

Evaluating the Explainability of Machine Learning Classifiers: A case study of Species Distribution Modeling in the Amazon

Renato Okabayashi Miyaji¹, Felipe Valencia Almeida¹, Pedro Luiz Pizzigatti Corrêa¹

Escola Politécnica da Universidade de São Paulo
{re.miyaji, felipe.valencia.almeida, pedro.correa}@usp.br

Abstract. Machine Learning Models are widely used in Computational Ecology. They can be applied for Species Distribution Modeling, which aims to determine the probability of occurrence of a species, given the environmental conditions. However, for ecologists, these models are considered as "black boxes", since basic Machine Learning knowledge is necessary to interpret them. Thus, in this work four Explainable Artificial Intelligence techniques - *Local Interpretable Model-Agnostic Explanation* (LIME), *SHapley Additive exPlanations* (SHAP), *BreakDown* and *Partial Dependence Plots* - were evaluated to the Random Forests classifier for *Coragyps atratus* in the Amazon Basin region. It was found that the SHapley Additive exPlanations technique and Partial Dependence Plots are able to improve the explainability of the model.

CCS Concepts: • **Computing methodologies** → *Classification and regression trees*.

Keywords: explainable artificial intelligence, machine learning, random forests

1. INTRODUÇÃO

A Modelagem de Distribuição de Espécies (*Species Distribution Models* – SDM) é uma análise ecológica relevante. Por meio dela é possível analisar a biodiversidade e determinar como as condições ambientais impactam as espécies [Elith and Leathwick 2009]. Desde o início do século, com o desenvolvimento de modelos de Classificação de Aprendizado de Máquina cada vez mais complexos e que apresentam uma acurácia mais elevada, eles passaram a ser amplamente adotados para essa aplicação [Hegel et al. 2010].

Entretanto, o crescimento da complexidade e da acurácia dos modelos não foi necessariamente acompanhado pelo aumento da compreensão a seu respeito, sendo dessa forma considerados como “caixas-pretas” pelos ecologistas [Ryo et al. 2021]. Assim, para os ecologistas, o ideal seria que um modelo de distribuição de espécies pudesse possuir uma alta acurácia, além de ser facilmente interpretável pelos especialistas que o utilizam [Phillips et al. 2004]. Nesse contexto, nos últimos anos, diversos esforços vêm sendo feitos com o objetivo de se aprimorar a explicação de modelos, por meio da emergente área de Inteligência Artificial Explicável (*Explainable Artificial Intelligence* – xAI), desenvolvendo técnicas que podem ser úteis para SDM por permitirem que se compreenda os resultados dos modelos e que se responda às questões científicas desejadas [Ryo et al. 2021].

Dessa forma, este artigo buscou avaliar a aplicação de técnicas de xAI para aprimorar a explicação de um classificador de Aprendizado de Máquina para a Modelagem de Distribuição de Espécies. Para isso, foi selecionado um estudo de caso de uma espécie de aves na região da Bacia Amazônica.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Ele foi possível devido aos Projetos Temáticos da FAPESP "Ciclos de vida e nuvens de aerossóis na Amazônia" (2017/ 17047-0) e "Research Centre for Greenhouse Gas Innovation - RCG2I" (2020/15230-5).

Copyright©2023 Permission to copy without fee all or part of the material printed in KDMiLe is granted provided that the copies are not made or distributed for commercial advantage, and that notice is given that copying is by permission of the Sociedade Brasileira de Computação.

A região de interesse para o estudo de caso foi a Floresta Amazônica, uma vez que essa é de grande interesse. A cidade de Manaus é situada no centro da Bacia Amazônica e é considerada por especialistas como um laboratório ideal para compreender a influência da ação antrópica em uma floresta tropical [Martin et al. 2017]. Nesse sentido, o *Atmospheric Radiation Measurement* (ARM), órgão do Departamento de Energia dos Estados Unidos da América, e instituições brasileiras, desenvolveram o projeto GoAmazon 2014/15. Nele buscou-se aumentar o volume de dados meteorológicos e de aerossóis disponíveis sobre a região.

