

INTELIGÊNCIA ARTIFICIAL E OS SISTEMAS DE GESTÃO DO MEC:

Governança algorítmica para a avaliação da educação superior

Fabiana Pereira Costa Ramos
Estudante de doutorado do Programa de Cognição e Linguagem da Universidade Estadual do Norte Fluminense Darcy Ribeiro
fabianacostapicanco@gmail.com

Eliana Crispim França Luquetti
Professora do Programa de de Cognição e Linguagem da Universidade Estadual do Norte Fluminense Darcy Ribeiro
elinafff@uenf.br

Carlos Henrique Medeiros de Souza
Professor do Programa de de Cognição e Linguagem da Universidade Estadual do Norte Fluminense Darcy Ribeiro
chmsouza@gmail.com

Fabio Machado de Oliveira
Professor do Programa de de Cognição e Linguagem da Universidade Estadual do Norte Fluminense Darcy Ribeiro
fabiomac@gmail.com

Claudino Bartolazi Boechat
Estudante de doutorado do Programa de Cognição e Linguagem da Universidade Estadual do Norte Fluminense Darcy Ribeiro
claudino.bartolazi@gmail.com

Resumo: Este resumo apresenta, de forma sintética, a integração da Inteligência Artificial (IA) aos sistemas de gestão do Ministério da Educação (MEC), com foco no e-MEC e no ciclo avaliativo do SINAES, à luz da Estratégia Federal de Governo Digital, do PTD-MEC 2025–2026 e do Decreto nº 12.456/2025 (EAD). A pesquisa bibliográfico documental mapeia oportunidades (análises preditivas de qualidade, verificação automatizada de documentos, dashboards explicáveis e chatbots regulatórios) e riscos (vieses algorítmicos, opacidade decisória, qualidade/interoperabilidade de dados e conformidade com a LGPD). Em diálogo com referenciais internacionais de garantia da qualidade, adotamos parâmetros de sucesso inspirados em: Reino Unido (OfS/NSS), com foco na satisfação e na experiência do estudante; Austrália (TEQSA/QILT), enfatizando progressão, retenção e conclusão, além de resultados de egressos e satisfação de empregadores; Estados Unidos (MSCHE), privilegiando evidências de aprendizagem e ciclos de melhoria contínua (closing the loop); e Europa (ESG/ENQA-EQAR), que demanda transparência, informação pública fidedigna e aprendizagem centrada no estudante. Propõe-se um referencial de governança algorítmica combinando legalidade digital, transparência, gestão do ciclo de vida de modelos, segurança da informação e participação social. Conclui-se que a IA pode fortalecer a regulação e a avaliação da educação superior ao reduzir prazos, antecipar fragilidades e ampliar a transparência, desde que implantada com salvaguardas éticas e jurídicas, capacitação das equipes e infraestrutura de dados interoperável.

Palavras-chave: Inteligência Artificial; Sistemas de Gestão; Avaliação

Abstract: This extended abstract synthesizes the integration of Artificial Intelligence (AI) into Brazil's Ministry of Education (MEC) management systems, focusing on e-MEC and the SINAES evaluation cycle, in light of the Federal Digital Government Strategy, the PTD-MEC 2025–2026, and Decree N°12.456/2025 (distance education). Using a bibliographic documentary approach, it maps opportunities predictive analytics for quality indicators, automated document verification, explainable dashboards, and regulatory chatbots and risks algorithmic bias, decision opacity, data quality/interoperability, and compliance with the Brazilian General Data Protection Law (LGPD). In dialogue with international quality-assurance references, we adopt success parameters inspired by: the UK (OfS/NSS), emphasizing student satisfaction and learning experience; Australia (TEQSA/QILT), stressing progression, retention, completion, graduate outcomes and employer satisfaction; the United States (MSCHE), privileging evidence of learning and continuous-improvement cycles (closing the loop); and Europe (ESG/ENQA-EQAR), requiring transparency, reliable public information, and student-centred learning. We propose an algorithmic-governance framework combining digital legality, transparency, model lifecycle management, information security, and social participation. We conclude that AI can strengthen regulation and evaluation in higher education by shortening timelines, anticipating weaknesses, and increasing transparency provided ethical-legal safeguards, staff training, and interoperable data infrastructures are ensured.

Keywords: Artificial Intelligence; Management Systems; Evaluation.

