



Uso de dados climáticos e *machine learning* na previsão de chuvas para gestão sustentável do ecoturismo em Francisco Beltrão (PR)

Use of climate data and machine learning for rainfall prediction in the sustainable management of ecotourism in Francisco Beltrão (PR, Brazil)

Emanuelle Lino Scheifer, Gabrielly Queiroz, Adriana Aparecida Guimarães, Luiz Fernando Souza, Juliana Aparecida Soltes Lorenzetto

RESUMO: A utilização de dados climáticos e técnicas de inteligência artificial tem se mostrado uma estratégia promissora no desenvolvimento de ferramentas voltadas ao planejamento e à gestão sustentável de atividades em ambientes naturais. Neste estudo, foi desenvolvido um modelo preditivo para a ocorrência de chuvas no município de Francisco Beltrão, Paraná, com base em registros históricos de variáveis meteorológicas como temperatura, umidade relativa, evaporação, insolação e precipitação. A base de dados, composta por observações diárias coletadas por estação oficial, passou por processos de tratamento, extração de atributos temporais e categorização binária do volume de chuva. Em seguida, foi treinado um modelo Random Forest, avaliado com métricas de desempenho como acurácia, precisão, recall, F1-score e área sob a curva ROC. Os resultados obtidos revelaram uma acurácia de 83% na previsão de dias chuvosos e secos, com destaque para a correta identificação de 91% dos dias sem chuva. As variáveis de maior influência foram *evaporacao* e *umidrel*, corroborando relações climáticas já conhecidas. As análises gráficas permitiram compreender o comportamento do modelo diante do desbalanceamento entre as classes, além de evidenciar a relevância das variáveis envolvidas. A solução proposta demonstrou potencial de aplicação no suporte a decisões relacionadas à programação de trilhas, segurança de visitantes e manejo de áreas em contextos de ecoturismo, contribuindo para o uso racional dos espaços e para a preservação ambiental. A estrutura do sistema pode ser replicada para outras localidades e aprimorada com a integração de dados de previsão em tempo real, ampliando seu alcance operacional.

PALAVRAS-CHAVE: Aprendizado de Máquina; Ecoturismo; Previsão de Chuva; Dados Climáticos; Sustentabilidade.

ABSTRACT: The use of climate data and artificial intelligence techniques has emerged as a promising strategy for developing tools aimed at planning and sustainable management of activities in natural environments. This study developed a predictive model for rainfall occurrence in Francisco Beltrão, Paraná, Brazil) based on historical records of meteorological variables such as temperature, relative humidity, evaporation, solar radiation, and precipitation. The dataset, composed of daily observations from an official weather station, underwent preprocessing, temporal feature extraction, and binary categorization of rainfall volumes. A Random Forest model was trained and evaluated using performance metrics including accuracy, precision, recall, F1-score, and ROC AUC. Results indicated 83% accuracy in predicting rainy and dry days, with 91% of dry days correctly identified. The most influential variables were evaporation and relative humidity, confirming known climate dynamics. Graphical analyses contributed to understanding model behavior under class imbalance and highlighted variable importance. The proposed system showed practical potential to support decision-making in trail scheduling, visitor safety, and area management within ecotourism contexts, enhancing sustainable land use and environmental conservation. The model's structure is replicable in other regions and can be expanded with real-time forecasting data to increase operational effectiveness.

KEYWORDS: Machine Learning; Ecotourism; Rainfall Prediction; Climate Data; Sustainability.

Introdução

As mudanças climáticas têm alterado significativamente os padrões meteorológicos globais, afetando diretamente diversos setores da sociedade, especialmente o turismo em áreas naturais. A crescente imprevisibilidade climática interfere na programação de atividades ao ar livre, impactando a segurança e a experiência dos visitantes (CNN Brasil, 2023). Nesse contexto, o ecoturismo se destaca como uma das modalidades mais vulneráveis, pois depende da estabilidade ambiental e das condições climáticas favoráveis para sua prática (Revista FBGA, 2022). A ocorrência de chuvas, em particular, representa um fator determinante, capaz de comprometer trilhas, gerar riscos físicos aos turistas e acentuar os impactos ambientais em áreas frágeis (Brasil, 2021).