2. TRABALHOS RELACIONADOS

Novas técnicas foram desenvolvidas recentemente para aprimorar a explicação de modelos de Aprendizado de Máquina. Essas técnicas podem ser divididas em duas categorias: interpretação baseada em modelos e interpretação *post-hoc*. A interpretação baseada em modelos faz o uso de modelos simples e de fácil compreensão para humanos, mas não necessariamente de alta acurácia, para realizar as previsões. Já a interpretação *post-hoc* se trata de análises feitas posteriormente ao ajuste de modelos, que possuem o objetivo de fornecer uma maior compreensão das relações aprendidas por ele, sendo particularmente úteis para conjuntos de dados complexos e de alta dimensionalidade [Murdoch et al. 2019].

Especificamente para a Modelagem de Distribuição de Espécies, no trabalho de Ryo et al. (2021), os autores aplicaram a técnica *post-hoc Local Interpretable Model-Agnostic Explanation* (LIME) [Ribeiro et al. 2016] para um estudo de caso com o modelo de Florestas Aleatórias. A partir dela, foi possível gerar um mapa de distribuição potencial do elefante africano, que se trata de um mapa em que cada pixel representa a probabilidade da ocorrência da espécie naquele determinado ponto. Então, a partir da inspeção de cada ponto, foi gerado um gráfico indicando a medida da importância de cada atributo na previsão, além do sentido de sua influência (positivo ou negativo).

Outra técnica de interpretação *post-hoc local* que foi aplicada para SDM foi a de *SHapley Additive exPlanations* (SHAP). Por meio dela, determina-se uma medida padrão de importância de atributos (valores de Shapley) [Lundberg and Lee 2017]. Ela foi aplicada para Modelagem de Distribuição de Espécies a partir de um modelo de *Deep Learning*, obtendo gráficos que indicam o efeito (valor de Shapley) de cada atributo e, mais especificamente, de cada valor do atributo na variável resposta [Rademaker et al. 2019].

Gráficos semelhantes aos de dependência parcial foram desenvolvidos para a Modelagem de Distribuição de Espécies. Um dos modelos mais utilizados para a tarefa, é o de Máxima Entropia [Phillips 2005]. Sua aplicação pode ser feita a partir do pacote *maxnet* da linguagem R, desenvolvido por Phillips (2006). Nele, após o ajuste do modelo, pode-se traçar as curvas da variável resposta em função de cada atributo considerado, permitindo a análise de sua relação.

3. METODOLOGIA

3.1 Estudo de Caso

Inicialmente, foi definido o estudo de caso a ser desenvolvido no trabalho. Para isso, foi construído um conjunto de dados bioclimáticos sobre a região da Bacia Amazônica. Os dados meteorológicos e de aerossóis foram obtidos a partir dos conjuntos de dados gerados e disponibilizados por Miyaji et al. (2021). Neste trabalho, a partir dos dados coletados pelo projeto GoAmazon 2014/15, foi aplicado o método de interpolação espacial, de modo a aumentar a resolução espacial dos dados sobre a região [Miyaji et al. 2021].

O projeto GoAmazon 2014/15 buscou compreender os impactos da pluma do centro urbano de Manaus sobre os poluentes e os aerossóis da região [Martin et al. 2017]. Para isso, foram realizadas diversas

coletas de dados, por meio de voos de baixa altitude. Nos conjuntos de dados, foram disponibilizadas as seguintes variáveis meteorológicas e de aerossóis: a temperatura, as concentrações de ozônio (O_3), monóxido de carbono (CO), óxidos de nitrogênio (NO_X), metano (CH_4), dióxido de carbono (CO_2), isopreno e acetonitrila, a concentração numérica de partículas e a fração volumétrica de água (H_2O).

Para possibilitar a construção do conjunto de dados bioclimáticos, foi necessário coletar os dados de ocorrência de espécies. Esses foram obtidos de dois repositórios: o Portal de Dados da Biodiversidade do Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) e do *Global Biodiversity Information Facility* (GBIF). Os dados de ocorrência de espécies foram unidos com o conjunto de dados meteorológicos e de aerossóis interpolados, por meio da operação de *Join* com as chaves de latitude, longitude e data do registro.

