



Campus São Mateus
UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO



MODELOS DE PREVISÃO DE IMPACTOS AMBIENTAIS COM INTELIGÊNCIA ARTIFICIAL: UMA REVISÃO BIBLIOMÉTRICA

Models for predicting environmental impacts with artificial intelligence: a bibliometric review

Modelos de predicción de impactos ambientales con inteligencia artificial: una revisión bibliométrica

Graziela Luiz Franco Martinez^{1*}, Michel Angelo Constantino² & Hemerson Pistori³

¹Universidade Federal de Rondônia - UNIR, Programa de Pós-Graduação em Ciências Ambientais ^{2,3}Universidade Católica Dom Bosco - UCDB, Programa de Pós-graduação Ciências Ambientais e Sustentabilidade Agropecuária

¹grazielafranco@unir.br ²michel@ucdb.br ³*In memoriam*

ARTIGO INFO.

Recebido: 31.10.2025

Disponibilizado: 20.07.2026

PALAVRAS-CHAVE: *Modelos de previsão; mudanças climáticas; machine learning.*

KEYWORDS: *Forecasting models; climate change; machine learning.*

PALABRAS CLAVE: *Modelos de previsión; cambio climático; machine learning*

***Autor Correspondente: Martinez, G. L. F.**

RESUMO

Este estudo examina a evolução da produção científica internacional sobre modelos de previsão de impactos ambientais baseados em algoritmos de Inteligência Artificial, com ênfase em técnicas de *Machine Learning-ML* aplicadas ao contexto das mudanças climáticas. O objetivo foi mapear tendências, identificar lacunas e avaliar a consolidação desse campo, considerando seu potencial de integração com métricas de sustentabilidade. A pesquisa utilizou métodos bibliométricos a partir de 631 artigos indexados na Web of Science entre 1945-2023, analisados com o pacote Bibliometrix no software R. Os resultados indicam crescimento exponencial das publicações a partir de 2016, acompanhado pela predominância de China, EUA e Índia tanto em volume quanto em influência científica. A aplicação das Leis de Bradford e Lotka revelou forte concentração da produção em poucos periódicos e elevada fragmentação autoral. A análise temática mostrou que machine learning, climate change e prediction models constituem os temas motores do campo, embora ainda focados em variáveis ambientais isoladas. Constatou-se ausência de modelos integrados que articulem previsões ambientais, impactos socioeconômicos e dimensões de governança, bem como inexistência de conexões sistemáticas entre técnicas de IA e indicadores ESG. Conclui-se que essa integração constitui uma fronteira promissora para pesquisas futuras e para a formulação de estratégias de sustentabilidade.

ABSTRACT

This study examines the evolution of international scientific production on environmental impact prediction models based on AI algorithms, with an emphasis on Machine Learning-ML techniques applied to the context of climate change. The objective was to map trends, identify gaps, and assess the consolidation of this field, considering its potential for integration with sustainability metrics. The research used bibliometric methods based on 631 articles indexed in the WoS between 1945-2023, analyzed with the Bibliometrix software in R. The results indicate an exponential growth of publications since 2016, accompanied by the predominance of China, EE. UU. and India both in volume and scientific influence. The application of the laws of Bradford and Lotka revealed a strong concentration of production in a few journals and high authorial fragmentation. The thematic analysis showed that ML, climate change, and prediction models are the driving themes of the field, although still focused on isolated environmental variables. It was found that there is an absence of integrated models articulating environmental forecasts, socioeconomic impacts, and governance dimensions, as well as a lack of systematic connections between AI techniques and ESG indicators. It is concluded that this integration constitutes a promising frontier for future research and for the formulation of sustainability strategies.

INTRODUÇÃO

Os Modelos Preditivos, que utilizam dados do passado para detectar padrões e prever comportamentos futuros (Greco, 2017), têm sido historicamente empregados em diversas áreas. Inicialmente, sua aplicação foi predominante no planejamento estratégico empresarial

research used bibliometric methods based on 631 articles indexed in the WoS between 1945-2023, analyzed with the Bibliometrix in R software. The results indicate exponential growth in publications since 2016, accompanied by the predominance of China, the USA, and India in both volume and scientific influence. The application of Bradford's and Lotka's Laws revealed a concentration of production in a few journals and high authorial fragmentation. The thematic analysis showed that ML, climate change, and prediction models are the driving themes of the field, although still focused on isolated environmental variables. It was found that there is an absence of integrated models articulating environmental forecasts, socioeconomic impacts, and governance dimensions, as well as a lack of systematic connections between AI techniques and ESG indicators. It is concluded that this integration constitutes a promising frontier for future research and for the formulation of sustainability strategies.