A previsão de chuvas, portanto, torna-se um recurso estratégico essencial para a gestão sustentável de unidades de conservação e destinos de natureza. A correta antecipação de eventos climáticos pode subsidiar decisões sobre abertura de trilhas, agendamentos de visitas, implementação de alertas de risco e manutenção de infraestrutura ecológica (Envolverde, 2020). Além disso, a adoção de tecnologias preditivas auxilia na minimização dos danos causados por eventos extremos e contribui para uma experiência mais segura e satisfatória aos visitantes (Brasil, 2021). Dessa forma, ferramentas baseadas em dados são fundamentais para alinhar preservação ambiental, segurança e uso público responsável.

Nos últimos anos, o avanço da ciência de dados e a popularização de técnicas de inteligência artificial têm revolucionado a meteorologia aplicada. A

utilização de algoritmos de aprendizado de máquina (machine learning), alimentados por grandes volumes de dados históricos, tem permitido a identificação de padrões climáticos complexos com maior precisão e agilidade (I4SEA, 2022). Modelos como Random Forest, redes neurais e SVM têm sido empregados com sucesso na previsão de eventos como precipitação, temperaturas extremas e fenômenos adversos (Aguiar; Silva, 2022). Além de prever a ocorrência de chuvas, essas abordagens possibilitam compreender a influência relativa das variáveis meteorológicas envolvidas, o que potencializa sua aplicabilidade prática (Observatório Nacional, 2023).

A aplicação de tais soluções em municípios de porte médio, como Francisco Beltrão, é particularmente relevante. Apesar de possuírem potencial turístico expressivo, essas cidades muitas vezes não contam com sistemas sofisticados de monitoramento climático (Ferreira; Oliveira, 2018). Estudos voltados à realidade local, que considerem suas especificidades geográficas e climáticas, podem gerar soluções acessíveis, escaláveis e com alto impacto para o planejamento do ecoturismo (Redalyc, 2021). A adoção de modelos preditivos também estimula a inovação e fortalece a gestão ambiental em contextos fora dos grandes centros turísticos.

Diversas variáveis meteorológicas são tradicionalmente utilizadas em modelos de previsão de chuvas, como temperatura, umidade relativa, evaporação, insolação e velocidade do vento. A análise conjunta dessas variáveis permite identificar condições atmosféricas propícias à precipitação (BRASIL, 2021). O uso de aprendizado de máquina se destaca por sua capacidade de lidar com dados extensos, não lineares e com interações complexas entre variáveis. Além disso, esses modelos são adaptativos, podendo ser continuamente aprimorados com a inserção de novos dados, o que garante atualizações alinhadas à realidade local (Aguiar; Silva, 2022; I4SEA, 2022).

Material e Métodos

O presente estudo foi desenvolvido com base em um conjunto de dados climáticos históricos da cidade de Francisco Beltrão, localizada no estado do Paraná, região Sul do Brasil. Os dados foram obtidos por meio da estação meteorológica operada pelo Instituto Agrônomo do Paraná (IAPAR) e fornecidos em formato Excel (.xlsx). Cada entrada da base representa registros diários contendo informações sobre temperatura mínima, média e máxima (°C), umidade relativa do ar (%), velocidade do vento a 2 metros de altura (km/h), radiação solar (horas de insolação), evaporação (mm) e volume de precipitação acumulada (mm).

A preparação dos dados foi realizada no ambiente Google Colab utilizando a linguagem Python e bibliotecas específicas para análise de dados e aprendizado de máquina. Inicialmente, o conjunto de dados passou por uma etapa de limpeza que envolveu a remoção de uma linha redundante de cabeçalho, conversão das colunas para tipos numéricos adequados e exclusão de registros com valores ausentes. Para permitir uma análise temporal mais refinada, a coluna de datas foi convertida para o tipo *datetime* e utilizada para derivar novas variáveis categóricas: mês, dia do mês, ano e dia da semana.

Com o objetivo de transformar a tarefa em um problema de classificação binária, foi criada uma variável-alvo denominada *vai_chover*, que recebeu o valor 1 nos dias em que a precipitação registrada ultrapassou 1 milímetro, e 0 nos demais casos. Essa decisão foi tomada para distinguir entre dias secos e dias com chuva perceptível, com potencial impacto nas atividades ao ar livre e no setor de ecoturismo.