No conjunto de dados bioclimáticos obtido, estavam disponíveis dados de ocorrência de 40 espécies distintas. Por isso, optou-se por trabalhar com os dados referentes a essa estação. Optou-se pela espécie *Coragyps atratus*, o urubu-de-cabeça-preta, uma vez que ela apresentava a maior quantidade de pontos de ocorrência distintos e uma pequena dispersão espacial dentro da região analisada. Esses dois fatores favorecem a aplicação de modelos de distribuição de espécies [Hernandez et al. 2006]. No conjunto de dados, a distribuição de amostras das classes era de 23% para a classe positiva (presença da espécie) e 77% para a classe negativa (ausência da espécie).

Definida a espécie a ser analisada, foi necessário selecionar as variáveis preditoras. Para isso, optou-se pela Análise de Correlação. Optou-se por retirar uma das variáveis preditoras dos pares altamente correlacionados entre si, ou seja, que possuíam o coeficiente de Pearson com módulo maior ou igual a 80 %. Assim, desejava-se evitar a ocorrência de multicolinearidade [Mateo et al. 2013]. A partir dela, notou-se que as variáveis preditoras de temperatura, concentração de dióxido de carbono e concentração numérica de partículas possuíam coeficiente de correlação de Pearson elevado com outras variáveis. Desse modo, optou-se por retirá-las. As variáveis preditoras selecionadas foram: a temperatura máxima, a temperatura mínima, as concentrações de ozônio, monóxido de carbono, óxidos de nitrogênio, metano, isopreno, acetonitrila e a fração volumétrica de água.

3.2 Modelagem

Na etapa de modelagem, foi necessário selecionar o modelo de Aprendizado de Máquina a ser utilizado. Optou-se pelo classificador de Florestas Aleatórias (*Random Forests* - RF), uma vez que esse apresentou o melhor desempenho para a tarefa de Modelagem de Distribuição de Espécies em comparação com outras técnicas [Nurhussen et al. 2021] [Carter et al. 2021] [Fern et al. 2020]. O processo de treinamento do modelo foi feito com o conjunto de dados dividido na proporção 70% e 30% entre treino e teste, sendo as métricas de desempenho avaliadas sobre o conjunto de *Hold-out*. Para otimizar seus hiper parâmetros, foi adotada uma validação cruzada pelo método *K-Fold*, com $K = 3$. Para a avaliação do modelo de Florestas Aleatórias, adotou-se as métricas de classificação de acurácia, além de outra relevante para a tarefa de Classificação Desbalanceada: a revocação.

Já para a avaliação quanto à explicação, o modelo deveria ser capaz de possibilitar que o ecologista responda à hipótese científica determinada na Modelagem de Distribuição de Espécies [Pinaya and Corrêa 2014], através das questões de pesquisa apresentadas a seguir: "Quais variáveis preditoras possuem maior influência na probabilidade de ocorrência da espécie analisada?"; "A influência das variáveis preditoras é positiva ou negativa?" e "Quais são os valores ótimos das variáveis para maximizar a probabilidade de ocorrência da espécie analisada?".

De acordo com a classificação proposta por Doran et al. (2017), a maior parte dos modelos utilizados para a Modelagem de Distribuição de Espécies podem ser classificados como interpretáveis, a exemplo do modelo de Florestas Aleatórias. Entretanto, mesmo os modelos interpretáveis são considerados como "caixas-pretas" por muitos ecologistas [Ryo et al. 2021], uma vez que necessitam de humanos com o conhecimento técnico necessário para compreender seu funcionamento. Ademais, também existe

o risco de interpretações erradas [Doran et al. 2017].

Dessa forma, a aplicação de técnicas de Inteligência Artificial Explicável (xAI) mostra-se necessária. Optou-se por avaliar quatro técnicas de xAI que foram apontadas na literatura como promissoras: *Local Interpretable Model-Agnostic Explanation* (LIME) [Ribeiro et al. 2016], *SHapley Additive ex-Planations* (SHAP) [Lundberg and Lee 2017], *BreakDown* [Staniak and Biecek 2018] e Gráficos de Dependência Parcial, semelhante às curvas de respostas [Phillips 2005].