RESUMEN

Este estudio examina la evolución de la producción científica internacional sobre modelos de predicción del impacto ambiental basados en algoritmos de IA, con énfasis en las técnicas de *Machine Learning-ML* aplicadas al contexto del cambio climático. El objetivo fue mapear tendencias, identificar brechas y evaluar la consolidación de este campo, considerando su potencial para integrarse con métricas de sostenibilidad. La investigación utilizó métodos bibliométricos basados en 631 artículos indexados en la WoS entre 1945-2023, analizados con el software Bibliometrix en R. Los resultados indican un crecimiento exponencial de las publicaciones desde 2016, acompañado por el predominio de China, EE. UU. e India tanto en volumen como en influencia científica. La aplicación de las leyes de Bradford y Lotka reveló una concentración de la producción en pocas revistas y una alta fragmentación autoral. El análisis temático mostró que el ML, el cambio climático y los modelos de predicción son los temas impulsores del campo, aunque todavía centrados en variables ambientales aisladas. Se constató la ausencia de modelos integrados que articulen pronósticos ambientales, impactos socioeconómicos y dimensiones de gobernanza, así como la falta de conexiones sistemáticas entre técnicas de IA e indicadores ESG. Se concluye que esta integración constituye una frontera prometedora para investigaciones futuras y para la formulación de estrategias de sostenibilidad.

para identificar fraudes, reduzir riscos e otimizar vendas (Zaihong et al., 2012). No entanto, com o aumento das incertezas em todas as áreas do conhecimento, a necessidade de analisar e refletir sobre perspectivas futuras cresceu exponencialmente. Nesse contexto, modelos de predição bem elaborados, aplicados em diversas áreas, tornam-se ferramentas essenciais para embasar decisões futuras (Laniak et al., 2013). Uma área com grandes possibilidades e demandas de aplicação da predição de cenários é a ambiental, especialmente diante das constantes mudanças climáticas, consideradas uma das maiores preocupações globais (Hughes, L., 2003).

A intensificação das mudanças climáticas nas últimas décadas consolidou-se como um dos maiores desafios ambientais, sociais e econômicos da atualidade. Seus impactos ultrapassam o âmbito físico e ecológico, repercutindo nas dinâmicas produtivas, na segurança hídrica e alimentar, nas desigualdades sociais e na capacidade adaptativa das regiões mais vulneráveis (Hughes, 2003; Sullivan & Huntingford, 2009). Em meio a esse cenário marcado por incertezas crescentes, cresce também a demanda por instrumentos capazes de antecipar tendências e subsidiar decisões estratégicas orientadas para mitigação, adaptação e planejamento de longo prazo. Os modelos preditivos, historicamente utilizados em análises econômicas e processos decisórios empresariais, tornaram-se essenciais para estimar possíveis trajetórias climáticas e seus efeitos adversos (Wolpert, 1996; Wibisono et al., 2016).

A incorporação de algoritmos de Inteligência Artificial (IA), especialmente aqueles baseados em Machine Learning (ML), tem expandido de modo significativo o potencial desses modelos. Métodos como Redes Neurais Artificiais, Support Vector Machines, Random Forest, bem como abordagens avançadas de Deep Learning, oferecem elevada capacidade de processar grandes volumes de dados ambientais e de identificar padrões complexos que dificilmente seriam detectados por métodos estatísticos tradicionais (Miyano & Girosi, 1994; Roesch & Günther, 2018; Hussin et al., 2023). O uso dessas técnicas tem se consolidado na modelagem de fenômenos como variações de temperatura, precipitação, eventos extremos, emissão de carbono e uso do solo, revelando uma expansão significativa da IA nas pesquisas dedicadas à mudança climática global (Liu et al., 2021; Yan et al., 2021).

Entretanto, apesar do avanço técnico e da multiplicidade de aplicações, a literatura permanece fragmentada. As pesquisas concentram-se majoritariamente em fenômenos específicos, tais como previsão de secas, captura de carbono, consumo energético e dinâmica hidrológica, sem oferecer uma visão integrada sobre o desenvolvimento do campo (Belayneh et al., 2015; Banihashemi et al., 2017; Adisa et al., 2020). Além disso, embora as mudanças climáticas afetem profundamente dimensões econômicas e sociais, os modelos de previsão baseados em ML têm sido aplicados predominantemente para variáveis ambientais isoladas. Até onde este estudo pôde identificar, não há evidências consistentes de que tais modelos estejam incorporando, de forma simultânea e sistematizada, indicadores socioeconômicos que permitam estimar impactos integrados sobre populações e territórios. Essa lacuna teórico-metodológica, a ausência de modelos capazes de capturar conjuntamente impactos ambientais, econômicos e sociais, constitui um ponto crítico ainda pouco explorado na literatura científica atual.

Diante desse cenário, torna-se fundamental compreender como o campo tem evoluído, quais abordagens predominam na produção científica, em que áreas a pesquisa se concentra, quais

redes de colaboração estruturam esse domínio e, sobretudo, quais lacunas persistem na interseção entre modelos de predição, IA e mudanças climáticas. Nesse sentido, os métodos bibliométricos constituem uma abordagem adequada e rigorosa para mapear tendências, descrever padrões de publicação, identificar núcleos de produção científica, visualizar redes de cooperação e compreender a evolução temática de um campo em expansão (Bornmann, 2015; Su & Lee, 2010; Thompson & Walker, 2015).