A análise exploratória dos dados foi conduzida por meio de gráficos de distribuição, contagem de classes e mapas de correlação entre as variáveis. Essa etapa permitiu identificar padrões climáticos locais e avaliar a consistência interna do conjunto de dados. A visualização gráfica também foi utilizada para verificar a predominância de classes (dias com ou sem chuva), o que é essencial para o entendimento do comportamento do modelo.

Para a construção do modelo preditivo, foi escolhido o algoritmo *Random Forest*, que pertence à classe dos classificadores baseados em árvores de decisão. Essa escolha foi motivada por sua capacidade de lidar com variáveis numéricas e categóricas, sua resistência ao overfitting em conjuntos de dados ruidosos e sua capacidade de fornecer medidas de importância das variáveis. O conjunto de dados foi dividido em dois subconjuntos: 80% para o treinamento e 20% para o teste, utilizando amostragem aleatória com semente fixa para garantir a reprodutibilidade.

As variáveis independentes utilizadas na modelagem incluíram os parâmetros climáticos (temperaturas, umidade, vento, insolação e evaporação), bem como os atributos temporais derivados (mês, dia e dia da semana). O treinamento e a avaliação do modelo foram realizados com a biblioteca *scikit-learn*, amplamente empregada para tarefas de aprendizado supervisionado. As previsões geradas pelo modelo foram comparadas com os valores reais utilizando métricas de avaliação como acurácia, precisão, recall, F1-score e matriz de confusão. Além disso, foi calculada a área sob a curva ROC (Receiver Operating Characteristic) para aferir a capacidade discriminativa do classificador.

Por fim, foi realizada uma análise da importância relativa das variáveis utilizadas, com o intuito de identificar quais atributos mais contribuíram para a decisão do modelo. As visualizações resultantes — incluindo gráficos de importância, curvas ROC e matrizes de confusão — auxiliaram na interpretação dos resultados e na validação do modelo proposto. Todo o processo foi documentado e implementado de forma reprodutível, com o objetivo de servir como base para futuras aplicações em sistemas de apoio à decisão para o planejamento de atividades ecoturísticas em função das condições climáticas previstas.

Resultados e Discussão

Após o desenvolvimento e validação do modelo preditivo de ocorrência de chuva utilizando o algoritmo *Random Forest*, foram obtidos resultados expressivos em termos de acurácia, desempenho de classificação e interpretação das variáveis envolvidas. As análises visuais e numéricas permitiram avaliar a qualidade do modelo e compreender aspectos climáticos

relevantes para a região de Francisco Beltrão, o que tem implicações diretas para o planejamento de atividades no contexto do ecoturismo.

A Figura 1 apresenta a distribuição dos dias com e sem chuva ao longo do período analisado. Verifica-se que o número de dias sem chuva (precipitação inferior ou igual a 1 mm) é significativamente maior que o número de dias com chuva. O desequilíbrio entre as classes é notável: aproximadamente 77% dos dias registrados no histórico não apresentam volumes relevantes de precipitação, enquanto apenas cerca de 23% correspondem a dias chuvosos.




Figura 1: Distribuição dos dias com e sem chuva.

Figure 1: Distribution of days with and without rain.

Fonte: elaborado pelos autores (2025).

Source: elaborated by the authors (2025).

Esse cenário é típico de dados meteorológicos históricos em regiões com regime de chuvas concentradas em determinadas épocas do ano. Para o modelo de aprendizado de máquina, essa desproporção representa um desafio, pois algoritmos de classificação tendem a ser influenciados pela classe majoritária, exigindo atenção especial na avaliação das métricas de desempenho.

Na Figura 2, observa-se o mapa de correlação entre as variáveis climáticas utilizadas no treinamento do modelo. As variáveis de temperatura (mínima, média e máxima) apresentam correlações muito altas entre si, especialmente entre tempmed e tempmax (0.90), e tempmed e tempmin (0.87), evidenciando que há uma grande redundância de informação térmica nos dados.

A variável chuva, por sua vez, apresenta correlação positiva com umidrel (0.35), o que é consistente com a literatura meteorológica, dado que altos níveis de umidade são pré-condições para a formação de precipitação. Por outro lado, chuva apresenta correlações negativas com tempmax, insolacao e evaporacao.

Esses resultados sugerem que dias com maior incidência de radiação solar e temperaturas elevadas tendem a não ser chuvosos, o que também se alinha com o comportamento esperado do clima subtropical da região analisada. Esses padrões evidenciam a importância de utilizar múltiplas variáveis para capturar a complexidade dos fenômenos atmosféricos.





