

INTELIGÊNCIA ARTIFICIAL NA GOVERNANÇA AMBIENTAL DA AMAZÔNIA LEGAL: FRAMEWORK SOCIOTÉCNICO E SALVAGUARDAS PARA USO RESPONSÁVEL

Onildo Ribeiro de Assis II¹, Ana Isabella Bezerra Lau Ribeiro²

RESUMO:

A incorporação de sistemas de Inteligência Artificial à governança ambiental da Amazônia Legal tem avançado em ritmo superior à produção de marcos conceituais que orientem seu uso responsável, criando uma lacuna entre capacidade técnica e *accountability* institucional que este artigo se propõe a preencher. O objetivo foi propor um *framework* sociotécnico em camadas e um conjunto de salvaguardas operacionais para o uso da IA nesse domínio, organizando as aplicações existentes em uma tipologia analítica e mapeando os riscos associados a cada eixo de uso. Para tanto, conduziu-se uma revisão integrativa da literatura nas bases Scopus, Web of Science, SciELO e Google Scholar, com recorte temporal entre 2015 e 2026 e síntese temática organizada em quatro eixos conceituais: Dados, Modelos, Decisão e Governança & *Accountability*. Os resultados compreendem um *framework* estruturado nessas quatro camadas interdependentes, um quadro síntese correlacionando aplicações, riscos, salvaguardas e indicadores de monitoramento, e uma cadeia de evidências representando o fluxo entre detecção automatizada e ato administrativo. Conclui-se que o potencial da IA na governança ambiental amazônica é real, mas estritamente condicionado à existência de trilhas de auditoria, mecanismos de contestação e responsabilização institucional estruturada – sem os quais a adoção dessas tecnologias tende a ampliar a opacidade dos processos decisórios sem produzir ganhos efetivos de proteção ambiental.

Palavras-chave: governança de dados; tomada de decisão; proteção ambiental; auditoria algorítmica; responsabilização institucional.

ARTIFICIAL INTELLIGENCE IN ENVIRONMENTAL GOVERNANCE IN THE LEGAL AMAZON: A SOCIOTECHNICAL FRAMEWORK AND SAFEGUARDS FOR RESPONSIBLE USE

ABSTRACT:

The incorporation of artificial intelligence systems into the environmental governance of the Brazilian Legal Amazon has advanced at a pace that outstrips the production of conceptual frameworks capable of guiding their responsible use, creating a gap between technical capability and institutional accountability that this article seeks to address. The objective was to propose a layered sociotechnical framework and a set of operational safeguards for the use of AI in this domain, organizing existing applications into an analytical typology and mapping the risks associated with each area of use. To this end, an integrative literature review was conducted using Scopus, Web of Science, SciELO, and Google Scholar databases, covering the period from 2015 to 2026, with thematic synthesis organized around four conceptual axes: Data, Models, Decision, and Governance & Accountability. The results comprise a framework structured around these four interdependent layers, a summary matrix correlating applications, risks, safeguards, and monitoring indicators, and an evidence chain representing the flow from automated detection to the corresponding administrative act. It is concluded that the potential of AI in Amazonian environmental governance is real, but strictly contingent on the existence of audit trails, contestation mechanisms, and structured institutional accountability — without

¹Doutorando em Ciências Sociais e Empresariais na Universidad de Ciencias Empresariales y Sociales (UCES) em Buenos Aires, Argentina; onildo.ribeiro@gmail.com, <https://orcid.org/0000-0002-8884-1378>.² Doutoranda em Ciências Jurídicas na Universidad del Museo Social Argentino (UMSA) em Buenos Aires, Argentina. anaisabellalau@gmail.com; <https://orcid.org/0000-0002-5441-4183>.

which the adoption of these technologies tends to increase the opacity of decision-making processes without producing effective gains in environmental protection.

Keywords: algorithmic auditing; data governance; decision-making; environmental protection; institutional accountability.

INTRODUÇÃO

A Amazônia Legal perdeu, entre agosto de 2021 e julho de 2022, aproximadamente 11.568 km² de cobertura florestal, área superior à do estado de Sergipe, segundo dados do PRODES/INPE (2022). O número é expressivo, mas não é o único indicador relevante. Por trás dele estão dinâmicas de desmatamento, garimpo ilegal, grilagem de terras e queimadas que operam em escala e velocidade que desafiam os instrumentos tradicionais de monitoramento e fiscalização. A pergunta que emerge desse cenário não é nova, mas permanece sem resposta satisfatória: como governar um território dessa dimensão, com essa complexidade, com os recursos institucionais disponíveis?

É nesse intervalo, entre a escala do problema e a capacidade de resposta das instituições, que a Inteligência Artificial tem sido apresentada, com frequência crescente, como uma solução. Sistemas de detecção automática de desmatamento, modelos preditivos de risco de incêndio, algoritmos de priorização de fiscalização, ferramentas de análise documental: o repertório de aplicações possíveis é extenso e, em muitos casos, tecnicamente promissor. O DETER, operado pelo INPE, já demonstrou que alertas gerados por processamento automatizado de imagens de satélite podem orientar operações de fiscalização com ganhos reais de agilidade e cobertura (Diniz et al., 2015). Outros sistemas, em desenvolvimento ou já em uso por órgãos como o Ibama e a Polícia Federal, apontam na mesma direção.

Mas a adoção crescente dessas ferramentas não tem sido acompanhada, na mesma proporção, por uma reflexão estruturada sobre suas condições de uso responsável. A literatura tende a concentrar atenção no desempenho técnico dos sistemas (acurácia, precisão, velocidade de processamento) e a tratar as questões institucionais e éticas como problemas secundários, a serem resolvidos após a tecnologia estar em funcionamento. Essa sequência é problemática. Sistemas de IA implantados sem governança adequada, sem mecanismos de auditoria e sem salvaguardas para os casos de erro podem produzir danos que se distribuem de forma assimétrica, recaindo, com maior frequência, sobre os atores com menor capacidade de contestação.

A lacuna identificada não é apenas empírica. É também conceitual. Na literatura revisada, observa-se que os componentes centrais do uso responsável de

sistemas de IA, os dados que alimentam os sistemas, os modelos que processam esses dados, as decisões resultantes desse processamento e os mecanismos de responsabilização que deveriam enquadrar todo esse fluxo são frequentemente tratados de forma separada, por campos disciplinares distintos. Diretrizes e estudos sobre ética e governança de IA reconhecem a interdependência entre qualidade dos dados, transparência, supervisão humana, prestação de contas e mecanismos de reparação, mas esses elementos ainda demandam tradução para domínios institucionais específicos, como a governança ambiental amazônica (Floridi et al., 2018; EU High-Level Expert Group on AI, 2019; Brasil, 2021). O que raramente se encontra é uma abordagem que os articule como partes de um único arranjo sociotécnico, no qual a falha em qualquer um dos elos compromete a integridade do conjunto. É essa articulação que o presente trabalho se propõe a construir.

O recorte pela Amazônia Legal não é apenas temático. É também metodológico. As particularidades desse território como a escala, a heterogeneidade institucional, a precariedade de infraestrutura em vastas porções do espaço, a intensidade dos conflitos fundiários e a diversidade dos atores envolvidos tornam esse contexto um caso especialmente exigente para qualquer proposta de uso de IA em governança ambiental (IBGE, 2022; Sparovek et al., 2019). Se o *framework* proposto for capaz de dar conta das especificidades amazônicas, é provável que ofereça contribuições úteis também para outros contextos de governança ambiental em territórios de grande escala e alta complexidade institucional.

O objetivo geral é propor um *framework* sociotécnico e um conjunto de salvaguardas para o uso responsável da Inteligência Artificial na governança ambiental da Amazônia Legal. Para tanto, a investigação perseguiu quatro objetivos específicos: organizar as aplicações potenciais da IA nesse domínio em uma tipologia analiticamente útil; mapear os riscos sociotécnicos associados a essas aplicações; traduzir as salvaguardas identificadas na literatura em termos operacionalmente aplicáveis; e delinear uma agenda de pesquisa que possa orientar investigações futuras, particularmente por parte de pesquisadores em formação interessados nessa intersecção entre tecnologia, instituições e sustentabilidade.