A técnica LIME é considerada como sendo de interpretação local, posto que possui enfoque em explicar a razão pela qual uma previsão específica foi feita, de acordo com a contribuição de cada variável preditora [Ribeiro et al. 2016]. Por meio da biblioteca *lime* do *Python* pode-se aplicar essa técnica [Ribeiro 2016].

Já a técnica SHAP é capaz de fornecer uma medida padrão de importância de atributos, ou o valor de Shapley, sendo especialmente utilizada para modelos complexos, como do tipo *Ensemble* [Lundberg and Lee 2017]. Ela pode ser aplicada através da biblioteca *SHAP* desenvolvida na linguagem *Python* [Lundberg 2018].

A técnica *BreakDown* também pode ser aplicada para aprimorar a explicação de modelos complexos. Através dela, a contribuição de cada atributo para a previsão final do modelo é feita de maneira sequencial, considerando os efeitos de atributos subsequentes, enquanto os demais são mantidos em valores fixos. As medidas de contribuição dos atributos são representadas por meio de gráficos de cachoeira (*Waterfall Plots*), que facilitam a compreensão em forma de cenários [Staniak and Biecek 2018]. Ela pode ser aplicada por meio da biblioteca *dalex* do *Python* [Baniecki et al. 2021].

Por fim, os Gráficos de Dependência parcial podem ser gerados para o modelo de Florestas Aleatórias com a função *PartialDependenceDisplay* da biblioteca *Scikit-learn*.

4. RESULTADOS E DISCUSSÕES

O modelo de Florestas Aleatórias (RF) foi aplicado no conjunto de dados bioclimáticos para a espécie *Coragyps atratus* na estação seca, obtendo as métricas de classificação apresentadas na Tabela I. Nota-se que a acurácia é elevada (98 %), mas por se tratar de um problema de Classificação Desbalanceada, isso era esperado, pois existe uma classe predominante. Assim, é necessário também avaliar a métrica de Revocação. A elevada Revocação indica que o modelo foi capaz de aumentar a quantidade de Verdadeiros Positivos (VP) e reduzir os Falsos Negativos (FN).

Classificador	Acurácia	Revocação (Classe Positiva)
RF	98 %	62 %

Table I. Métricas de classificação para o modelo de Florestas Aleatórias

Já em relação à explicação, foi aplicada a técnica SHAP ao modelo de Florestas Aleatórias. Os módulos médios dos valores de Shapley são apresentados na Figura 1. Nela, observa-se que não existe uma diferença relevante nos módulos para as duas classes (Ausência da Espécie e Presença da Espécie). Entre as variáveis com maiores valores Shapley, ou seja, mais relevantes para a previsão do modelo estão: a concentração de óxidos de nitrogênio (NO_X), de isopreno (C_8H_8), a temperatura mínima e as concentrações de acetoneitrila (CH_3CN) e de metano (CH_4). As demais variáveis apresentam valores Shapley menores - em torno de 0,035.

Na Figura 2, são apresentados os valores Shapley para todas as linhas do conjunto de dados. Nela, cada ponto representa uma das linhas, sendo os pontos vermelhos correspondentes à classe positiva (Presença da Espécie) e os pontos azuis correspondentes à classe negativa (Ausência da Espécie). Assim, nota-se que para a variável mais importante (com módulo médio de valor Shapley maior), a

concentração de óxidos de nitrogênio (NO_X), a influência é predominantemente positiva (com valor Shapley maior que zero) para as classes de Presença da Espécie e negativa (com valor Shapley menor que zero) para as classes de Ausência da Espécie. Já para a concentração de isopreno (C_8H_5), a influência é contrária: é majoritariamente negativa para as classes positivas, além de positiva para as classes negativas, ou seja, a concentração de isopreno possui efeito negativo para a ocorrência da espécie *Coragyps atratus*. Para a variável de temperatura mínima, o comportamento é semelhante ao de NO_X . Já para as concentrações de acetonitrila (CH_3CN) e metano (CH_4), esse padrão não é claro, uma vez que existem classes positivas e negativas tanto com valores Shapley positivos, quanto negativos.