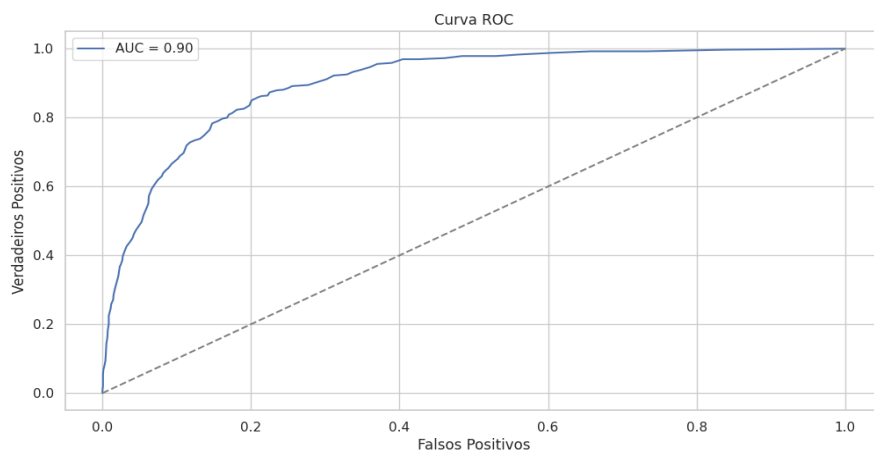
Figura 2: Mapa de Correlação de Variáveis Climáticas.
Figure 2: Correlation Map of Climate Variables.
Fonte: elaborado pelos autores (2025).
Source: elaborated by the authors (2025).

A Figura 3 mostra a matriz de confusão obtida após a aplicação do modelo ao conjunto de teste. Dos 1538 dias sem chuva (classe 0), o modelo previu corretamente 1394, resultando em uma taxa de acerto de aproximadamente 91% para essa classe. Já na classe 1 (dias com chuva), 436 dos 654 dias foram corretamente classificados, enquanto 218 foram classificados erroneamente como dias sem chuva (falsos negativos).

A matriz mostra que o modelo tem maior precisão para prever a ausência de chuva, o que é um comportamento comum em modelos treinados com bases desbalanceadas. No entanto, mesmo com essa limitação, a capacidade do modelo de identificar corretamente dois terços dos dias chuvosos é relevante do ponto de vista prático. Em aplicações reais, como o planejamento de atividades ao ar livre, essa previsão pode servir como alerta de risco e ajudar a minimizar contratempos causados por chuvas inesperadas.

**Figura 3:** Matriz de Confusão.**Figure 3:** Confusion matrix.**Fonte:** elaborado pelos autores (2025).**Source:** elaborated by the authors (2025).

A Figura 4 exibe a curva ROC (Receiver Operating Characteristic), que permite avaliar a capacidade discriminativa do modelo, ou seja, sua habilidade de separar corretamente as classes positivas (chuva) e negativas (sem chuva). A área sob a curva (AUC) atingiu o valor de 0.90, o que indica excelente desempenho. Quanto mais próxima de 1, melhor é a separação entre as classes. O formato da curva reforça que o modelo é capaz de manter altos valores de verdadeiro positivo mesmo com baixos falsos positivos, o que é desejável em sistemas de apoio à decisão, especialmente quando falsos alarmes (prever chuva onde não há) são menos prejudiciais do que a omissão de alertas (não prever onde haverá chuva).

**Figura 4:** Curva ROC.**Figure 4:** ROC curve.**Fonte:** elaborado pelos autores (2025).**Source:** elaborated by the authors (2025).

A Figura 5 apresenta a importância relativa de cada variável no processo decisório do modelo *Random Forest*, medida por sua contribuição para a redução da impureza nas árvores de decisão. Destaca-se a variável *evaporacao* como a mais influente na previsão de chuva, com importância superior a 0,26. Este resultado é coerente com a dinâmica atmosférica, uma vez que altos índices de evaporação tendem a ocorrer em dias quentes e secos, o que está associado à ausência de chuva. Na sequência, a variável *umidrel* aparece como a segunda mais relevante, reforçando a observação feita na análise de correlação (Figura 2) de que a umidade relativa do ar é um fator diretamente associado à formação de precipitação.




Figura 5: Importância das Variáveis no Modelo.