MATERIAL E MÉTODOS

O delineamento metodológico adotado consiste em uma revisão integrativa da literatura, modalidade de síntese do conhecimento que se distingue da revisão narrativa convencional pela exigência de etapas explícitas e replicáveis: formulação de questão norteadora, busca sistemática em bases indexadas, aplicação de critérios de inclusão e exclusão previamente definidos, extração estruturada de dados e análise temática dos achados (Souza, Silva e Carvalho, 2010). A distinção não é terminológica. Ela determina o grau de controle metodológico sobre o processo de síntese e, consequentemente, a solidez das inferências que dele decorrem.

A questão que orientou a investigação foi formulada nos seguintes termos: de que modo o uso da Inteligência Artificial na governança ambiental da Amazônia Legal pode ser estruturado de maneira a ser simultaneamente efetivo do ponto de vista institucional e responsável do ponto de vista social? A tensão embutida nessa formulação foi preservada deliberadamente ao longo de todo o estudo. Efetividade operacional e responsabilidade sociotécnica não são dimensões necessariamente convergentes, e tratar essa tensão como já resolvida implicaria simplificar um problema que a literatura reconhece, ainda que de forma fragmentada, como genuinamente complexo.

A busca bibliográfica foi conduzida nas bases *Scopus*, *Web of Science*, *SciELO* e *Google Scholar*, com descritores em português e inglês combinando os termos "inteligência artificial", "machine learning", "governança ambiental", "sensoriamento remoto", "desmatamento", "accountability", "governança de dados" e "Amazônia Legal", articulados por operadores booleanos AND e OR conforme a especificidade de cada combinação. O recorte temporal abrangeu o período de 2015 a 2026, delimitação justificada pelo fato de ser a partir de meados daquela década que sistemas de aprendizado de máquina passaram a ser incorporados de modo mais sistemático ao monitoramento ambiental em larga escala, inclusive no Brasil (Körting et al., 2021).

Foram considerados elegíveis artigos científicos revisados por pares, capítulos de livros, relatórios técnicos de organizações governamentais e não governamentais e documentos normativos com relação direta ou suficientemente próxima à aplicação de Inteligência Artificial em processos de governança

ambiental. Também foram considerados apenas estudos publicados entre 2015 e 2026, em português ou inglês, com texto completo disponível e fundamentação metodológica explícita. Foram excluídos estudos restritos à avaliação do desempenho técnico de algoritmos sem interface identificável com a tomada de decisão institucional ou com as implicações sociais dessas tecnologias; resumos de eventos sem texto completo disponível; textos de opinião sem fundamentação metodológica explícita; e trabalhos cujo objeto empírico não apresentasse relação direta ou suficientemente próxima com a aplicação de Inteligência Artificial em contextos de governança ambiental. Registros duplicados foram eliminados antes da leitura integral.

A seleção dos estudos foi realizada em duas etapas. Na primeira, procedeu-se à triagem por título e resumo, com a exclusão de registros duplicados, trabalhos publicados fora do recorte temporal, produções em idiomas diferentes do português e do inglês, resumos de eventos sem texto completo disponível e textos de opinião sem fundamentação metodológica explícita. Na segunda etapa, os textos pré-selecionados foram submetidos à leitura integral, sendo excluídos aqueles que não atendiam aos critérios de elegibilidade, especialmente os estudos centrados exclusivamente no desempenho técnico de algoritmos e os trabalhos cujo objeto empírico não apresentava relação suficientemente próxima com a aplicação de Inteligência Artificial em processos de governança ambiental. A busca inicial recuperou 412 registros nas quatro bases consultadas. Após a remoção de duplicatas e a triagem por título e resumo, 318 registros foram excluídos por não atenderem aos critérios estabelecidos. Os 94 textos remanescentes foram submetidos à leitura integral, da qual resultou a exclusão de outros 61 trabalhos, majoritariamente estudos circunscritos à avaliação técnica de algoritmos sem interface com processos decisórios institucionais. Ao final do processo, 33 estudos foram incluídos na síntese temática, aos quais se somaram documentos normativos e relatórios institucionais diretamente relevantes para os objetivos da investigação.

A síntese dos estudos foi conduzida por meio de análise temática. Os achados foram organizados em quatro eixos conceituais: Dados, Modelos, Decisão e Governança e Responsabilização. A partir dessa categorização, foram sistematizadas as aplicações de Inteligência Artificial, os riscos sociotécnicos e as salvaguardas operacionais

correspondentes. Por não envolver seres humanos como sujeitos de pesquisa, o estudo dispensou submissão ao Comitê de Ética.

RESULTADOS E DISCUSSÃO

Achados gerais da revisão

Um padrão recorrente emergiu da análise dos estudos selecionados: a literatura examinada é significativamente mais detalhada na descrição das capacidades técnicas dos sistemas do que na abordagem de suas implicações institucionais e dos riscos associados ao uso em contextos operacionais reais. Essa predominância do enfoque técnico também é observável em estudos sobre monitoramento ambiental e priorização da fiscalização, que enfatizam o desempenho dos dados, dos modelos e das estratégias de detecção, ao passo que questões relativas à governança, à supervisão humana, à transparência e à responsabilização institucional recebem tratamento menos sistemático (Körting et al., 2021; Reis et al., 2022; Floridi et al., 2018). Essa assimetria não é um detalhe periférico: ela reflete uma lacuna relevante no estado atual do campo e fornece parte da justificativa empírica para a proposta deste trabalho.

A análise temática permitiu identificar convergências e divergências relevantes entre os estudos revisados. No que diz respeito às convergências, observou-se amplo consenso sobre a eficácia técnica dos sistemas de sensoriamento remoto para a detecção de desmatamento, a necessidade de supervisão humana em decisões de alto impacto e a centralidade da qualidade dos dados como condição de base para o desempenho dos modelos. As divergências concentram-se principalmente na relação entre interpretabilidade e desempenho preditivo. Parte da literatura privilegia arquiteturas de maior acurácia bruta, enquanto outra vertente, representada especialmente por Rudin (2019), defende a preferência por modelos explicáveis em contextos de alto risco institucional. Outra divergência relevante diz respeito ao papel da transparência. Enquanto documentos normativos internacionais, como as diretrizes europeias para uma IA confiável (EU High-Level Expert Group on AI, 2019), tendem a tratá-la como princípio amplo, a literatura aplicada a contextos de fiscalização ambiental reconhece que a divulgação irrestrita de informações operacionais pode comprometer a eficácia das ações de fiscalização. A lacuna mais

consistente identificada ao longo da revisão é a ausência de estruturas analíticas que integrem, em um único arranjo, as dimensões técnicas, institucionais e normativas do uso de IA na governança ambiental. Na literatura existente, essas dimensões são tratadas de forma compartimentada e insuficientemente articulada.

Onde a IA entra na governança ambiental

A literatura revisada permite identificar, com razoável clareza, cinco grandes eixos de aplicação da Inteligência Artificial na governança ambiental: monitoramento e detecção de mudanças na cobertura vegetal; previsão de risco; priorização de esforços de fiscalização; triagem e análise documental; e integração e verificação de consistência entre bases de dados. Não se trata de categorias estanques. Na prática institucional, esses usos podem se sobrepor e depender mutuamente para produzir efeitos operacionais, pois alertas de sensoriamento remoto, dados fundiários, informações administrativas e capacidades de fiscalização tendem a compor uma mesma cadeia de decisão (Diniz et al., 2015; Körting et al., 2021; Reis et al., 2022). A separação analítica adotada neste estudo tem a finalidade de tornar mais legível o mapa de possibilidades e de riscos associado à adoção dessas tecnologias pelas instituições responsáveis pela gestão da Amazônia Legal.

O eixo mais consolidado, tanto em termos de produção científica quanto de implementação efetiva, é o do monitoramento e da detecção de mudanças na cobertura vegetal. Sistemas de sensoriamento remoto, classificação automatizada e análise de séries temporais de imagens de satélite têm sido empregados para identificar supressão de vegetação, degradação florestal e alterações no uso da terra em escala regional e nacional (Diniz et al., 2015; Körting et al., 2021). O PRODES e o DETER, operados pelo Instituto Nacional de Pesquisas Espaciais (INPE), constituem referências centrais nesse campo: o PRODES fornece estimativas anuais de desmatamento por corte raso na Amazônia desde 1988, enquanto o DETER emite alertas de desmatamento e degradação em frequência próxima ao tempo real, utilizados para subsidiar ações de fiscalização (INPE, 2022; Diniz et al., 2015). A capacidade de processar grandes volumes de dados de sensoriamento remoto em intervalos progressivamente menores representa um avanço relevante para a produção de alertas e o acompanhamento territorial (Körting et al., 2021).