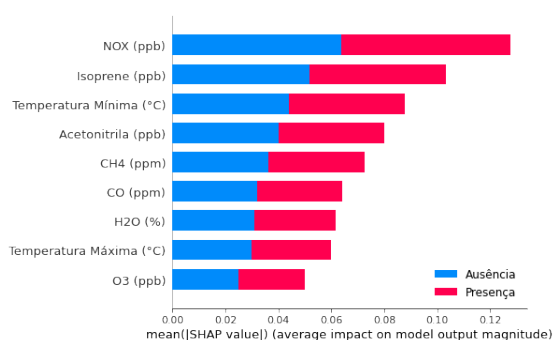


Fig. 1. Módulo médio dos valores de Shapley do modelo de Florestas Aleatórias para a espécie *Coragyps atratus*

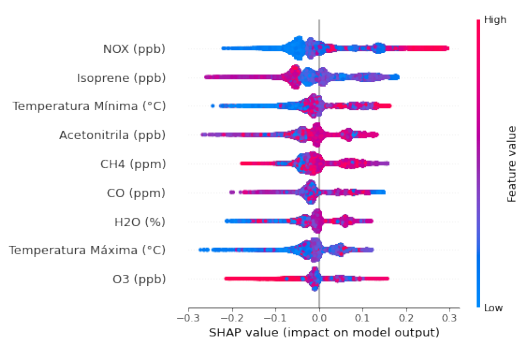


Fig. 2. Valores de Shapley do modelo de Florestas Aleatórias para a espécie *Coragyps atratus*

Também foi aplicada a técnica *BreakDown* para o classificador de Florestas Aleatórias. Para isso, foi selecionado um ponto para o qual a espécie *Coragyps atratus* não foi observada (classe negativa) e para o qual ela foi (classe positiva). Os *Waterfall plots* para os pontos selecionados são apresentados na Figura 3. Para o ponto de ausência da espécie, nota-se que as contribuições das variáveis preditoras são mais homogêneas, com um destaque maior para as variáveis de concentração de ozônio (O_3) e de acetonitrila (CH_3CN). Já para o ponto de presença da espécie, as contribuições positivas para as variáveis de concentração de acetonitrila (CH_3CN) e de isopreno (C_8H_5) são as mais relevantes.

Para os mesmos pontos de presença e ausência da espécie *Coragyps atratus* foi aplicada a técnica LIME. Essa tem como resultados gráficos semelhantes aos *Waterfall plots*. Na Figura 4, são apresentados os resultados para o modelo de Florestas Aleatórias. Para o ponto de ausência, nota-se que as variáveis que possuem maior influência nesse resultado são: as concentrações de isopreno, óxidos de nitrogênio e acetonitrila. Já para o ponto de presença, a variável que apresentou a maior influência positiva foi a concentração de óxidos de nitrogênio.

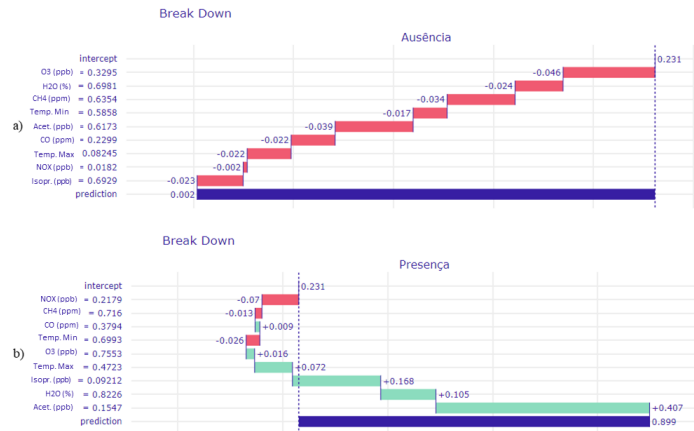


Fig. 3. Waterfall plot da aplicação da técnica BreakDown para modelo de Florestas Aleatórias para ponto de a) Ausência b) Presença da espécie *Coragyps atratus*