O presente artigo, portanto, tem como objetivo analisar a produção científica internacional sobre modelos de previsão de impactos ambientais que utilizam algoritmos de Machine Learning, buscando compreender sua evolução, identificar seus principais focos de pesquisa, mapear suas estruturas temáticas e apontar lacunas ainda existentes nesse domínio interdisciplinar. Ao oferecer uma leitura sistematizada do campo, este estudo busca contribuir para o amadurecimento conceitual e metodológico da área, bem como apoiar futuras investigações voltadas ao desenvolvimento de modelos preditivos mais abrangentes, capazes de integrar indicadores ambientais, econômicos e sociais e, assim, fornecer subsídios mais robustos para políticas públicas e estratégias de adaptação às mudanças climáticas.

METODOLOGIA

Uma abordagem bibliométrica foi adotada por sua capacidade de quantificar, organizar e interpretar padrões de produção científica em áreas emergentes, permitindo identificar tendências, lacunas e potenciais conexões temáticas (Okubo, 1997; Thompson & Walker, 2015). Concentrou-se na base de dados Web of Science (WoS), adotada por sua abrangência multidisciplinar e relevância em análises de impacto científico (WoS, 2005). A escolha previu maior uniformidade nos resultados e rigor metodológico, já que artigos revisados por pares e trabalhos completos publicados em anais de eventos foram considerados.

A estratégia de busca baseou-se em três grupos de palavras-chave. O primeiro agrupou termos relacionados às técnicas de Inteligência Artificial e Aprendizado de Máquina, incluindo “Machine Learning”, “Deep Learning”, “Artificial Neural Networks”, “Support Vector Machines”, “Decision Trees”, “Random Trees”, “ANN” e “SVM”. O segundo contemplou expressões ligadas à modelagem preditiva, como “Prediction”, “Forecast” e “Regression”. O terceiro grupo incorporou a dimensão ambiental, com os termos “Global Climate Change” e “Global Warming”. O operador lógico “OR” foi utilizado dentro de cada grupo para abarcar sinônimos e variações terminológicas, enquanto “AND” combinou os três conjuntos, assegurando que apenas artigos que tratassem simultaneamente de algoritmos de aprendizado de máquina, previsão e mudanças climáticas fossem recuperados.

Assim, formulou-se 4 questões de pesquisa: (i) quais tipos de investigação têm sido desenvolvidos sobre previsão de cenários relacionados às mudanças climáticas globais; (ii) de que forma algoritmos de ML são aplicados na construção de modelos ambientais; (iii) como evoluiu a produção científica nesse campo ao longo do tempo; e (iv) quais lacunas são identificadas a partir do mapeamento bibliométrico. Tais questões serviram como guia para o refinamento dos resultados e interpretação crítica das evidências. Ademais, incluiu-se apenas artigos e *proceedings papers* publicados (1945 a 2023), idioma inglês e correspondendo exatamente às combinações da chave de busca. Excluindo-se livros, capítulos, erratas e outros documentos não enquadrados como pesquisa científica. Após filtragem, 631 artigos compuseram o corpus final de análise (Figura 1).

Figura 1. Síntese das etapas e procedimentos adotados - delineamento da busca até a análise dos dados

Fonte: Autores.

Os dados foram exportados em formato BibTeX e tratados com o pacote Bibliometrix do software R (Aria & Cucurullo, 2017), por meio da interface Biblioshiny, que possibilita análises descritivas e visuais dos dados. O processo envolveu a contabilização do número de publicações anuais, identificação de autores, instituições e países mais produtivos, além da análise de redes de colaboração científica. Foram também aplicados indicadores clássicos como a Lei de Bradford (1934), que avalia a concentração da produção em periódicos, e a Lei de Lotka (1926), que mede a produtividade de autores em determinada área (Urbizagastegui, 2008; Rodrigues & Godoy, 2016; Sembay et al., 2020). Por fim, realizou-se a análise de palavras-chave, possibilitando a construção de mapas temáticos e clusters de acoplamento, que revelaram tanto os temas centrais quanto os emergentes no campo de estudo.

RESULTADOS E DISCUSSÃO

Panorama Geral da Produção Científica

Os dados coletados na base WoS indicaram um total de 631 artigos publicados entre 1945 e 2023, sendo que a produção se tornou significativa a partir da década de 2010 e atingiu crescimento exponencial após 2016. Considerando que não foram aplicados filtros para o período de publicação, os anos de 1945 a 1995 são considerados improdutivos, uma vez que não apresentaram publicações envolvendo a palavra-chave de busca. A evolução das publicações, em termos de número de artigos e citações, pode ser dividida em quatro fases:


- Fase I (1945-1995): período com “zero” publicações;
- Fase II (1995-2010): intervalo com “n=1 a n=4” publicações, correspondendo a 0,168% e 0,634% do total de publicações, respectivamente;
- Fase III (2011-2015): registra de 1,109% (n=7) a 1,585% (n=10) do total de publicações, respectivamente; e
- Fase IV (2016-2023): apresenta um crescimento acelerado das publicações nessa área e um aumento significativo da tendência e do interesse pela pesquisa. Em 2016, contabilizam-se n=18 (2,853%); em 2022 esse número sobe para n=147 (23,296%); e em 2023* já alcança n=136 (21,553%).