Contudo, a geração de alertas não garante, por si só, proteção ambiental: sua efetividade depende da capacidade institucional de verificar os eventos identificados, priorizar ações e mobilizar recursos de fiscalização e resposta (Reis et al., 2022).

Distinto do monitoramento, embora frequentemente confundido com ele, é o uso de IA para fins preditivos. Modelos de previsão de risco de desmatamento e de ocorrência de incêndios florestais operam sobre uma lógica diferente: em vez de identificar o que já aconteceu, buscam antecipar onde e quando determinados eventos têm maior probabilidade de ocorrer, combinando variáveis climáticas, históricas, fundiárias e socioeconômicas. A modelagem espacial aplicada à Amazônia demonstrou que fatores como a expansão de fronteiras agrícolas, a proximidade de infraestrutura viária e as dinâmicas de uso da terra podem contribuir para a projeção de perdas florestais futuras (Soares-Filho et al., 2006). Abordagens mais recentes têm ampliado essa capacidade por meio da análise de séries temporais de observação da Terra, com dados multitemporais de sensoriamento remoto empregados para acompanhar processos de degradação florestal e mudanças na cobertura vegetal em grande escala (Körting et al., 2021). Quando articuladas a informações fundiárias, territoriais e socioeconômicas, essas análises também podem subsidiar a priorização preventiva de áreas para monitoramento e fiscalização (Reis et al., 2022). Ainda assim, a tradução dessas previsões em decisões de alocação preventiva de recursos permanece, na maioria dos casos, um passo que as instituições não realizam de forma sistemática.

A priorização e alocação de esforços de fiscalização constitui um terceiro eixo, talvez o mais diretamente vinculado à capacidade operacional do Estado. A lógica aqui é relativamente direta: dado que os recursos humanos, logísticos e financeiros disponíveis para fiscalização ambiental são invariavelmente insuficientes diante da escala do território a ser monitorado, algoritmos de priorização podem contribuir para direcionar equipes aos locais onde a probabilidade de ocorrência de ilícitos é mais elevada ou onde o impacto potencial da intervenção é maior. Reis et al. (2022) exploram justamente essa possibilidade no contexto do controle do desmatamento, sugerindo que a combinação de alertas de sensoriamento remoto com dados fundiários e socioeconômicos pode aumentar significativamente a eficiência das operações de

fiscalização. Vale a ressalva, porém: eficiência na alocação não resolve o problema da capacidade de resposta. Se o gargalo é a falta de efetivo ou de infraestrutura logística, nenhum algoritmo de priorização, por mais sofisticado que seja, vai contorná-lo.

Um quarto eixo de aplicação, menos explorado na literatura brasileira, mas crescente em contextos internacionais, diz respeito à triagem e à análise de documentos. Sistemas de processamento de linguagem natural têm sido utilizados para automatizar a leitura e a categorização de grandes volumes de processos administrativos, relatórios de vistoria, denúncias e registros de licenciamento, identificando inconsistências, padrões suspeitos e informações relevantes que dificilmente seriam localizadas por análise humana em tempo hábil (Brown et al., 2020). No contexto da governança ambiental brasileira, onde o volume de processos administrativos é notoriamente elevado e a capacidade de análise das equipes técnicas é frequentemente insuficiente, as possibilidades abertas por essa abordagem são consideráveis. Contudo, a literatura ainda não permite afirmar, com precisão, o grau de confiabilidade desses sistemas quando aplicados a documentos jurídicos e técnicos em português, marcados por ambiguidade, variação terminológica e alta especificidade contextual. No Brasil, os estudos de processamento de linguagem natural jurídico ainda se concentram, em grande medida, em tarefas delimitadas, como o reconhecimento de entidades nomeadas em documentos judiciais, o que evidencia a necessidade de validações específicas antes de empregar esses sistemas em atividades de classificação documental e apoio à decisão administrativa (de Araujo et al., 2020).

Por fim, há o eixo da integração e da verificação de consistência entre bases de dados. A governança ambiental na Amazônia Legal mobiliza múltiplos cadastros, registros e sistemas de informação, entre eles o Cadastro Ambiental Rural (CAR), o Sistema de Gestão Fundiária (SIGEF), o Cadastro Técnico Federal (CTF) e o Sistema Nacional de Controle da Origem dos Produtos Florestais (Sinaflor), cuja utilização conjunta requer procedimentos de compatibilização, rastreabilidade e controle de qualidade. No caso do CAR, estudos já documentaram problemas de inconsistência declaratória, sobreposições territoriais e limitações para sua utilização isolada como base de verificação da regularidade ambiental e fundiária (Azevedo et al.,

2017). Essas limitações evidenciam que a integração de dados não é apenas uma questão técnica, mas também uma condição institucional para a confiabilidade das análises produzidas.

Ferramentas de inteligência artificial e técnicas de análise de dados podem apoiar o cruzamento dessas bases, a identificação de sobreposições territoriais, a detecção de registros potencialmente duplicados ou inconsistentes e a sinalização de casos que demandam verificação humana. Entretanto, a qualidade dos resultados depende da procedência, da atualização, da padronização e da documentação dos dados integrados (DAMA International, 2017; Azevedo et al., 2017). Trata-se, provavelmente, de um eixo com menor visibilidade acadêmica, mas com impacto institucional potencialmente elevado, dado que a qualidade e a rastreabilidade das informações fundiárias e ambientais constituem condições de base para que os demais usos de IA produzam resultados confiáveis.

Riscos sociotécnicos

A discussão sobre Inteligência Artificial (IA) aplicada à governança ambiental não pode se limitar ao desempenho técnico dos sistemas. A literatura sobre IA responsável destaca que critérios como justiça, explicabilidade, supervisão humana, segurança e responsabilização devem ser considerados desde a definição dos dados até o uso institucional dos resultados produzidos pelos modelos (Floridi et al., 2018; EU High-Level Expert Group on AI, 2019). Nessa perspectiva, os riscos sociotécnicos não constituem limitações periféricas, mas condições que influenciam diretamente a legitimidade, a confiabilidade e a utilidade pública das ferramentas empregadas.

O primeiro risco a ser examinado é o do viés de dados. Modelos de aprendizado de máquina aprendem a partir de dados históricos e podem reproduzir ou, em determinadas condições, ampliar padrões de desigualdade, omissões e distorções presentes nas bases utilizadas em seu treinamento (Barocas, Hardt e Narayanan, 2023). No contexto do monitoramento ambiental, esse problema pode ocorrer quando determinados territórios concentram registros, vistorias e dados de validação, enquanto áreas remotas ou menos monitoradas dispõem de menor densidade de informação. Nesses casos, o sistema pode apresentar desempenho desigual entre regiões, não necessariamente por uma falha

algorítmica isolada, mas pela qualidade, distribuição e cobertura territorial dos dados disponíveis (Barocas, Hardt e Narayanan, 2023). Na Amazônia Legal, marcada por grande heterogeneidade territorial e por limitações de cobertura institucional, esse risco exige verificação empírica contínua e avaliação específica do desempenho dos modelos em diferentes contextos territoriais.

Falsos positivos e falsos negativos também merecem atenção separada, não apenas porque constituem erros de naturezas distintas, mas porque seus custos podem recair de forma assimétrica sobre atores e territórios. Um falso positivo em alertas de desmatamento pode mobilizar recursos de fiscalização para uma área em que não se confirme a ocorrência de ilícito. Um falso negativo, por sua vez, pode retardar a identificação de dano ambiental e a eventual resposta institucional. Em conjuntos de dados desbalanceados, métricas agregadas, como a acurácia global, podem ocultar desempenhos insuficientes para a classe de eventos mais relevante; por isso, a avaliação deve considerar métricas como precisão, revocação e curvas precisão-revocação, além da distribuição territorial dos erros (Saito e Rehmsmeier, 2015). A definição das métricas de avaliação possui, portanto, consequências operacionais e distributivas, e não apenas técnicas.