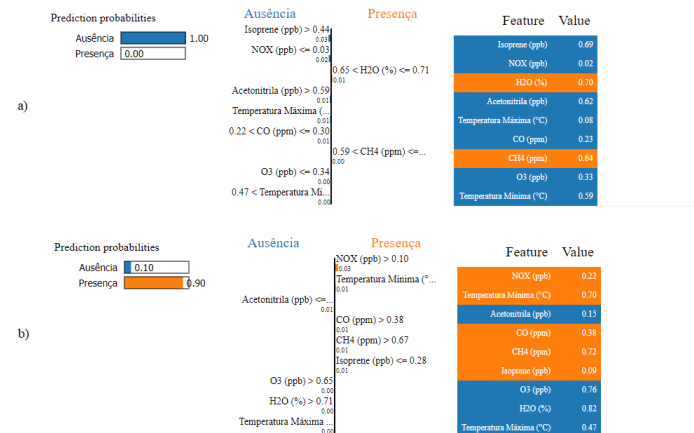


Fig. 4. Resultados da aplicação da técnica LIME para modelo de Florestas Aleatórias para ponto de a) Ausência b) Presença da espécie *Coragyps atratus*

Outro recurso que foi aplicado para aprimorar a capacidade de explicação do modelo foram os Gráficos de Dependência Parcial. Eles são apresentados na Figura 5 para o modelo de Florestas Aleatórias. Nela, observa-se que, por se tratar de um modelo não linear, existem descontinuidades. Além disso, a principal variável que possui efeito negativo na probabilidade de ocorrência da espécie *Coragyps atratus* é a concentração de isopreno: a probabilidade de ocorrência passa a ser nula a partir de 1,5 ppb de concentração. Ademais, para a concentração de ozônio é possível observar um decréscimo da probabilidade de ocorrência com o aumento de sua concentração, sendo menor de 12 % para valores acima de 15 ppb.

A partir dos resultados apresentados, nota-se que a aplicação da técnica SHapley Additive exPlanations permite avaliar as variáveis mais influentes tanto em relação ao seu módulo, quanto ao sinal, sendo possível fazer uma análise geral para os pontos de cada classe em função dos atributos. No entanto, não é possível identificar com clareza os valores ótimos das variáveis predictoras para a maior

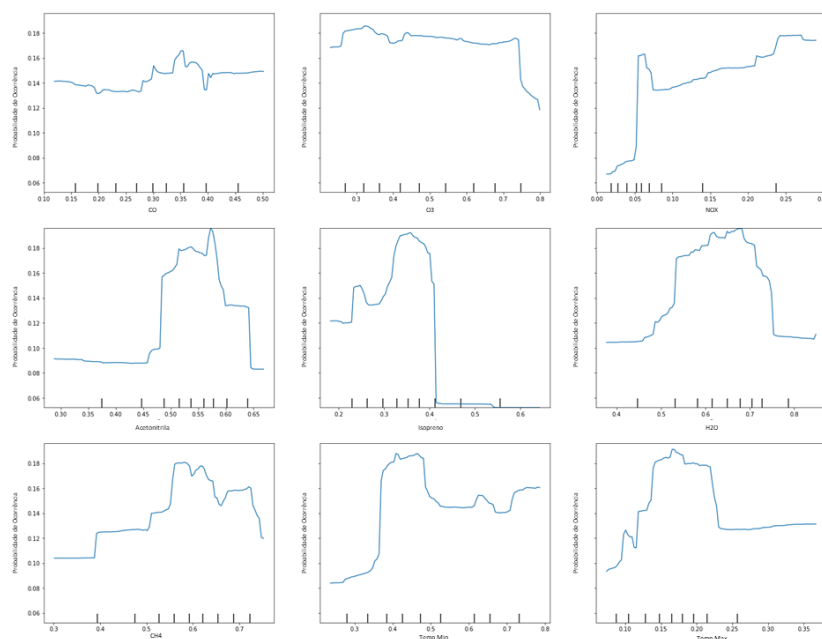


Fig. 5. Gráficos de Dependência Parcial do modelo de Florestas Aleatórias para probabilidade de ocorrência da espécie *Coragyps atratus* em função dos atributos

