-1 time series data. *Remote Sensing*, 9(5). <https://doi.org/10.3390/rs9050440>

Ottinger, M., Clauss, K., & Kuenzer, C. (2018). Opportunities and challenges for the estimation of aquaculture production based on earth observation data. *Remote Sensing*, 10(7), 1–24. <https://doi.org/10.3390/rs10071076>

Planet Team. (2017). Planet Application Program Interface: In Space for Life on Earth. In *Planet Team*. <https://api.planet.com>

QGIS 3.28.2. (2024). *QGIS.org Geographic Information System*. (3.28.2). www.qgis.org.

Santiago-Montero, R., Bribiesca, E., Montero, R. S., Santiago, R., & Bribiesca, E. (2009). State of the art of compactness and circularity measures State of the Art of Compactness and Circularity Measures 1. *International Mathematical Forum*, 4(27), 1305–1335. <https://www.researchgate.net/publication/228948093>

Souza, C. M., Shimbo, J. Z., Rosa, M. R., Parente, L. L. & Rosa, E. R. (2020) Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat Data Archive and Google Earth Engine. *Remote Sensing*. 12(17).

Sun, W., Hou, T., Chen, C., Yang, G., Chen, B., Meng, X., & Ren, K. (2024). Mapping China's coastal aquaculture ponds expansion with sentinel-2 images during 2017–2021. *International Journal of Digital Earth*, 17(1). <https://doi.org/10.1080/17538947.2023.2297943>

Sun, Z., Luo, J., Yang, J., Yu, Q., Zhang, L., Xue, K., & Lu, L. (2020). Nation-scale mapping of coastal aquaculture ponds with sentinel-1 SAR data using google earth engine. *Remote Sensing*, 12(18). <https://doi.org/10.3390/RS12183086>.

Tian, P., Liu, Y., Li, J., Pu, R., Cao, L., Zhang, H., Ai, S., & Yang, Y. (2022). Mapping Coastal Aquaculture Ponds of China Using Sentinel SAR Images in 2020 and Google Earth Engine. *Remote Sensing*, 14(21). <https://doi.org/10.3390/rs14215372>

Xia, Z., Guo, X., & Chen, R. (2020). Automatic extraction of aquaculture ponds based on Google Earth Engine. *Ocean and Coastal Management*, 198. <https://doi.org/10.1016/j.ocecoaman.2020.105348>

Yu, Z., An, Q., Liu, W., & Wang, Y. (2022). Analysis and evaluation of surface water

changes in the lower reaches of the Yangtze River using Sentinel-1 imagery. *Journal of Hydrology: Regional Studies*, 41. <https://doi.org/10.1016/j.ejrh.2022.101074>.