A opacidade dos modelos constitui outro ponto de tensão. Sistemas baseados em redes neurais profundas, frequentemente empregados em tarefas de classificação de imagens de satélite, podem dificultar a compreensão dos critérios que conduziram determinada classificação. Esse problema, frequentemente denominado *black box*, tem consequências relevantes para a governança, pois decisões ou recomendações que não podem ser suficientemente explicadas tendem a ser mais difíceis de auditar, contestar e corrigir (Rudin, 2019). No âmbito do direito administrativo brasileiro, o princípio da motivação dos atos administrativos exige a indicação dos fundamentos de fato e de direito que sustentam a decisão (Brasil, 1999). Assim, quando sistemas de IA subsidiarem procedimentos com efeitos sobre direitos, territórios ou atividades econômicas, a instituição responsável deverá assegurar condições de rastreabilidade, justificativa e revisão humana qualificada.

A privacidade e a segurança da informação constituem risco adicional. Sistemas que integram dados georreferenciados, registros fundiários, denúncias e informações socioeconômicas podem

ampliar a capacidade analítica do Estado, mas também aumentar os riscos associados ao tratamento, ao compartilhamento e à exposição indevida de dados. Esse cuidado é particularmente relevante quando as informações permitirem identificar pessoas, famílias, comunidades ou padrões territoriais sensíveis. A Lei Geral de Proteção de Dados Pessoais estabelece princípios como finalidade, necessidade, segurança, prevenção e responsabilização, aplicáveis também ao tratamento de dados pelo poder público (Brasil, 2018). Dessa forma, a integração de bases ambientais e fundiárias deve ser acompanhada por controles de acesso, definição de responsabilidades, registro de operações e avaliação dos riscos relacionados à divulgação de informações.

Por fim, a fragilidade institucional pode limitar estruturalmente a utilidade da IA. Um sistema capaz de gerar alertas precisos e tempestivos não produz, por si só, proteção ambiental: seus resultados precisam ser verificados, priorizados e convertidos em ações por instituições que disponham de competência, recursos humanos, infraestrutura logística e capacidade decisória. Estudos sobre monitoramento e fiscalização na Amazônia mostram que a priorização baseada em dados pode contribuir para tornar a atuação estatal mais eficiente, mas não substitui as condições institucionais necessárias para responder aos eventos identificados (Reis et al., 2022). Além disso, análises sobre a política ambiental brasileira evidenciam que o enfraquecimento de estruturas normativas e institucionais compromete a capacidade de proteção ambiental (Abessa, Famá e Buruaem, 2019). Investir em sistemas de IA sem fortalecer simultaneamente a capacidade de resposta institucional pode, portanto, reduzir a efetividade esperada da tecnologia.

Tomados em conjunto, esses riscos não apontam para a inviabilidade do uso da IA na governança ambiental. Indicam, contudo, que sua adoção deve ser acompanhada por salvaguardas relacionadas à qualidade e à rastreabilidade dos dados, à avaliação contínua dos modelos, à supervisão humana proporcional ao risco, à explicabilidade, à auditabilidade, à contestabilidade e à proteção das informações tratadas (Floridi et al., 2018; EU High-Level Expert Group on AI, 2019; Brasil, 2018). A seção seguinte sistematiza essas salvaguardas em termos aplicáveis à governança ambiental da Amazônia Legal.

Salvaguardas

A identificação de riscos deve ser acompanhada da definição de controles institucionais e técnicos capazes de preveni-los, mitigá-los ou permitir sua correção. No campo da Inteligência Artificial (IA), isso envolve considerar a governança ao longo de todo o ciclo de vida do sistema: definição de finalidades, seleção e tratamento de dados, desenvolvimento e validação dos modelos, uso de seus resultados, monitoramento contínuo e prestação de contas. O *Artificial Intelligence Risk Management Framework* do National Institute of Standards and Technology (NIST) organiza esse processo em funções de governar, mapear, medir e gerenciar riscos, enquanto as diretrizes europeias para uma IA confiável destacam requisitos como supervisão humana, transparência, robustez técnica, privacidade e responsabilização (National Institute of Standards and Technology, 2023; EU High-Level Expert Group on AI, 2019).

A governança de dados é o ponto de partida. Sem dados de qualidade, procedência conhecida, metadados documentados e regras claras de acesso, atualização e uso, os resultados produzidos por sistemas de IA terão confiabilidade limitada, independentemente da sofisticação do algoritmo empregado. Práticas como controle de versionamento, documentação das fontes, registro dos critérios de coleta, definição de responsáveis pelos dados e avaliação periódica de sua qualidade são componentes básicos da gestão de dados (Dama International, 2017; National Institute of Standards and Technology, 2023). No contexto amazônico, essa salvaguarda é particularmente relevante porque o Cadastro Ambiental Rural (CAR), embora seja uma fonte importante de informação territorial, apresenta limitações decorrentes de sua natureza autodeclaratória e de problemas relacionados à validação e à sobreposição de registros (Azevedo et al., 2017). Assim, bases fundiárias e ambientais não devem ser incorporadas aos modelos sem procedimentos de verificação, rastreabilidade e atualização.

A proteção de dados pessoais e de informações sensíveis também integra a governança de dados. Sistemas voltados ao monitoramento ambiental podem reunir dados geoespaciais, registros administrativos, informações fundiárias e denúncias, cuja combinação pode elevar os riscos de exposição indevida de pessoas, comunidades e territórios. A Lei Geral de Proteção de Dados Pessoais estabelece

princípios como finalidade, necessidade, segurança, prevenção e responsabilização para o tratamento de dados pessoais, inclusive pelo poder público (Brasil, 2018). Portanto, a integração de bases deve observar controles de acesso por perfil de usuário, registro de operações, medidas de segurança e limitação do compartilhamento aos dados estritamente necessários para a finalidade institucional declarada.

Um segundo conjunto de salvaguardas diz respeito à validação contínua dos modelos. Sistemas de aprendizado de máquina não permanecem automaticamente confiáveis após sua implantação. Mudanças nas características dos dados, nas condições ambientais, nos sensores utilizados, nas práticas de ocupação territorial ou nos padrões de ocorrência dos eventos monitorados podem reduzir o desempenho do modelo ao longo do tempo. O NIST recomenda que organizações monitorem os sistemas em operação, avaliem seus resultados em contextos reais de uso e estabeleçam procedimentos para identificar, documentar e tratar falhas ou degradações de desempenho (National Institute of Standards and Technology, 2023).

No monitoramento ambiental, essa orientação implica comparar periodicamente os resultados automatizados com dados de campo, imagens de maior resolução ou outras fontes independentes de validação. Também requer avaliar o desempenho por região, período e tipo de evento, evitando que uma métrica global aparentemente satisfatória oculte resultados insuficientes em áreas específicas. Devem ser acompanhados, entre outros indicadores, os percentuais de falsos positivos e falsos negativos, a precisão, a cobertura territorial e o tempo entre a geração de um alerta e sua validação. A revisão periódica dos dados de treinamento e dos parâmetros de decisão é necessária para que o sistema permaneça compatível com as condições efetivas em que será utilizado (National Institute of Standards and Technology, 2023).

A supervisão humana proporcional ao risco constitui outra salvaguarda central. As diretrizes europeias para uma IA confiável estabelecem que os sistemas devem ser concebidos de forma a permitir intervenção e supervisão humanas adequadas ao contexto e ao impacto potencial de suas decisões (EU High-Level Expert Group on AI, 2019). Na governança ambiental, essa exigência recomenda distinguir entre sistemas que informam decisões e sistemas que produzem efeitos administrativos ou jurídicos. Alertas de desmatamento, classificações

preliminares de imagens e priorizações de áreas podem apoiar o trabalho de equipes técnicas; entretanto, não devem substituir a análise humana quando a decisão puder resultar em autuação, embargo, restrição de direitos ou outro efeito direto sobre pessoas, comunidades ou organizações.

A supervisão humana não deve ser apenas formal. O agente responsável pela revisão precisa dispor de informações suficientes para compreender o resultado produzido pelo sistema, verificar sua consistência e registrar os fundamentos da decisão adotada. A revisão humana qualificada é especialmente necessária quando os dados são incompletos, quando o modelo apresenta baixa confiança, quando há divergência entre fontes de informação ou quando o caso envolve territórios indígenas, comunidades tradicionais, conflitos fundiários ou outros contextos de elevada sensibilidade social e territorial (EU High-Level Expert Group on AI, 2019; Brasil, 2018).