Esse resultado confirma a hipótese de que o avanço das técnicas de *machine learning* e *deep learning* foi decisivo para estimular pesquisas ambientais orientadas por dados massivos

(Müller & Bostron, 2016; Hussin et al., 2023). A intensificação do debate científico internacional sobre mudanças climáticas, em especial após os relatórios do IPCC de 2007 e 2014, também contribuiu para o aumento expressivo do número de publicações (Haunschild, Bornmann & Marx, 2016). A partir de 2016, a literatura apresenta não apenas maior volume, mas também maior diversificação temática, cobrindo desde a previsão de eventos climáticos extremos até o uso de modelos híbridos em energias renováveis e emissões de carbono. Essa expansão significa o desenvolvimento progressivo da disciplina, embora a metodologia relativa a parâmetros ambientais específicos, incluindo opções, temperatura e CO₂, permaneça predominante.

O exame das afiliações dos autores revela acentuada concentração geográfica da produção cinetífica. China, Estados Unidos e Índia estão na vanguarda do volume de publicações, representando coletivamente mais de 50% da produção global. A China ocupa posição de destaque com aproximadamente 24,7% das publicações, seguida pelos Estados Unidos (19,8%) e pela Índia (11,2%). O Brasil, embora presente, ainda representa parcela modesta da produção, com baixa taxa de colaboração internacional (Figura 2).

Figura 2. Mapa da colaboração científica entre países considerando as palavras-chave (WoS e de 1945 a 2023)




Fonte: Autores. Obs.: mínimo de 2 conjuntas.

A liderança da China pode ser explicada pelo volume de investimentos em pesquisa aplicada às mudanças climáticas e ao desenvolvimento de tecnologias de energia limpa, áreas estratégicas para o país. Já os Estados Unidos mantêm forte tradição em ciência climática e ciência da computação, o que facilita a convergência interdisciplinar. A Índia, por sua vez, tem ampliado sua participação em virtude da vulnerabilidade climática e da necessidade de soluções tecnológicas para mitigar riscos agrícolas e hídricos.

É importante ressaltar que a concentração da produção em poucos países pode gerar desequilíbrios no desenvolvimento do campo, sobretudo porque diferentes regiões enfrentam impactos climáticos específicos que demandariam soluções localmente adaptadas. A baixa representatividade de países latino-americanos e africanos, por exemplo, limita a diversidade de contextos analisados e restringe a aplicabilidade global dos modelos produzidos.

Outro aspecto fundamental é a análise das redes de colaboração entre países. Observa-se que, apesar do elevado volume de publicações, a China apresenta baixa taxa de colaboração internacional, com cerca de 23,4% de seus artigos desenvolvidos em parceria com outros países ($MCP = 0,234$). A maior parte de sua produção é doméstica, evidenciando forte capacidade interna, mas limitada integração global (Figura 3).

Figura 3. Produção científica por país considerando a autoria dos artigos publicados na WoS e colaboração



Fonte: Autores.

Os Estados Unidos, em contrapartida, possuem rede de colaboração mais ampla e consistente, com parcerias recorrentes com Canadá, Reino Unido e países da União Europeia. Essa característica reflete tanto a estrutura descentralizada da ciência norte-americana quanto o investimento em projetos multilaterais. A Índia, embora apresente produção significativa, ainda mantém padrões de colaboração restritos, principalmente com países asiáticos.

Entre os países com maior proporção de colaboração internacional destacam-se Arábia Saudita ($MCP = 0,643$), Alemanha (0,583), Austrália (0,571), Malásia (0,565), Itália (0,538) e Reino Unido (0,526). Esses índices revelam que, mesmo com menor número absoluto de publicações, tais países se beneficiam da integração em redes científicas globais, o que tende a aumentar a visibilidade e o impacto das pesquisas.

No caso do Brasil, a taxa de colaboração internacional permanece baixa ($MCP = 0,250$), com parcerias limitadas a Estados Unidos, Canadá e Reino Unido. Essa condição aponta para a necessidade de ampliar a inserção do país em projetos internacionais de grande porte, especialmente considerando sua relevância estratégica para estudos sobre mudanças climáticas em biomas sensíveis como a Amazônia e o Cerrado.


Em 2011, Li e colaboradores apresentaram uma comparação das tendências de publicações sobre mudanças climáticas no mundo (não considerando o objeto de predição) e encontraram uma lista de países muito semelhante à identificada neste estudo, porém em uma ordem diferente quanto ao número de publicações. A mesma relação de países também aparece no trabalho de Haunschild et al. (2016), ao analisar a pesquisa sobre mudanças climáticas sob a ótica da bibliometria, e no estudo de Hussin et al. (2023), ao realizarem uma revisão sistemática das abordagens de *machine learning* em aplicações de captura de carbono. Ambos os estudos evidenciam que esses são, de fato, os países que mais se destacam em termos de

No quadrante dos temas básicos, aparecem tópicos relacionados a modelagem de séries temporais e previsão de temperatura, que possuem alta centralidade, mas ainda baixa densidade, revelando um estágio intermediário de desenvolvimento. Já os temas de nicho incluem abordagens específicas, como otimização de algoritmos ou aplicações em setores energéticos particulares, que possuem relevância local, mas pouco impacto na agenda global. Por fim, os temas emergentes correspondem a tópicos que começam a aparecer com maior frequência, mas cuja consolidação ainda é incerta.