Figure 5: Importance of Variables in the Model.

Fonte: elaborado pelos autores (2025).

Source: elaborated by the authors (2025).

As temperaturas mínimas (*tempmin*) e máxima (*tempmax*), bem como a *insolacao*, também figuram entre as variáveis com maior influência, o que está de acordo com o entendimento climático de que o calor e a radiação solar modulam os processos de convecção e formação de nuvens. Embora as três variáveis de temperatura apresentem certa redundância, o modelo identificou nuances entre elas que justificam suas posições diferenciadas no ranking de importância. Variáveis como *vento2m* e os atributos temporais (*dia*, *mes* e *dia_semana*) apresentam menor influência individual, mas ainda assim contribuem para refinar a previsão ao capturar padrões sazonais ou semanais típicos de eventos meteorológicos.

Essa análise de importância é valiosa tanto para a interpretação do modelo quanto para aplicações práticas. Em cenários de coleta limitada de dados, por exemplo, é possível priorizar sensores ou fontes de dados que capturam as variáveis mais relevantes, otimizando recursos em projetos de monitoramento climático voltados à gestão de atividades ecoturísticas. Além disso, a identificação clara dos atributos mais influentes permite a adaptação do modelo para outros contextos geográficos, com foco nas variáveis que demonstraram maior poder discriminativo.

A Tabela 1 apresenta os principais indicadores de desempenho do modelo *Random Forest* utilizado para prever a ocorrência de chuvas a partir de dados climáticos históricos da cidade de Francisco Beltrão. Os resultados demonstram um desempenho bastante sólido, especialmente na previsão de dias sem chuva. A classe 0, que representa esses dias, obteve precisão de 0,86 e recall de 0,91, com um F1-score de 0,89 — evidenciando que o modelo erra pouco ao classificar dias secos. A classe 1, correspondente aos dias chuvosos, apresentou desempenho inferior: 0,75 de precisão, 0,67 de recall e F1-score de 0,71. Isso indica que, embora o modelo consiga capturar parte dos padrões que antecedem eventos de chuva, ele apresenta maior dificuldade em identificar todos os casos corretamente. Ainda assim, o valor de acurácia global de 83% é expressivo dentro do contexto de dados ambientais naturalmente ruidosos e sazonais, como os dados meteorológicos.

Tabela 1: Resultados do Relatório de Classificação do Modelo *Random Forest* para Previsão de Chuva.

Table 1: Classification Report Results of the *Random Forest* Model for Rainfall Prediction.

Classe	Precisão	Recall	F1-score	Suporte
0 – Sem chuva	0.86	0.91	0.89	1538
1 – Com chuva	0.75	0.67	0.71	654
Acurácia			0.83	2192
Média macro	0.81	0.79	0.80	2192
Média ponderada	0.83	0.83	0.83	2192

Essa diferença entre as classes está ilustrada na Figura 1, que mostra a distribuição de dias com e sem chuva. A predominância da classe 0 (dias secos) reflete o padrão climático da região, que concentra precipitações em determinados períodos do ano, resultando em um banco de dados desbalanceado. Esse desbalanceamento influencia diretamente a capacidade do modelo em aprender e generalizar os padrões da classe minoritária, o que se confirma na Figura 3, onde a matriz de confusão revela que o número de falsos negativos (dias chuvosos classificados como secos) é relevante — 218 casos, frente a 436 acertos para a classe 1.

Por outro lado, a Figura 4, que apresenta a curva ROC do modelo, mostra que ele possui uma capacidade discriminativa bastante elevada, com AUC de 0,90. Esse valor indica que, mesmo diante do desbalanceamento de classes, o modelo consegue distinguir com eficiência os padrões subjacentes entre dias secos e dias chuvosos. Na prática, isso representa um modelo robusto para aplicações que exijam confiabilidade em previsões binárias.

Complementando a análise, a Figura 2, com o mapa de correlação entre variáveis climáticas, mostra a forte dependência entre as variáveis de temperatura (mínima, média e máxima), com correlações superiores a 0,8. Esse agrupamento indica redundância informacional, mas o modelo conseguiu extrair valor diferencial de cada uma, como visto na Figura 5, que exhibe a importância relativa das variáveis no processo de decisão do algoritmo *Random Forest*. Destacam-se *evaporacao* e *umidrel* como as variáveis mais relevantes, seguidas por *tempmin* e *insolacao*. A presença dessas variáveis

no topo da hierarquia é coerente com o conhecimento meteorológico, pois dias de alta evaporação e baixa umidade relativa tendem a ser secos, enquanto dias úmidos e com menor insolação estão mais associados à formação de chuvas.