1. Introdução

A aceleração da transformação digital no setor público brasileiro recoloca a gestão de dados, a interoperabilidade e a automação inteligente como capacidades estratégicas do Estado democrático. No Ministério da Educação (MEC), esse movimento se ancora na Estratégia Federal de Governo Digital, instituída para orientar a digitalização de serviços públicos, e no Plano de Transformação Digital do MEC 2025–2026, que prevê revisão de processos, integração de bases de dados, modernização de sistemas legados e oferta de serviços digitais centrados no cidadão, com foco em eficiência, transparência e participação social.

No campo da educação superior, tais diretrizes convergem com o redesenho do marco regulatório da Educação a Distância, especialmente após a publicação do Decreto n° 12.456/2025, que dispõe sobre a oferta de EAD em cursos de graduação e altera o Decreto n° 9.235/2017, responsável por disciplinar as funções de regulação, supervisão e avaliação das Instituições de Educação Superior (IES) e de seus cursos no sistema federal de ensino. Esse novo arranjo normativo intensifica a pressão por modernizar o e-MEC, qualificar o ciclo avaliativo do Sistema Nacional de Avaliação da Educação Superior (SINAES) e fortalecer mecanismos de garantia da qualidade em um cenário de expansão, diversificação institucional e crescente oferta de cursos na modalidade a distância.

Nesse contexto, a Inteligência Artificial (IA) emerge como tecnologia de propósito geral com potencial para reconfigurar os sistemas de gestão do MEC, oferecendo recursos de automação responsável, análises preditivas, monitoramento em tempo quase real e apoio à explicabilidade de decisões regulatórias e avaliativas. Aplicada ao e-MEC e ao ciclo SINAES, a IA pode sustentar, por exemplo, triagens automatizadas de processos, verificação de consistência documental, identificação de padrões de risco em indicadores de qualidade, construção de dashboards explicáveis e disponibilização de assistentes virtuais regulatórios orientados por regras normativas. Tais possibilidades dialogam com experiências internacionais de uso intensivo de dados e analytics em sistemas de garantia da qualidade, como aqueles organizados em torno dos Standards and Guidelines for Quality Assurance in the European Higher Education Area (ESG).

Contudo, a incorporação de modelos algorítmicos em decisões sensíveis em educação

superior não é neutra nem meramente técnica. Ela supõe salvaguardas ético-jurídicas, proteção de dados pessoais e sensíveis, respeito aos direitos dos titulares, possibilidade de contestação de decisões automatizadas, e condições técnicas robustas, como qualidade e completude das bases de dados, governança e interoperabilidade entre sistemas, bem como trilhas de auditoria e mecanismos de prestação de contas. A Recomendação da UNESCO sobre a Ética da IA, adotada em 2021, explicita princípios como transparência, responsabilização, justiça e respeito aos direitos humanos como parâmetros para projetos de IA em políticas públicas.

De forma convergente, Floridi e Cowls defendem um arcabouço normativo baseado em beneficência, não maleficência, autonomia, justiça e explicabilidade, destacando a necessidade de tornar inteligíveis os sistemas algorítmicos e de clarificar responsabilidades ao longo de seu ciclo de vida.

No caso brasileiro, essa discussão precisa articular-se às finalidades públicas da avaliação da educação superior, tal como previstas na Lei do SINAES (Lei nº 10.861/2004) e em sua regulamentação, que atribuem centralidade à melhoria da qualidade, ao aumento da responsabilidade social e ao fortalecimento da função formativa da avaliação, em diálogo com uma tradição crítica que recusa concepções meramente classificatórias ou punitivas de qualidade (BRASIL, 2004; DIAS SOBRINHO, 2008). A adoção de IA em processos de avaliação institucional, de cursos e de desempenho discente coloca, assim, questões sobre o risco de reforço de assimetrias entre IES, de cristalização de vieses históricos presentes nos bancos de dados oficiais e de opacificação de decisões, caso não haja um desenho cuidadoso de governança algorítmica.

Diante desse cenário, observa-se uma lacuna na literatura nacional no que se refere à análise sistemática da integração da IA aos sistemas de gestão do MEC, em particular ao e-MEC e ao ciclo avaliativo do SINAES, à luz simultânea do marco regulatório brasileiro da educação superior e dos referenciais internacionais de garantia da qualidade. Em geral, os estudos sobre avaliação da educação superior e os debates sobre ética da IA em políticas públicas tendem a caminhar em trilhas paralelas, com pouco diálogo entre as especificidades da regulação educacional e os desafios técnico-normativos da adoção de algoritmos em ambientes regulatórios complexos.