Essa classificação permite concluir que, embora o campo esteja consolidado em torno de algoritmos e variáveis ambientais específicas, falta-lhe ainda maior articulação com temas de natureza socioeconômica ou de governança. A ausência de palavras-chave associadas a indicadores de sustentabilidade, como *ESG* ou *sustainability metrics*, confirma que essa integração ainda não se materializou na literatura científica.

A análise da evolução das palavras-chave ao longo do tempo, Figura 7, reforça a percepção de que o campo passou por três fases distintas. Entre 1995 e 2012, a produção foi incipiente, marcada por trabalhos isolados sobre modelagem de temperatura e chuva. No período de 2013 a 2018, observa-se um aumento gradual, com o surgimento de termos como *fuzzy inference systems*, *classification* e *prediction*, indicando uma diversificação metodológica.

Figura 7. Evolução temática das palavras-chave identificadas na pesquisa



Fonte: Autores.

A partir de 2019, inicia-se a fase de maior crescimento, caracterizada pelo fortalecimento de termos como *deep learning*, *renewable energy*, *carbon emissions* e *biodiversity*. Nesse período, os estudos se tornaram mais aplicados, buscando respostas a problemas concretos relacionados às mudanças climáticas. No entanto, mesmo com essa evolução, a análise mostra que a centralidade temática continua restrita ao eixo ambiental-técnico, sem expandir-se para dimensões integradas de sustentabilidade. Essa constatação é particularmente relevante porque sugere que, embora o campo esteja em franca expansão, ele corre o risco de aprofundar-se em especializações fragmentadas, em vez de avançar para modelos mais sistêmicos. O desafio, portanto, consiste em promover a integração entre previsões ambientais baseadas em IA e indicadores de desempenho socioeconômico e institucional.

Lacunas e Oportunidades

A análise das figuras e dos indicadores confirma três lacunas centrais:

1. Fragmentação temática: a maioria dos estudos concentra-se em variáveis ambientais isoladas (chuva, temperatura, CO₂), sem integrar múltiplos fatores de forma sistêmica;

2. Ausência de modelos integrados: não foram identificados trabalhos que incorporem simultaneamente previsões ambientais, impactos econômicos e efeitos sociais;
3. Desconexão com métricas de sustentabilidade: não há evidências de que modelos preditivos baseados em IA tenham sido integrados às métricas ESG, que continuam retrospectivas e incapazes de antecipar riscos futuros (Al-Abassi et al., 2020).

Essas lacunas representam, por outro lado, oportunidades para novas agendas de pesquisa. A incorporação de modelos preditivos às métricas ESG permitiria transformar indicadores históricos em ferramentas prospectivas, capazes de antecipar riscos ambientais e sociais e de orientar estratégias empresariais e políticas públicas. Esse movimento fortaleceria não apenas o rigor científico da área, mas também sua aplicabilidade prática, colocando a Engenharia de Produção em posição estratégica para propor soluções inovadoras de sustentabilidade.

Discussão dos Resultados

A análise bibliométrica realizada revelou um campo científico em plena expansão, marcado pelo aumento exponencial de publicações na última década, pelo protagonismo de países como China, Estados Unidos e Índia e pela concentração da produção em alguns periódicos especializados. O crescimento no número de artigos publicados evidencia a relevância crescente do tema, especialmente em resposta à intensificação dos efeitos das mudanças climáticas e ao avanço das técnicas de aprendizado de máquina. Esses achados confirmam estudos anteriores que já apontavam a tendência de consolidação do debate climático na literatura científica (Haunschild, Bornmann & Marx, 2016; Grieneisen & Zhang, 2011), mas acrescentam o diferencial da integração progressiva de algoritmos de IA a esse debate.

Do ponto de vista da geopolítica científica, a concentração de publicações em poucos países revela tanto a capacidade tecnológica dessas nações quanto as assimetrias na produção global de conhecimento. A China destaca-se pelo volume absoluto de publicações, embora apresente baixa taxa de colaboração internacional. Os Estados Unidos, em contrapartida, mostram maior integração em redes científicas, com parcerias que aumentam a visibilidade de suas pesquisas. Países europeus como Alemanha, Reino Unido e Itália, embora com menor produção absoluta, apresentam elevados índices de colaboração, o que tende a amplificar o impacto de seus trabalhos. O Brasil aparece de forma ainda tímida, com poucas publicações e baixa taxa de cooperação internacional, o que limita sua contribuição ao debate. Esses resultados corroboram Li, Wang e Ho (2011), que já haviam apontado a concentração da pesquisa climática em determinados polos, mas reforçam a necessidade de ampliar a diversidade geográfica das investigações.