A estrutura do sistema construído para este estudo baseia-se em uma cadeia de processamento de dados simples e reproduzível. O sistema inicia com a ingestão de dados climáticos históricos, segue com o pré-processamento, criação de atributos derivados (como mês, dia e dia da semana), construção da variável-alvo (classificação binária de chuva) e culmina com o treinamento e avaliação de um modelo *Random Forest*. Os resultados são complementados com visualizações que tornam o sistema interpretável e acessível, inclusive para uso por gestores ambientais, técnicos de campo e operadores de turismo ecológico.

Em termos de aplicabilidade, o sistema possui forte potencial para apoiar a gestão sustentável do ecoturismo. Prever dias com e sem chuva com antecedência confiável pode auxiliar no agendamento de visitas guiadas, realização de trilhas, manejo de áreas sensíveis e orientação de visitantes quanto às condições climáticas previstas. Isso contribui diretamente para a preservação de trilhas, minimização de erosão causada por uso indevido em dias chuvosos, e segurança dos usuários que exploram ambientes naturais. O modelo pode ser integrado a aplicativos móveis, painéis em unidades de conservação, ou sistemas online que informem em tempo real a previsão de condições propícias ou adversas à visitação.

Apesar dos bons resultados, o sistema apresenta limitações. O primeiro desafio é o desbalanceamento da base de dados, que prejudica a sensibilidade do modelo em detectar dias chuvosos. Isso pode ser tratado com técnicas específicas, como o uso de *oversampling* (ex.: SMOTE), penalização da classe majoritária ou ajustes no *threshold* de classificação. Outro ponto crítico é a ausência de dados de previsão futura no treinamento — o sistema foi construído apenas com dados históricos, o que limita sua aplicação operacional imediata. Para torná-lo funcional em tempo real, seria necessário integrar dados de previsão climática (como modelos numéricos ou APIs meteorológicas) como entrada do modelo. Por fim, variáveis que não foram incluídas — como pressão atmosférica, cobertura de nuvens e temperatura do ponto de orvalho — poderiam enriquecer ainda mais o modelo.

Do ponto de vista técnico e ambiental, o estudo demonstra que o uso de dados climáticos combinados com aprendizado de máquina pode gerar ferramentas de previsão úteis e eficientes, capazes de ampliar o planejamento estratégico em áreas naturais. A previsão de chuvas não deve ser vista apenas como uma aplicação meteorológica, mas como um componente fundamental para a gestão integrada do território e das experiências turísticas sustentáveis. O caso de Francisco Beltrão mostra que mesmo municípios fora dos grandes eixos turísticos podem se beneficiar de soluções tecnológicas para promover o uso racional dos seus recursos naturais e valorizar a experiência dos seus visitantes com base em dados e inteligência artificial.

Considerações Finais

O presente estudo demonstrou a viabilidade e relevância da utilização de dados climáticos históricos combinados com técnicas de aprendizado de máquina para a previsão de chuvas em Francisco Beltrão, com foco na gestão sustentável do ecoturismo. A partir de registros meteorológicos diários, foi possível construir um modelo baseado em Random Forest capaz de prever a ocorrência de chuva com acurácia de 83%, destacando-se pela capacidade de identificar corretamente a ausência de precipitação e, com desempenho satisfatório, prever eventos chuvosos.

A análise dos dados revelou padrões climáticos consistentes com a dinâmica atmosférica da região, com forte correlação entre umidade relativa, temperatura, radiação solar e evaporação. O modelo identificou *evaporacao* e *umidrel* como variáveis-chave na classificação de dias chuvosos e secos, o que reforça a importância de selecionar atributos climáticos com base em fundamentos físicos e meteorológicos. Além disso, os gráficos de distribuição, matriz de confusão e curva ROC permitiram avaliar o comportamento do modelo frente ao desequilíbrio de classes, contribuindo para a transparência e interpretabilidade da solução proposta.