As trilhas de auditoria merecem atenção específica. Para que um sistema possa ser examinado posteriormente, é necessário registrar de forma estruturada os dados utilizados, a versão do modelo aplicada, os parâmetros relevantes, a data de processamento, o resultado gerado, a intervenção humana realizada e o ato administrativo eventualmente praticado. Essa documentação permite identificar falhas, reproduzir análises, corrigir erros e atribuir responsabilidades institucionais. A rastreabilidade e a documentação dos processos são elementos importantes para a governança de riscos em IA e para a prestação de contas no uso de sistemas automatizados (National Institute of Standards and Technology, 2023; EU High-Level Expert Group on AI, 2019).

No âmbito da Administração Pública federal, a necessidade de motivação dos atos administrativos reforça essa exigência. A Lei nº 9.784/1999 prevê que os atos administrativos devem indicar os fatos e os fundamentos jurídicos que justificam sua adoção, especialmente quando afetarem direitos ou interesses dos administrados (Brasil, 1999). Assim, a saída de um sistema de IA pode compor a instrução de um processo, mas não dispensa a explicitação dos elementos que sustentam a decisão administrativa.

A contestabilidade é uma consequência prática da auditabilidade e da transparência. Pessoas ou coletividades afetadas por decisões que utilizem sistemas automatizados devem ter meios de compreender a participação da IA no processo,

apresentar informações adicionais, questionar erros e solicitar revisão. A LGPD assegura ao titular o direito de solicitar revisão de decisões tomadas unicamente com base em tratamento automatizado de dados pessoais que afetem seus interesses, nos casos abrangidos pela norma (Brasil, 2018). De modo complementar, a Lei nº 9.784/1999 prevê mecanismos de recurso e revisão no processo administrativo federal (Brasil, 1999).

Em aplicações ambientais, a contestação exige que as instituições disponham de canais acessíveis e procedimentos claros para receber questionamentos sobre alertas, classificações, cruzamentos de bases ou decisões apoiadas por IA. Isso não significa que todo resultado automatizado deva ser automaticamente invalidado mediante contestação; significa, porém, que a instituição deve ter condições de revisar o caso, examinar as evidências disponíveis e justificar a manutenção, a correção ou o cancelamento da medida adotada.

Por fim, a transparência deve ser proporcional aos riscos envolvidos. A divulgação pública da existência do sistema, de sua finalidade, das categorias de dados utilizadas, dos critérios gerais de funcionamento, dos responsáveis institucionais e dos mecanismos de supervisão fortalece a legitimidade e a *accountability*. Ao mesmo tempo, a transparência não pode resultar na exposição de dados pessoais, informações protegidas por sigilo legal ou detalhes operacionais cuja divulgação comprometa a segurança dos envolvidos ou a efetividade das ações de fiscalização. A Lei de Acesso à Informação estabelece a publicidade como regra na Administração Pública, mas também prevê hipóteses de restrição legalmente justificadas; a LGPD, por sua vez, impõe proteção específica aos dados pessoais (Brasil, 2011; Brasil, 2018).

Tomadas em conjunto, essas salvaguardas não constituem um *checklist* aplicável de forma automática e idêntica a todos os sistemas. Elas devem ser adaptadas à finalidade da ferramenta, aos dados empregados, ao grau de autonomia do modelo, ao impacto potencial das decisões e às condições institucionais do órgão responsável. O *framework* proposto na seção seguinte organiza essas exigências nas camadas de Dados, Modelos, Decisão e Governança & *Accountability*, buscando traduzi-las em parâmetros aplicáveis à governança ambiental da Amazônia Legal.

Proposta do framework

A organização temática dos estudos em quatro eixos — Dados, Modelos, Decisão e Governança e Responsabilização — fundamentou a estrutura sociotécnica em camadas proposta neste artigo e o conjunto de salvaguardas operacionais correspondente. Essas salvaguardas foram extraídas da literatura e traduzidas para termos aplicáveis a contextos institucionais concretos, sendo posteriormente articuladas a indicadores de monitoramento passíveis de acompanhamento sistemático.

Frameworks conceituais podem transmitir uma aparência de linearidade que não corresponde à complexidade dos processos institucionais que pretendem representar. A proposta desenvolvida neste estudo não descreve como os sistemas de Inteligência Artificial (IA) necessariamente funcionam na prática; apresenta, antes, um arranjo normativo e analítico sobre como deveriam ser estruturados quando empregados na governança ambiental da Amazônia Legal. Trata-se, portanto, de uma prescrição sociotécnica, orientada pela articulação entre capacidade técnica, decisão administrativa e mecanismos de responsabilização.

A contribuição original do *framework* não consiste na criação isolada de técnicas de IA, de modelos de governança de dados ou de procedimentos de auditoria, elementos já discutidos em diretrizes e estudos especializados. Sua inovação está na integração desses elementos em uma arquitetura voltada especificamente à governança ambiental da Amazônia Legal, conectando: **(i)** a qualidade e a rastreabilidade dos dados; **(ii)** o desenvolvimento, a validação e a interpretabilidade dos modelos; **(iii)** a mediação humana entre resultados algorítmicos e decisões administrativas; e **(iv)** mecanismos de governança, transparência, contestação e responsabilização. Essa integração aproxima recomendações gerais para sistemas de IA confiáveis das condições territoriais, institucionais e ambientais que caracterizam a região amazônica (EU High-Level Expert Group on AI, 2019; National Institute of Standards and Technology, 2023).

A estrutura organiza-se em quatro camadas interdependentes: Dados, Modelos, Decisão e Governança & *Accountability*. Elas não devem ser interpretadas como etapas rígidas ou inteiramente sequenciais. Embora os dados alimentem os modelos e estes subsidiem decisões, a governança e a *accountability* atravessam todo o ciclo de vida do

sistema, desde a definição de sua finalidade até o monitoramento de seus efeitos. A fragilidade de uma camada compromete as demais: dados inadequados reduzem a confiabilidade dos modelos; modelos pouco transparentes dificultam a revisão das decisões; e decisões sem registro ou possibilidade de contestação enfraquecem a legitimidade institucional do sistema.

Camada de Dados

A camada de Dados constitui a base do *framework*. Dados imprecisos, incompletos, desatualizados ou enviesados podem comprometer os resultados de qualquer modelo, independentemente de sua sofisticação técnica. Por essa razão, a gestão de dados deve abranger a documentação de metadados, a identificação das fontes, o controle de versionamento, a definição de responsáveis, os critérios de qualidade e as regras de acesso, compartilhamento e atualização das bases utilizadas (DAMA International, 2017; National Institute of Standards and Technology, 2023).

No contexto da Amazônia Legal, essa camada exige atenção particular. O Cadastro Ambiental Rural (CAR), por exemplo, é uma base relevante para análises territoriais e ambientais, mas sua natureza autodeclaratória e os limites de sua utilização isolada como instrumento de controle do desmatamento reforçam a necessidade de validação, verificação de consistência e rastreabilidade antes de sua incorporação em modelos de IA (Azevedo et al., 2017). O *framework* propõe, portanto, que nenhum conjunto de dados seja empregado como insumo decisório sem documentação mínima sobre sua procedência, abrangência territorial, data de atualização, limitações conhecidas e critérios de qualidade.

Camada de Modelos

A camada de Modelos compreende o desenvolvimento, o treinamento, a validação, a documentação e o monitoramento contínuo dos algoritmos. As escolhas realizadas nessa etapa, como a definição das variáveis, a composição das amostras de treinamento e teste, as métricas de desempenho e os critérios de atualização, influenciam diretamente o que o sistema é capaz de identificar, prever ou priorizar.

A avaliação dos modelos não deve se limitar à acurácia global. Em situações nas quais eventos de interesse são relativamente raros, como alertas de

desmatamento, incêndios ou indícios de irregularidade, métricas baseadas apenas em acurácia podem ocultar desempenhos insuficientes para os casos mais relevantes. Nesses contextos, medidas como precisão, revocação (*recall*) e curvas de precisão-revocação contribuem para uma avaliação mais informativa do desempenho do classificador (Saito e Rehmsmeier, 2015).

Além disso, o *framework* recomenda a avaliação desagregada dos resultados por região, período, tipo de cobertura do solo e outras variáveis relevantes para o contexto de aplicação. Essa prática permite identificar se o modelo apresenta desempenho desigual entre territórios ou grupos de dados. Em decisões com efeitos potencialmente relevantes sobre direitos, territórios ou meios de vida, a preferência por modelos interpretáveis ou acompanhados de mecanismos robustos de explicação deve ser considerada desde a etapa de projeto. Rudin (2019) sustenta que, em contextos de alto impacto, a interpretabilidade não deve ser tratada apenas como recurso posterior de explicação, mas como critério de escolha do próprio modelo.