Este artigo busca contribuir para preencher essa lacuna ao analisar potencialidades e riscos do uso de IA nos sistemas de gestão do MEC voltados à educação superior, com foco no e-MEC e no ciclo SINAES; propor um framework de governança algorítmica ancorado na legalidade digital, na transparência, na gestão do ciclo de vida de modelos, na segurança da informação e na participação social; e discutir parâmetros de sucesso inspirados em referenciais internacionais de garantia da qualidade, como ENQA/ESG, MSCHE, OfS/NSS, TEQSA/QILT, entre outros. A pesquisa se apoia em abordagem bibliográfico-documental, mobilizando a legislação e a normatização educacional brasileira recente, documentos estratégicos sobre governo digital e literatura especializada em ética da IA e avaliação da educação superior, com o objetivo de problematizar de que modo a IA pode fortalecer, e em que condições, a regulação e a avaliação da educação superior sem desfigurar sua finalidade pública.

2. Fundamentação teórica

A discussão sobre governança algorítmica insere-se no campo mais amplo da ética da Inteligência Artificial e da regulação de dados no setor público. Em termos gerais, governança algorítmica diz respeito ao conjunto de princípios, normas, processos e instrumentos sociotécnicos que orientam o desenho, a implementação, o monitoramento e a responsabilização pelo uso de sistemas algorítmicos em decisões que afetam direitos e políticas públicas. Floridi e Cowls propõem um quadro ético unificado para a

IA, ancorado em cinco princípios, beneficência, não maleficência, autonomia, justiça e explicabilidade, e defendem que sistemas algorítmicos só podem ser considerados aceitáveis quando maximizam benefícios, minimizam danos, respeitam a autonomia dos sujeitos, não reforçam injustiças estruturais e permanecem inteligíveis e atribuíveis a responsáveis humanos.

No plano normativo internacional, a Recomendação da UNESCO sobre a Ética da IA (2021) constitui o primeiro instrumento global voltado especificamente à regulação ética da Inteligência Artificial. O documento afirma a centralidade dos direitos humanos, da dignidade humana e da supervisão humana significativa, estabelecendo como princípios estruturantes a transparência, a justiça, a não discriminação, a responsabilidade e a possibilidade de auditoria dos sistemas algorítmicos. Esses referenciais convergem para a ideia de que a adoção de IA em políticas públicas, incluindo a avaliação da educação superior, não pode ser reduzida a ganhos de eficiência, devendo ser acompanhada de mecanismos institucionais de accountability e participação social.

No caso brasileiro, a Lei Geral de Proteção de Dados Pessoais (LGPD) (Lei nº 13.709/2018) oferece um pilar jurídico central para a governança algorítmica. A LGPD estabelece que o tratamento de dados pessoais, inclusive nos meios digitais, deve proteger os direitos fundamentais de liberdade, de privacidade e o livre desenvolvimento da personalidade, assentando-se em fundamentos como o respeito à privacidade, a autodeterminação informativa e os direitos humanos. Além disso, a lei explicita princípios como finalidade, adequação, necessidade (minimização de dados), segurança, prevenção, transparência e não discriminação, que se tornam critérios obrigatórios para o desenho de sistemas de IA utilizados pelo poder público. Em cenários de alto risco para direitos e liberdades, a LGPD recomenda a elaboração de Relatórios de Impacto à Proteção de Dados (RIPD), instrumentos que dialogam diretamente com a ideia de avaliações de impacto algorítmico na literatura internacional, reforçando a necessidade de antecipar riscos e de documentar decisões no ciclo de vida dos modelos.

A avaliação da educação superior no Brasil é estruturada pelo Sistema Nacional de Avaliação da Educação Superior (SINAES), instituído pela Lei nº 10.861/2004. O SINAES organiza um processo nacional de avaliação que abrange instituições, cursos e desempenho dos estudantes, com o objetivo de melhorar a qualidade da educação superior, orientar a expansão da oferta, aumentar a eficácia acadêmica e social e promover a responsabilidade das IES perante a sociedade. Suas dimensões contemplam missão e plano de desenvolvimento institucional, políticas acadêmicas, políticas de gestão e infraestrutura, entre outros eixos, desdobrando-se em instrumentos e indicadores como o Conceito Preliminar de Curso (CPC) e o Índice Geral de Cursos (IGC), derivados de combinações entre dados de desempenho discente, corpo docente, infraestrutura e insumos acadêmicos.