Os resultados obtidos indicam que o sistema desenvolvido pode ser aplicado como uma ferramenta de apoio ao planejamento de atividades ecoturísticas, auxiliando na tomada de decisão quanto à abertura de trilhas, agendamento de visitas e implementação de medidas preventivas em dias com maior risco de chuva. Essa abordagem favorece tanto a experiência dos visitantes quanto a conservação dos ambientes naturais, promovendo um uso mais consciente e planejado dos espaços ao ar livre.

Contudo, o estudo também identificou limitações que apontam para caminhos futuros. A predominância de dias secos no conjunto de dados influenciou negativamente a sensibilidade do modelo para a classe chuvosa, sendo necessário, em trabalhos posteriores, aplicar estratégias de balanceamento e incorporar variáveis meteorológicas adicionais. Além disso, a adaptação do sistema para funcionamento em tempo real requer a integração com dados de previsão climática, o que possibilitará aplicações operacionais mais amplas e dinâmicas.

Conclui-se, portanto, que a aplicação de inteligência artificial ao monitoramento climático representa um avanço estratégico para o ecoturismo, especialmente em contextos locais como o de Francisco Beltrão, onde o uso eficiente de dados pode contribuir para a valorização do território, segurança dos visitantes e preservação ambiental. O modelo desenvolvido neste trabalho serve como base para futuros aprimoramentos e para a construção de sistemas preditivos aplicáveis a diferentes regiões e realidades do turismo de natureza no Brasil.

Referências

AGUIAR, Guilherme; SILVA, Victor. Sistema de previsão climática baseado em Machine Learning. Brasília: Universidade de Brasília, 2022. **Trabalho de Conclusão de Curso**. Disponível em: https://bdm.unb.br/bitstream/10483/34525/1/2022_GuilhermeAguiar_VictorSilva_tcc.pdf. Acesso em: 05 jun. 2025.

BRASIL. Ministério do Turismo. Ecoturismo: orientações básicas. Brasília: **Ministério do Turismo**, 2021. Disponível em: <https://www.gov.br/turismo/pt-br/centrais-de-conteudo/-publicacoes/segmentacao-do-turismo/ecoturismo-orientacoes-basicas.pdf>. Acesso em: 05 jun. 2025.

BRASIL. Observatório Nacional. Estudo com participação do ON/MCTI usa machine learning para detectar eventos climáticos extremos. **ON**, Brasília, 2023. Disponível em: <https://www.gov.br/observatorio/pt-br/assuntos/noticias/estudo-com-participacao-do-on-mcti-usa-machine-learning-para-detectar-eventos-climaticos-extremos>. Acesso em: 05 jun. 2025.

CNN BRASIL. Mudanças climáticas já afetam turismo no Brasil, diz pesquisa. São Paulo, 2023. **CNN**, Disponível em: <https://www.cnnbrasil.com.br/economia/macroeconomia/mudancas-climaticas-ja-afetam-turismo-no-brasil-diz-pesquisa/>. Acesso em: 05 jun. 2025.

ENVOLVERDE. Ecoturismo e turismo de aventura com segurança no Brasil. **Revista Envolverde**, 2020. Disponível em: <https://envolverde.com.br/arquivo/ecoturismo-e-turismo-de-aventura-com-seguranca-no-brasil/>. Acesso em: 05 jun. 2025.

FERREIRA, Mariana; OLIVEIRA, Rafael. Tecnologias sustentáveis para cidades de médio porte: análise de potencial no sul do Brasil. **Revista de Planejamento e Sustentabilidade**, v. 6, n. 2, p. 45–62, 2018.

I4SEA. Melhores previsões do tempo com inteligência artificial. **Blog i4sea**, 2022. Disponível em: <https://www.i4sea.com/pt-br/blog/melhores-previsoes-do-tempo>. Acesso em: 05 jun. 2025.

REDALYC. Inteligência Artificial aplicada ao clima em municípios não metropolitanos: um estudo de caso no Paraná. **Revista Latino-Americana de Geografia e Meio Ambiente**, v. 30, n. 1, 2021. Disponível em: <https://www.redalyc.org/journal/1154/115459473012/html/>. Acesso em: 05 jun. 2025.

REVISTA FBGA. Os impactos das mudanças climáticas no ecoturismo. **Revista da Fundação Brasileira de Geografia Ambiental**, n. 10, p. 17–22, 2022. Disponível em: <https://revistafbga.com.br/os-impactos-das-mudancas-climaticas-no-ecoturismo/>. Acesso em: 05 jun. 2025.