Camada de Decisão

A camada de Decisão corresponde ao momento em que os resultados produzidos pelos modelos são interpretados e convertidos em ações institucionais. O ponto central dessa camada é reconhecer que um alerta, uma classificação ou uma previsão não equivale, por si só, a uma decisão administrativa. Esses resultados devem ser analisados por agentes humanos com competência institucional, conhecimento do território e responsabilidade pelos efeitos decorrentes da medida adotada.

O *framework* distingue, nesse sentido, sistemas que informam decisões daqueles que efetivam decisões. Sistemas de detecção de mudanças na cobertura vegetal, previsão de risco ou priorização de áreas para vistoria podem subsidiar o planejamento de ações, desde que seus resultados sejam tratados como evidências a serem verificadas. Já decisões com efeitos jurídicos diretos, como a imposição de sanções, o bloqueio de benefícios ou a restrição de direitos não devem ser automatizadas sem revisão humana qualificada, fundamentação adequada e possibilidade de contestação.

Essa diferenciação está alinhada às diretrizes para IA confiável, que destacam a supervisão humana como requisito para sistemas que possam produzir impactos relevantes sobre indivíduos, coletividades

ou direitos (EU High-Level Expert Group on AI, 2019; National Institute of Standards and Technology, 2023). No âmbito da Administração Pública brasileira, a exigência de motivação dos atos administrativos, prevista no art. 50 da Lei nº 9.784/1999, reforça a necessidade de que decisões baseadas ou assistidas por IA permaneçam compreensíveis, justificáveis e passíveis de revisão (Brasil, 1999).

Camada de Governança & Accountability

A camada de Governança & Accountability é transversal às demais. Ela compreende as normas, os procedimentos, as instâncias de supervisão e os mecanismos de responsabilização necessários para tornar o sistema auditável, contestável e corrigível. Sem essa camada, mesmo sistemas tecnicamente consistentes podem produzir resultados institucionalmente frágeis, pois não haverá meios suficientes para identificar falhas, atribuir responsabilidades ou reparar efeitos indevidos.

Essa dimensão exige, entre outros elementos, a definição explícita da finalidade do sistema; a designação de responsáveis institucionais; o registro das fontes de dados e das versões dos modelos; a documentação dos critérios de decisão; a manutenção de trilhas de auditoria; a realização de avaliações periódicas de risco; e a disponibilização de canais para revisão e contestação. O *Artificial Intelligence Risk Management Framework* do NIST organiza a

governança de riscos em funções de governar, mapear, medir e gerenciar, enfatizando que a gestão de sistemas de IA deve acompanhar todo o seu ciclo de vida (National Institute of Standards and Technology, 2023).

No Brasil, a Estratégia Brasileira de Inteligência Artificial reconhece a relevância de princípios como transparência, ética, responsabilidade, segurança e proteção de direitos na adoção de sistemas de IA pelo poder público e pela sociedade (Brasil, 2021). Para a governança ambiental amazônica, esses princípios precisam ser traduzidos em procedimentos operacionais concretos, especialmente nos casos em que sistemas automatizados orientem atividades de fiscalização, gestão territorial, análise documental ou integração de bases de dados.

A Figura 1 apresenta a arquitetura do *framework* e as relações entre as quatro camadas. A Figura 2 detalha a cadeia de evidências que conecta a detecção automatizada de um evento à eventual adoção de um ato administrativo, incluindo etapas de verificação, supervisão humana, registro, decisão e retroalimentação. Essa cadeia não deve ser compreendida como um fluxo inteiramente linear: os resultados dos modelos podem ser revistos, os dados podem ser corrigidos e as decisões podem ser reconsideradas à luz de novas informações ou de contestações apresentadas pelos sujeitos afetados.




Figura 1. Framework sociotécnico para uso responsável da Inteligência Artificial na governança ambiental da Amazônia Legal: arquitetura em quatro camadas interdependentes.




Figura 2. Cadeia de evidências: fluxo entre detecção automatizada pelo sistema de IA e ato administrativo correspondente, com etapas de verificação, supervisão humana, registro e retroalimentação.

O Quadro 1 sintetiza as aplicações de IA discutidas neste estudo, relacionando-as às evidências de referência, aos riscos sociotécnicos, às salvaguardas recomendadas e aos indicadores propostos para monitoramento. Os indicadores não representam medidas universais ou obrigatórias; constituem parâmetros analíticos que podem ser adaptados às competências, aos recursos e às condições operacionais de cada instituição.

Uma ressalva final é necessária. O *framework* não substitui a análise das condições institucionais

concretas em que cada sistema será utilizado. Sua função é oferecer uma estrutura comum para orientar decisões sobre adoção, desenvolvimento, contratação, uso, monitoramento e revisão de sistemas de IA. A aplicação prática dessas diretrizes dependerá das competências institucionais, da disponibilidade de dados, da infraestrutura tecnológica, dos marcos normativos e das características territoriais de cada situação.

Quadro 1. Tipologia de aplicações de IA na governança ambiental da Amazônia Legal: riscos, salvaguardas e indicadores de monitoramento.

Eixo de aplicação	Finalidade	Riscos associados	Salvaguardas recomendadas	Indicadores de monitoramento
Monitoramento e detecção de mudanças Diniz et al. (2015); Rudin (2019); National Institute of Standards and Technology (2023)	Identificar supressão de vegetação, degradação florestal e alterações no uso e na cobertura da terra por meio de imagens de satélite.	Cobertura territorial desigual; falsos positivos e falsos negativos; baixa interpretabilidade de modelos complexos.	Documentação de metadados; validação com dados de campo; avaliação de desempenho por região; revisão humana antes de medidas com efeitos jurídicos.	Taxas de falsos positivos e falsos negativos por região; tempo entre alerta e resposta institucional; proporção de alertas verificados em campo.
Previsão de risco Saito e Rehmsmeier (2015); National Institute of Standards and Technology (2023)	Antecipar áreas e períodos com maior probabilidade de ocorrência de desmatamento, degradação ou incêndios.	Desempenho desigual entre regiões; uso inadequado de métricas em bases desbalanceadas; perda de desempenho após mudanças nas condições ambientais ou territoriais.	Monitoramento contínuo do desempenho; atualização documentada dos dados de treinamento; validação por região e período; comunicação das incertezas associadas às previsões.	Precisão, revocação e curva precisão-revocação por região; frequência de atualização dos modelos; proporção de alertas preventivos verificados.
Priorização e alocação de recursos de fiscalização Reis et al. (2022); Barocas, Hardt e Narayanan (2023); National Institute of Standards and Technology (2023)	Apoiar a priorização de áreas para fiscalização, considerando probabilidade de ilícito, impacto potencial e urgência da intervenção.	Reforço de padrões históricos de concentração da fiscalização; invisibilização de áreas remotas; reprodução de vieses presentes nos dados institucionais.	Auditoria de distribuição territorial; revisão humana dos critérios de priorização; documentação das variáveis utilizadas; avaliação periódica de efeitos distributivos.	Distribuição geográfica das operações; proporção de áreas remotas incluídas nas prioridades; taxa de confirmação das irregularidades identificadas.

Eixo de aplicação	Finalidade	Riscos associados	Salvaguardas recomendadas	Indicadores de monitoramento
Triagem e análise documental Chalkidis et al. (2020); EU High-Level Expert Group on AI (2019); National Institute of Standards and Technology (2023)	Apoiar a leitura, a classificação e a organização de processos administrativos, relatórios, denúncias e registros de licenciamento.	Erros de interpretação de linguagem jurídica ou técnica; classificação inadequada de documentos; automação indevida de decisões com efeitos jurídicos.	Supervisão humana antes de qualquer efeito jurídico; registro dos critérios e resultados de triagem; validação periódica com especialistas; mecanismos de correção de erros.	Taxa de erro na categorização documental; proporção de triagens revisadas por analistas; número de correções ou contestações relacionadas ao sistema.
Integração e verificação de consistência entre bases de dados Azevedo et al. (2017); DAMA International (2017); Brasil (2018)	Cruzar registros ambientais, fundiários e de fiscalização para identificar inconsistências, sobreposições e informações que demandem verificação.	Propagação de erros entre bases integradas; uso de dados desatualizados; exposição indevida de informações pessoais ou sensíveis.	Rastreabilidade das fontes; critérios de atualização; validação de consistência; controle de acesso por perfil; medidas compatíveis com a LGPD.	Número de inconsistências identificadas e corrigidas; tempo médio de atualização das bases; registros de incidentes de segurança e de acesso indevido.