No que diz respeito às tendências temáticas, os mapas e clusters identificados confirmam a centralidade de termos como *machine learning*, *prediction models* e *artificial neural networks*, reconhecidos como temas motores do campo (Cobo et al., 2011; Ferreira, 2022). Essa centralidade demonstra que o núcleo da produção científica está firmemente ancorado em abordagens técnicas voltadas à modelagem de variáveis ambientais. Entretanto, a análise também revelou lacunas significativas: a ausência de conexões robustas entre previsões ambientais e impactos socioeconômicos, bem como a falta de integração dos modelos de IA às métricas de sustentabilidade, como o ESG.

Esse ponto merece destaque. As métricas ESG vêm sendo amplamente utilizadas por empresas e investidores para monitorar desempenho ambiental, social e de governança, mas, como observam Al-Abassi et al. (2020), permanecem essencialmente retrospectivas. A

integração de modelos preditivos baseados em IA a essas métricas permitiria transformar indicadores históricos em instrumentos prospectivos, capazes de antecipar riscos e orientar decisões estratégicas. No entanto, a revisão realizada não identificou estudos que estabeleçam essa conexão de forma sistemática. A lacuna abre espaço para uma agenda inovadora de pesquisa, com potencial para gerar impacto tanto acadêmico quanto prático.

Outro aspecto relevante refere-se à fragmentação da literatura. Embora a análise temática tenha identificado clusters bem definidos em torno de emissões de carbono, energias renováveis e séries temporais, a maior parte dos estudos permanece focada em variáveis ambientais isoladas. Essa fragmentação limita a construção de modelos integrados capazes de capturar a complexidade das mudanças climáticas, que envolvem simultaneamente dimensões ambientais, sociais e econômicas. Gosling e Arnell (2016) já haviam alertado para essa dificuldade ao analisar a relação entre mudanças climáticas e escassez hídrica, destacando a necessidade de abordagens mais holísticas.

As implicações práticas desses resultados são múltiplas. Para pesquisadores, a principal contribuição é a identificação de lacunas claras que podem orientar novos estudos: a necessidade de modelos integrados, a inclusão de variáveis socioeconômicas e a articulação com métricas ESG. Para gestores empresariais, os achados sugerem que os modelos atualmente disponíveis ainda oferecem respostas limitadas para a tomada de decisão estratégica, justamente porque não traduzem riscos ambientais em impactos econômicos e sociais mensuráveis. Para formuladores de políticas públicas, a ausência de modelos integrados implica em dificuldade de elaborar estratégias de mitigação e adaptação que considerem de forma equilibrada sustentabilidade ambiental, desenvolvimento econômico e justiça social.

Do ponto de vista teórico, ao integrar técnicas quantitativas de previsão, ferramentas de análise de dados e práticas de gestão, o campo pode desempenhar papel de ponte entre engenharias, ciência da computação, ciências ambientais, economia e administração. Essa posição privilegiada permite propor soluções que não apenas aprimoram a acurácia dos modelos, mas também ampliam sua aplicabilidade prática em organizações e instituições. A agenda de pesquisa que une IA, previsão ambiental e métricas ESG representa, portanto, uma oportunidade de avançar no desenvolvimento de indicadores mais robustos, capazes de orientar a transição para padrões produtivos sustentáveis.

Em síntese, a discussão dos resultados aponta para um campo em ascensão, mas ainda marcado por assimetrias, fragmentação e ausência de integração com indicadores de sustentabilidade. Superar essas limitações exige ampliar a diversidade geográfica da produção científica, fortalecer redes de colaboração internacional, promover a interdisciplinaridade e, sobretudo, conectar previsões ambientais às métricas ESG. Tal integração tem o potencial de transformar a forma como empresas, governos e sociedades enfrentam os desafios das mudanças climáticas, permitindo decisões mais informadas e preventivas.

CONSIDERAÇÕES FINAIS

A revisão bibliométrica realizada evidenciou a rápida expansão das pesquisas sobre modelos de previsão de impactos ambientais baseados em técnicas de aprendizado de máquina. O crescimento significativo do número de publicações a partir de 2016 confirma a relevância do tema, impulsionada tanto pelo avanço dos algoritmos de IA quanto pela urgência dos problemas associados às mudanças climáticas. China, Estados Unidos e Índia emergem como

os principais polos de produção, embora com diferentes padrões de colaboração internacional, o que reflete a assimetria global na distribuição do conhecimento científico.

Os resultados mostraram ainda que a produção científica está concentrada em poucos periódicos especializados e dispersa entre muitos autores com contribuições isoladas, em conformidade com as Leis de Bradford e Lotka. A análise temática revelou a centralidade de termos como *machine learning*, *artificial neural networks* e *prediction models*, que configuram os temas motores do campo, enquanto tópicos relacionados a energias renováveis e emissões de carbono aparecem como áreas de expansão.

Apesar dos avanços, permanecem lacunas importantes. A literatura apresenta forte fragmentação, com foco em variáveis ambientais específicas, e não oferece modelos integrados que considerem simultaneamente impactos ambientais, sociais e econômicos. Além disso, não foram identificados estudos que conectem de forma sistemática os modelos de previsão baseados em IA às métricas de sustentabilidade, como os indicadores ESG, ainda ancorados em dados retrospectivos.