probabilidade de ocorrência da espécie analisada. Esses podem ser avaliados com maior exatidão através da construção dos Gráficos de Dependência Parcial. As técnicas de *BreakDown* e *Local Interpretable Model-Agnostic Explanation* são de maior utilidade para interpretações locais (de pontos em específico), como de presença ou de ausência da espécie. Porém, não é possível generalizar as tendências observadas para todos os pontos do conjunto de dados, nem identificar as faixas de valores ótimos de cada variável preditora.

Dessa forma, a aplicação da técnica SHAP para a avaliação das variáveis preditoras com maior influência, assim como o sinal do efeito (positivo ou negativo), em conjunto com os Gráficos de Dependência Parcial para identificar as faixas de valores para os quais a probabilidade de ocorrência da espécie é maior, mostra-se ideal para aprimorar a explicação dos modelos de distribuição de espécies. Esse tipo de avaliação não é possível apenas com as técnicas de interpretação naturalmente incorporadas ao modelo de Florestas Aleatórias.

5. CONCLUSÃO E TRABALHOS FUTUROS

Com os resultados obtidos conclui-se que foi possível avaliar a aplicação de quatro técnicas de Inteligência Artificial Explicável (LIME, SHAP, *BreakDown* e Gráficos de Dependência Parcial) para o classificador de Florestas Aleatórias. Com ele, foi realizado um estudo de caso de Modelagem de Distribuição de Espécies para o urubu-de-cabeça-preta (*Coragyps atratus*) na região central da Bacia Amazônica. Em termos de desempenho, obteve-se uma Acurácia de 98 % e uma Revocação de 62 %. Já em relação à explicação, as técnicas que permitiram uma maior interpretação para responder à hipótese científica, foram a aplicação de *SHapley Additive exPlanations* e dos Gráficos de Dependência Parcial. Assim, é possível responder quais variáveis preditoras são as mais relevantes para a probabilidade de ocorrência, seu sinal e as faixas de valores que maximizam a probabilidade.

Para trabalhos futuros, recomenda-se a avaliação da viabilidade de aplicar outras técnicas de xAI. Além disso, também podem ser avaliados outros modelos de Classificação - como os baseados em Redes Neurais Artificiais e *Support Vector Machines* - e seu processo de treinamento pode ser aprimorado com

a aplicação de métodos de balanceamento do conjunto de dados, principalmente para obter melhores desempenhos em relação à classe minoritária.