Fonte: Adaptado de Diniz et al. (2015), Azevedo et al. (2017), DAMA International (2017), Brasil (2018), EU High-Level Expert Group on AI (2019), Rudin (2019), Reis et al. (2022), Barocas, Hardt e Narayanan (2023), National Institute of Standards and Technology (2023), Saito e Rehmsmeier (2015) e Chalkidis et al. (2020).

Implicações para a Amazônia Legal

A Amazônia Legal constitui um território habitado, disputado e administrado por uma pluralidade de atores, entre os quais povos indígenas, comunidades tradicionais, agricultores familiares, proprietários rurais, órgãos federais e estaduais, municípios e organizações da sociedade civil. Nesse contexto, a adoção de sistemas de Inteligência Artificial (IA) para fins de monitoramento, fiscalização ou gestão territorial não pode ser tratada como uma intervenção exclusivamente técnica. Seus efeitos incidem sobre relações fundiárias, atividades econômicas, direitos territoriais e capacidades institucionais que variam de forma significativa entre os estados e municípios da região (Brasil, 2023; Comissão Pastoral da Terra, 2024).

A escala territorial é o primeiro condicionante. A Amazônia Legal abrange aproximadamente 5 milhões de km², distribuídos por nove estados brasileiros, o que corresponde a cerca de 59% do território nacional (IBGE, 2022). Nenhum sistema de monitoramento, humano ou automatizado, consegue cobrir esse espaço de modo inteiramente homogêneo. A IA pode ampliar a capacidade de

processamento de imagens, a identificação de padrões e a priorização de áreas para fiscalização; contudo, sua utilidade depende da qualidade, da atualização e da cobertura dos dados disponíveis. Sistemas que produzem resultados em áreas com baixa disponibilidade de dados ou reduzida validação de campo devem explicitar suas limitações, seus níveis de incerteza e as condições sob as quais suas previsões podem ser empregadas na tomada de decisão (*National Institute of Standards and Technology*, 2023).

A conectividade e a infraestrutura digital constituem outro condicionante relevante. A implantação de ferramentas de IA frequentemente pressupõe acesso estável à internet, capacidade de armazenamento e processamento de dados, integração entre sistemas e comunicação contínua entre equipes de campo e centrais administrativas. Entretanto, a conectividade no Brasil permanece desigual, especialmente entre áreas urbanas e rurais e entre as diferentes regiões do país, o que pode limitar o uso contínuo de sistemas digitais em territórios remotos (CGI.br, 2024). Assim, soluções voltadas à Amazônia Legal precisam prever procedimentos

compatíveis com cenários de conectividade intermitente, operação *off-line*, sincronização posterior de dados e manutenção de rotinas alternativas de comunicação e registro.

A heterogeneidade institucional também exige atenção. A governança ambiental na Amazônia Legal envolve órgãos federais, estaduais e municipais com competências, recursos, sistemas de informação e procedimentos administrativos distintos. O Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal reconhece a necessidade de coordenação entre diferentes órgãos e níveis de governo para enfrentar o desmatamento e outros ilícitos ambientais (Brasil, 2023). Nesse ambiente, a incorporação de IA requer definição prévia de responsabilidades, fluxos de decisão, critérios de compartilhamento de dados e mecanismos de prestação de contas. A interoperabilidade, portanto, não deve ser entendida apenas como compatibilidade técnica entre bases, mas como um arranjo de governança que estabeleça quem produz, acessa, atualiza, valida e utiliza cada informação (Brasil, 2019; *National Institute of Standards and Technology*, 2023).

Os conflitos fundiários acrescentam uma camada adicional de complexidade. A região reúne terras indígenas, territórios quilombolas, assentamentos de reforma agrária, unidades de conservação, imóveis rurais privados e áreas com diferentes graus de regularização fundiária. Registros de conflitos no campo demonstram que disputas por terra, recursos naturais e reconhecimento territorial permanecem presentes em diversos estados amazônicos (Comissão Pastoral da Terra, 2024). Nesse cenário, classificações automatizadas, cruzamentos de cadastros ou modelos de priorização não devem ser tratados como prova suficiente para decisões com efeitos jurídicos ou territoriais. Resultados produzidos por sistemas de IA precisam ser submetidos à verificação humana qualificada, à análise documental e, quando pertinente, à consulta às instituições e populações potencialmente afetadas.

A legitimidade social é igualmente decisiva. Sistemas de IA introduzidos sem transparência sobre sua finalidade, suas fontes de dados, seus critérios gerais de funcionamento e seus mecanismos de contestação podem ser percebidos como instrumentos externos de controle territorial. A Recomendação da Unesco sobre a Ética da Inteligência Artificial estabelece que a governança dessas tecnologias deve incorporar participação de partes interessadas,

avaliação de impactos, transparência apropriada ao contexto e mecanismos de supervisão e reparação (Unesco, 2021). No contexto amazônico, isso implica reconhecer que comunidades e coletividades afetadas devem ter acesso a informações compreensíveis sobre o uso dos sistemas e a canais institucionais para questionar resultados que produzam efeitos sobre seus direitos, territórios ou meios de vida.

A adoção de IA na governança ambiental da Amazônia Legal deve, portanto, ser precedida por diagnóstico institucional e territorial específico. Esse diagnóstico precisa identificar: a finalidade pública do sistema; os dados disponíveis e suas limitações; a infraestrutura de conectividade e processamento; os órgãos envolvidos; os fluxos de decisão; os riscos para direitos individuais e coletivos; e os mecanismos de supervisão, auditoria e contestação aplicáveis. A estrutura proposta pelo *Artificial Intelligence Risk Management Framework* recomenda justamente o mapeamento do contexto, dos atores afetados e dos impactos potenciais como condição para a gestão responsável de riscos associados à IA (*National Institute of Standards and Technology*, 2023). A tecnologia pode ser semelhante em diferentes localidades, mas o arranjo sociotécnico necessário para seu uso responsável deverá ser adaptado às capacidades institucionais, às condições territoriais e às populações afetadas em cada caso.

Limitações do estudo e agenda de pesquisa

Este estudo apresenta limitações inerentes ao delineamento adotado, entre as quais se destacam possíveis vieses de cobertura das bases consultadas, a heterogeneidade conceitual dos descritores e as restrições próprias de uma investigação de natureza teórica. Essas limitações podem ter influenciado a composição do corpus analisado e o alcance das inferências produzidas. Além disso, a estrutura sociotécnica proposta ainda não foi submetida à validação empírica em contextos institucionais específicos. Sua aplicação futura deverá, portanto, ser acompanhada de estudos de caso, avaliações de desempenho dos sistemas e análises dos efeitos concretos sobre os processos decisórios e os grupos afetados.

CONCLUSÃO

Este estudo propôs um *framework* sociotécnico e salvaguardas para orientar o uso responsável da Inteligência Artificial na governança

ambiental da Amazônia Legal. Os resultados atenderam aos objetivos da pesquisa ao organizarem as aplicações de IA em cinco eixos – monitoramento e detecção, previsão de risco, priorização da fiscalização, triagem documental e integração de bases de dados –, identificarem os principais riscos sociotécnicos associados e os traduzirem em salvaguardas operacionais. O *framework*, estruturado nas camadas Dados, Modelos, Decisão e Governança e Responsabilização, evidencia que a efetividade dessas tecnologias não depende apenas do desempenho algorítmico, mas também da qualidade e rastreabilidade dos dados, da validação contínua dos modelos, da supervisão humana e da existência de mecanismos de auditoria, transparência e contestação.