Conclui-se que o campo apresenta grande potencial para contribuir tanto para o avanço científico quanto para a prática em sustentabilidade e governança. A integração entre previsões ambientais, algoritmos de IA e métricas ESG representa uma fronteira de pesquisa promissora, capaz de transformar indicadores em instrumentos prospectivos e estratégicos. O fortalecimento dessa agenda depende de maior diversidade geográfica da produção, ampliação das redes de colaboração internacional e incorporação explícita das dimensões socioeconômicas nos modelos preditivos.

REFERÊNCIAS

- Adisa, O. M., Masinde, M., Botai, J. O., & Botai, C. M. (2020). Bibliometric analysis of methods and tools for monitoring and forecasting droughts in Africa. *Sustainability*, 12(16), 6516. <https://doi.org/10.3390/su12166516>
- Al-Abassi, A., Karimipour, H., Haddadpajouh, H., Dehghantaha, A., & Parizi, R. M. (2020). Industrial big data analytics: challenges and opportunities. In *Handbook of Big Data Privacy* (37-61). Springer. https://doi.org/10.1007/978-3-030-38557-6_3
- Anderegg, W. R. L., Prall, J. W., Harold, J., & Schneider, S. H. (2010). Expert credibility on climate change. *Proceedings of the National Academy of Sciences*, 107(27), 12107-09. <https://doi.org/10.1073/pnas.1003187107>
- Aria, M. & Cucurullo, C. (2017). Bibliometrix: an R tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959-975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Banihashemi, S., Ding, G., & Wang, J. (2017). Developing a hybrid model of prediction and classification algorithms for building energy consumption. *Energy Procedia*, 110, 371-376. <https://doi.org/10.1016/j.egypro.2017.03.155>
- Belayneh, A., Adamowski, J., & Khalil, B. (2015). Short-term SPI drought forecasting in the Awash River Basin, Ethiopia, using wavelet transforms and machine learning methods. *Sustainable Water Resources Management*, 2, 87-101. <https://doi.org/10.1007/s40899-015-0010-2>
- Bornmann, L. (2016). Bibliometrics in climate change research: A perspective from bibliometric indicators. *PLoS ONE*, 11(7), e0157650. <https://doi.org/10.1371/journal.pone.0157650>
- Brookes, B. C. (1969). Bradford's law and the bibliography of science. *Nature*, 224, 953-6. <https://doi.org/10.1038/224953a0>
- Buarque, S. C. (2003). Metodologia e técnicas de construção de cenários globais e regionais. *IPEA*.
- Cobo, M. J., López-Herrera, A. G., Herrera-Viedma, E., & Herrera, F. (2011). An approach for detecting, quantifying, and visualizing the evolution of a research field: a practical application to the fuzzy sets theory field. *Journal of Informetrics*, 5(1), 146-66. <https://doi.org/10.1016/j.joi.2010.10.002>
- Ferreira, A. L., Marton, F., & Perez, G. (2022). Cybersecurity in services: a bibliometric study. *Journal of Professional Master's Degrees*, 11(2). <https://doi.org/10.51359/2317-0115.2022.256796>
- Gleckler, P. J., Taylor, K. E., & Doutriaux, C. (2008). Performance metrics for climate models. *Journal of Geophysical Research: Atmospheres*, 113, D06104. <https://doi.org/10.1029/2007JD008972>
- Gosling, N. W. & Arnell, N. (2016). A global assessment of the impact of climate change on water scarcity. *Climatic Change*, 134, 371-85. <https://doi.org/10.1007/s10584-013-0853-x>
- Greco, D. (2017). Modelos preditivos: o que são e para que servem. *Análise de Dados*. <https://marketingpordados.com/2017/05/10/>
- Grieneisen, M. L. & Zhang, M. (2011). The current status of climate change research. *Nature Climate Change*, 1(2), 72-3. <https://doi.org/10.1038/nclimate1093>
- Guresen, E., Kayakutlu, G., & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38, 10389-97. <https://doi.org/10.1016/j.eswa.2011.02.068>
- Haunschild, R., Bornmann, L., & Marx, W. (2016). Climate change research in view of bibliometrics. *PLoS ONE*, 11(7), e0157649. <https://doi.org/10.1371/journal.pone.0157649>
- Hughes, L. (2003). Climate change and Australia: trends, projections and impacts. *Austral Ecology*, 28, 423-43. <https://doi.org/10.1046/j.1442-9993.2003.01300.x>
- Hussin, F., Rahim, S. A. N. M., Hatta, N. S. M., Aroua, M. K., & Mazari, S. A. (2023). A systematic review of machine learning approaches in carbon capture applications. *Journal of CO₂ Utilization*, 71. <https://doi.org/10.1016/j.jcou.2023.102474>

IPCC. (2014). Climate change 2014: synthesis report. Summary for Policymakers. *Intergovernmental Panel on climate change*. https://www.ipcc.ch/pdf/assessment-report/ar5/syr/AR5_SYR_FINAL_SPM.pdf

Laniak, G. F. et al. (2013). Integrated environmental modeling: A vision and roadmap for the future. *Environmental Modelling & Software*, 39, 3-23. <https://doi.org/10.1016/j.envsoft.2012.09.006>