REFERENCES

- BANIECKI, H., KRETOWICZ, W., PIATYSZEK, P., WISNIEWSKI, J., AND BIECEK, P. dalex: Responsible machine learning with interactive explainability and fairness in python. *Journal of Machine Learning Research* 22 (214): 1–7, 2021.
- CARTER, S., VAN REES, C. B., HAND, B. K., MUHLFELD, C. C., LUIKART, G., AND KIMBALL, J. S. Testing a generalizable machine learning workflow for aquatic invasive species on rainbow trout (*oncorhynchus mykiss*) in northwest montana. *Frontiers in Big Data* vol. 4, 2021.
- DORAN, D., SCHULZ, S., AND BESOLD, T. R. What does explainable ai really mean? a new conceptualization of perspectives. In *Proceedings of the First International Workshop on Comprehensibility and Explanation in AI and ML*, 2017.
- ELITH, J. AND LEATHWICK, J. R. Species distribution models: Ecological explanation and prediction across space and time. *The Annual Review of Ecology, Evolution and Systematics* vol. 40, pp. 677–697, 2009.
- FERN, R. R., MORRISON, M. L., GRANT, W. E., WANG, H., AND CAMPBELL, T. A. Modeling the influence of livestock grazing pressure on grassland bird distributions. *Ecological Processes* 9 (42), 2020.
- HEGEL, T. M., CUSHMAN, A., EVANS, J., AND HUETMANN, F. Current State of the Art for Statistical Modelling of Species Distributions. In *Spatial Complexity, Informatics and Wildlife Conservation*. Springer, 2010.
- HERNANDEZ, P. A., GRAHAM, C. H., MASTER, L. L., AND ALBERT, D. L. The effect of sample size and species characteristics on performance of different species distribution modeling methods. *Ecography* 29 (5): 773–785, 2006.
- LUNDBERG, S. Shap documentation. <https://shap.readthedocs.io/en/latest/>, 2018. Acesso em: 03/07/2022.
- LUNDBERG, S. M. AND LEE, S. A unified approach to interpreting model predictions. In *Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017)*, 2017.
- MARTIN, S. T., ARTAXO, P., MACHADO, L., MANZI, A. O., SOUZA, R. A. F. D., SCHUMACHER, C., WANG, J., BISCARO, T., BRITO, J., CALHEIROS, A., ET AL. The green ocean amazon experiment (goamazon2014/5) observes pollution affecting gases, aerosols, clouds, and rainfall over the rain forest. *Bulletin of the American Meteorological Society* 98 (5): 981–997, 2017.
- MATEO, R. G., VANDERPOORTEN, A., MUÑOZ, J., LAENEN, B., AND DÉSAMORÉ, A. Modeling species distributions from heterogeneous data for the biogeographic regionalization of the european bryophyte flora. *PLoS One* 8 (2): e55648, 2013.
- MIYAJI, R. O., ALMEIDA, F. V., BAUER, L. O., FERRARI, V., CORRÊA, P. L. P., RIZZO, L. V., AND PRAKASH, G. Spatial interpolation of air pollutant and meteorological variables in central amazonia. *Data* 6 (12), 2021.
- MURDOCH, W. J., SINGH, C., KUMBIER, K., ABBASI-ASI, R., AND YU, B. Definitions, methods, and applications in interpretable machine learning. In *Proceedings of the National Academy of Sciences of the United States of America*. pp. 22071–22080, 2019.
- NURHUSSEN, A., ATZBERGER, C., AND ZEWDIA, W. Species distribution modelling performance and its implication for sentinel-2-based prediction of invasive prosopis juliflora in lower awash river basin, ethiopia. *Ecological Processes* 10 (18), 2021.
- PHILLIPS, S. J. Maximum entropy modeling of species geographic distribution. *Ecological Modelling* vol. 190, pp. 231–259, 2005.
- PHILLIPS, S. J., DUDIK, M., AND SCHAPIRE, R. E. A. Maximum entropy approach to species distribution modelling. In *Proceedings of the Twenty-First International Conference on Machine Learning*. pp. 655–662, 2004.
- PINAYA, J. AND CORRÊA, P. Metodologia para definição das atividades do processo de modelagem de distribuição de espécies. In *Anais do V Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais*. SBC, Porto Alegre, RS, Brasil, pp. 45–54, 2014.
- RADEMAKER, M., HOGEWEG, L., AND VOS, R. Modelling the niches of wild and domestic ungulate species using deep learning. *Biodiversity Information Science and Standards*, 2019.
- RIBEIRO, M. T. Local interpretable model-agnostic explanations (lime) documentation. <https://lime-ml.readthedocs.io/en/latest/>, 2016. Acesso em: 03/07/2022.
- RIBEIRO, M. T., SINGH, S., AND GUESTRIN, C. “why should i trust you?” explaining the prediction of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. pp. 1135–1144, 2016.
- RYO, M., ANGELOV, B., MAMMOLA, S., KASS, J. M., BENITO, B. M., AND F, H. Explainable artificial intelligence enhances the ecological interpretability of black-box species distribution models. *Ecography* vol. 44, pp. 199–205, 2021.
- STANIAK, M. AND BIECEK, P. Explanations of models predictions with live and breakdown packages. *The R Journal* 10 (2): 395–409, 2018.