A contribuição científica do estudo consiste em integrar dimensões técnicas, institucionais e normativas que a literatura sobre Inteligência Artificial e governança ambiental frequentemente aborda de modo fragmentado. Ao adaptar essa integração às particularidades territoriais e institucionais da Amazônia Legal, o trabalho oferece uma referência analítica para o desenvolvimento, a adoção e a avaliação de sistemas de IA voltados à gestão ambiental. Conclui-se que tais sistemas podem ampliar a capacidade de monitoramento e priorização das ações públicas, desde que sua implementação esteja vinculada a salvaguardas capazes de assegurar decisões auditáveis, justificáveis e compatíveis com a proteção ambiental e de direitos.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abessa, D.; Famá, A. & Buruaem, L. (2019). *The systematic dismantling of Brazilian environmental laws risks losses on all fronts*. **Nature Ecology & Evolution** 3(4): 510-511. <https://doi.org/10.1038/s41559-019-0855-9>.
- Azevedo, A.A.; Rajão, R.; Costa, M.A.; Stabile, M.C.C.; Macedo, M.N.; Reis, T.N.P.; Alencar, A.; Soares-Filho, B.S. & Pacheco, R. (2017). *Limits of Brazil's Forest Code as a means to end illegal deforestation*. **Proceedings of the National Academy of Sciences** 114(29): 7653-7658. <https://doi.org/10.1073/pnas.1604768114>.
- Barocas, S.; Hardt, M. & Narayanan, A. (2023). *Fairness and machine learning: Limitations and opportunities*. Cambridge: MIT Press. Disponível em: <https://fairmlbook.org/>.
- Brasil. (1999). **Lei nº 9.784, de 29 de janeiro de 1999**. Regula o processo administrativo no âmbito da Administração Pública Federal. *Diário Oficial da União*, Brasília, DF, 1 fev. 1999. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/19784.htm.
- Brasil. (2011). **Lei nº 12.527, de 18 de novembro de 2011**. Regula o acesso a informações previsto no inciso XXXIII do art. 5º da Constituição Federal. *Diário Oficial da União*, Brasília, DF, 18 nov. 2011. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/l12527.htm.
- Brasil. (2018). **Lei nº 13.709, de 14 de agosto de 2018**. Lei Geral de Proteção de Dados Pessoais (LGPD). *Diário Oficial da União*, Brasília, DF, 15 ago. 2018. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm.
- Brasil. (2019). **Decreto nº 10.046, de 9 de outubro de 2019**. Dispõe sobre a governança no compartilhamento de dados no âmbito da administração pública federal e institui o Cadastro Base do Cidadão e o Comitê Central de Governança de Dados. *Diário Oficial da União*, Brasília, DF, 10 out. 2019. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2019/decreto/d10046.htm.
- Brasil. Ministério da Ciência, Tecnologia e Inovações. (2021). **Estratégia Brasileira de Inteligência Artificial (EBIA)**. Brasília: MCTI. Disponível em: <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacao-digital/inteligencia-artificial>.
- Brasil. Ministério do Meio Ambiente e Mudança do Clima. (2023). **Plano de ação para prevenção e controle do desmatamento na Amazônia Legal: PPCDAm – 5ª fase, 2023-2027**. Brasília: Ministério do Meio Ambiente e Mudança do Clima.
- Brown, T.B. et al. (2020). *Language models are few-shot learners*. **Advances in Neural Information**

Processing Systems 33: 1877-1901. Disponível em: <https://arxiv.org/abs/2005.14165>.

Chalkidis, I.; Fergadiotis, M.; Malakasiotis, P.; Aletras, N. & Androustopoulos, I. (2020). *LEGAL-BERT: The Muppets straight out of law school*. In: **Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing**. Stroudsburg: Association for Computational Linguistics. p. 2898-2904. <https://doi.org/10.18653/v1/2020.emnlp-main.261>.

Comissão Pastoral da Terra. (2024). **Conflitos no campo Brasil 2023**. Goiânia: Comissão Pastoral da Terra. Disponível em: <https://www.cptnacional.org.br/publicacoes-2/conflitos-no-campo-brasil>.

Comitê Gestor da Internet no Brasil – CGI.br. (2024). **Pesquisa sobre o uso das tecnologias de informação e comunicação nos domicílios brasileiros: TIC Domicílios 2023**. São Paulo: CGI.br. Disponível em: <https://cetic.br/pt/pesquisa/domicilios/>.
DAMA International. (2017). **DAMA-DMBOK: Data management body of knowledge**. 2. ed. Basking Ridge: Technics Publications. 621p.

De Araujo, P.H.L.; de Campos, T.E.; de Oliveira, R.R.R.; Stauffer, M.; Couto, S. & Bermejo, P.H.S. (2020). *LeNER-Br: A dataset for named entity recognition in Brazilian legal documents*. In: **Proceedings of the 13th International Conference on Theory and Practice of Electronic Governance**. [S. l.]: ACM.

Diniz, C.G.; Souza, A.A. de A.; Santos, D.C.; Dias, M.C.; Luz, N.C. da; Moraes, D.R.V. de; Maia, J.S.; Gomes, A.R.; Narvaes, I. da S.; Valeriano, D.M.; Maurano, L.E.P. & Adami, M. (2015). *DETER-B: The new Amazon near real-time deforestation detection system*. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing** 8(7): 3619-3628. <https://doi.org/10.1109/JSTARS.2015.2437075>.

EU High-Level Expert Group on AI. (2019). **Ethics guidelines for trustworthy AI**. Brussels: European Commission. Disponível em: <https://digital->

strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai.

FLORIDI, Luciano; COWLS, Josh; BELTRAMETTI, Monica; CHATILA, Raja; CHAZERAND, Patrice; DIGNUM, Virginia; LUETGE, Christoph; MADELIN, Robert; PAGALLO, Ugo; ROSSI, Francesca; SCHAFER, Burkhard; VALCKE, Peggy; VAYENA, Effy. (2018). *An ethical framework for a good AI society: Opportunities, risks, principles, and recommendations*. **Minds and Machines** 28(4): 689-707. <https://doi.org/10.1007/s11023-018-9482-5>.

IBGE – Instituto Brasileiro de Geografia e Estatística. (2022). **Amazônia Legal**. Rio de Janeiro: IBGE. Disponível em: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html>.

INPE – Instituto Nacional de Pesquisas Espaciais. (2022). **PRODES: Monitoramento do desmatamento da Floresta Amazônica Brasileira por satélite**. São José dos Campos: INPE. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programa/s/amazonia/prodes>.

Körting, T.S.; Fonseca, L.M.G. & Câmara, G. (2021). *Big Earth observation time series analysis for forest degradation monitoring in the Brazilian Amazon*. **Remote Sensing of Environment** 255: 112270. <https://doi.org/10.1016/j.rse.2020.112270>.

National Institute of Standards and Technology. (2023). **Artificial intelligence risk management framework (AI RMF 1.0)**. Gaithersburg: National Institute of Standards and Technology. NIST AI 100-1. <https://doi.org/10.6028/NIST.AI.100-1>.

Reis, L.P.; Carvalho, W.D.; Silveira, M.; Adami, M.; Escada, M.I.S. & Araújo, L.S. (2022). *Prioritizing deforestation monitoring and enforcement in the Brazilian Amazon*. **Forest Policy and Economics** 134: 102626. <https://doi.org/10.1016/j.forpol.2021.102626>.

Rudin, C. (2019). *Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead*. **Nature Machine**

- Intelligence** 1(5): 206-215. <https://doi.org/10.1038/s42256-019-0048-x>.
- Saito, T. & Rehmsmeier, M. (2015). *The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets*. **PLoS ONE** 10(3): e0118432. <https://doi.org/10.1371/journal.pone.0118432>.
- Soares-Filho, B.S.; Nepstad, D.C.; Curran, L.M.; Cerqueira, G.C.; Garcia, R.A.; Ramos, C.A. & Schlesinger, P. (2006). *Modelling conservation in the Amazon basin*. **Nature** 440(7083): 520-523. <https://doi.org/10.1038/nature04389>.
- Souza, M.T.; Silva, M.D. & Carvalho, R. (2010). Revisão integrativa: o que é e como fazer. **Einstein** 8(1): 102-106. <https://doi.org/10.1590/S1679-45082010RW1134>.
- Sparovek, G. et al. (2019). *Fake legal gains in Brazilian Amazon deforestation amnesty*. **Science Advances** 5(11): eaax4346. <https://doi.org/10.1126/sciadv.aax4346>.
- UNESCO – United Nations Educational, Scientific and Cultural Organization. (2021). **Recommendation on the ethics of artificial intelligence**. Paris: UNESCO. Disponível em: <https://unesdoc.unesco.org/ark:/48223/pf0000381137>.