Li, J. F., Wang, M. H., & Ho, Y. S. (2011). Trends in global climate change research. *Global and Planetary Change*, 77(1-2), 13-20. <https://doi.org/10.1016/j.gloplacha.2011.02.005>

Li, W. & Zhao, Y. (2015). Bibliometric analysis of global environmental assessment research. *Environmental Impact Assessment Review*, 50, 158-66. <https://doi.org/10.1016/j.eiar.2014.09.012>

Liu, Y., Esan, O. C., Pan, Z., & An, L. (2021). Machine learning for advanced energy materials. *Energy and AI*, 3. <https://doi.org/10.1016/j.egyai.2021.100049>

Miyano, T. & Girosi, F. (1994). Forecasting global temperature variations by neural networks (Technical Report). MIT, Artificial Intelligence Laboratory.

Müller, V. C. & Bostrom, N. (2016). Future progress in artificial intelligence: A survey of expert opinion. In V. C. Müller (Ed.), *Fundamental issues of artificial intelligence* (553-71). Springer. https://doi.org/10.1007/978-3-319-26485-1_33

Okubo, Y. (1997). *Bibliometric indicators and analysis of research systems: Methods and examples*. OECD.

Penland, C. & Matrosova, L. (1998). Prediction of tropical Atlantic sea surface using linear inverse modeling. *Journal of Climate*, 11, 483-96. [https://doi.org/10.1175/1520-0442\(1998\)011<0483:POTASS>2.0.CO;2](https://doi.org/10.1175/1520-0442(1998)011<0483:POTASS>2.0.CO;2)

Roesch, I. & Günther, T. (2018). Visualization of neural network predictions for weather forecasting. *Computer Graphics Forum*, 38, 209-20. <https://doi.org/10.1111/cgf.13403>

Rodrigues, C. & Godoy, A. F. G. (2016). Bibliometric studies on the scientific production of information and communication technologies in libraries. *InCID: Revista de Ciência da Informação e Documentação*, 7(1), 167-80. <https://doi.org/10.11606/issn.2178-2075.v7i1p167-180>

Sembay, M., Luiz Pinto, A., de Macedo, D. J., & Moreiro-González, J. A. (2020). Aplicación de la Ley de Bradford a la investigación sobre open government. *Anales de Documentación*, 23(1). <https://doi.org/10.6018/analesdoc.326771>

Smith, D. M., Cusack, S., Colman, A. W., Folland, C. K., Harris, G. R., & Murphy, J. M. (2007). Improved prediction

of surface temperature for the next decade from a global climate model. *Science*, 317, 796-99.

Su, H. & Lee, P. (2010). Mapping knowledge structure by keyword co-occurrence. *Scientometrics*, 85(1), 65-79. <https://doi.org/10.1007/s11192-010-0252-8>

Tanure, T. M. P., et al. (2020). The impacts of climate change on agricultural production, land use and economy of the Legal Amazon region between 2030 and 2049. *Economia Aplicada*, 21, 73-90. <https://doi.org/10.11606/1980-5330/ea162093>

Thai, H.-T. (2022). Machine learning for structural engineering: A state-of-the-art review. *Structures*, 38, 448-91. <https://doi.org/10.1016/j.istruc.2022.02.003>

Thompson, D. F. & Walker, C. K. (2015). A descriptive and historical review of bibliometrics with applications to the medical sciences. *Pharmacotherapy*, 35(6), 551-59. <https://doi.org/10.1002/phar.1582>

Tol, R. S. (2002). Estimates of the damage costs of climate change. Part 1: Baseline estimates. *Environmental and Resource Economics*, 21, 47-73. <https://doi.org/10.1023/A:1014500930521>

Urbizagastegui, R. (2008). The productivity of authors on Lotka's Law. *Ciência da Informação*, 37(2), 87-102. <https://doi.org/10.1590/S0100-19652008000200008>

Wibisono, A. et al. (2016). Traffic big data prediction and visualization using fast incremental model trees-drift detection. *Knowledge-Based Systems*, 93, 33-46. <https://doi.org/10.1016/j.knosys.2015.11.017>

Wolpert, D. H. (1996). The lack of a priori distinctions between learning algorithms. *Neural Computation*, 8(7), 1341-90. <https://doi.org/10.1162/neco.1996.8.7.1341>

Yan, Y. et al. (2021). Harnessing the power of machine learning for carbon capture, utilization, and storage (CCUS). *Energy & Environmental Science*, 14(12), 6122-57. <https://doi.org/10.1039/D1EE02395K>

Zaihong, Z., Zhiqiang, D., & Rusch, K. A. (2012). Development of predictive models for determining enterococci levels at Gulf Coast beaches. *Water Research*, 46(2), 481-92. <https://doi.org/10.1016/j.watres.2011.11.050>

Zarur, M. A. F. (2000). Modelo para elaboração de cenários do setor energético, utilizando técnicas de data mining (Mestrado). *Universidade Federal do Rio de Janeiro*.

Zhu, D. et al. (1999). A process for mining science & technology documents databases. *Ciência da Informação*, 28(1), 7-20. <https://doi.org/10.1590/S0100-19651999000100002>