A literatura crítica sobre avaliação da educação superior, representada por autores como Dias Sobrinho, alerta, contudo, para os riscos de uma redução tecnocrática da qualidade a um conjunto estreito de indicadores numéricos. Ao insistir no caráter ético-político da avaliação, essas análises sublinham que métricas só adquirem sentido quando interpretadas à luz de projetos formativos, desigualdades estruturais, condições de oferta e impactos sociais, sob pena de reforçar hierarquias e estigmatizar instituições que atendem públicos mais vulneráveis. Nesse sentido, uma governança algorítmica aplicada ao SINAES precisa ser capaz de articular o uso de dados e modelos preditivos com a preservação do caráter público, formativo e participativo da avaliação.

A discussão sobre dados, infraestruturas e qualidade da informação é igualmente central para compreender as possibilidades e os limites do uso de IA em avaliação. Kitchin argumenta que análises confiáveis dependem de ecossistemas de dados ancorados em

padrões de interoperabilidade, metadados robustos, documentação de linhagem (data lineage) e arranjos institucionais claros de governança, que definam responsabilidades sobre produção, curadoria, atualização e compartilhamento de dados. Em um contexto como o da educação superior brasileira, isso significa que indicadores regulatórios (CPC, IGC, ENADE, censo, dados do e-MEC) só podem alimentar sistemas de IA de forma responsável quando há padronização semântica e técnica, registros de transformações aplicadas, mecanismos de correção de inconsistências e espaços para contestação de erros por parte das IES.

Do ponto de vista da garantia da qualidade em perspectiva comparada, os Standards and Guidelines for Quality Assurance in the European Higher Education Area (ESG) constituem referência consolidada. Elaborados pela ENQA em cooperação com associações estudantis e acadêmicas europeias, os ESG definem padrões para a garantia interna e externa da qualidade em torno de princípios como aprendizagem centrada no estudante, cultura de melhoria contínua, uso criterioso de informação pública e participação de múltiplos atores (estudantes, docentes, sociedade) nos processos avaliativos. Mais do que um checklist técnico, os ESG configuram um quadro normativo que vincula avaliação, transparência e responsabilização em um espaço europeu de ensino superior cada vez mais integrado.

Nos Estados Unidos, a Middle States Commission on Higher Education (MSCHE) exemplifica uma abordagem de acreditação baseada em padrões que enfatizam a centralidade da experiência estudantil, a tomada de decisão orientada por dados e evidências e os ciclos de melhoria contínua (closing the loop). Seus padrões articulam missão institucional, governança, recursos, desenho curricular, avaliação da aprendizagem e eficácia institucional, exigindo que as instituições demonstrem, com evidências, que utilizam dados para planejar, monitorar e aprimorar suas práticas.

No Reino Unido, o Office for Students (OfS) coordena, entre outros instrumentos, o National Student Survey (NSS), pesquisa nacional que coleta anualmente percepções de estudantes sobre ensino, avaliação, apoio acadêmico, recursos de aprendizagem, gestão do curso, voz estudantil e bem-estar. Já na Austrália, a Tertiary Education Quality and Standards Agency (TEQSA) atua como agência reguladora nacional, aplicando o Higher Education Standards Framework (Threshold Standards) para garantir integridade e qualidade na oferta da educação superior; em paralelo, o sistema QILT (Quality Indicators for Learning and Teaching) constitui um conjunto de pesquisas nacionais que acompanha toda a trajetória estudantil, da experiência no curso aos desfechos de empregabilidade, produzindo dados comparáveis sobre satisfação, retenção, conclusão e resultados de egressos.

Esses referenciais internacionais convergem em alguns pontos relevantes para a discussão deste artigo: (a) a centralidade da experiência e da aprendizagem dos estudantes como critério de qualidade; (b) o uso intensivo de dados, incluindo percepções estudantis e resultados de egressos, para orientar políticas; (c) a combinação entre padrões mínimos (thresholds) e incentivos à melhoria contínua; e (d) a exigência de transparência e de informação pública fidedigna para sustentar a confiança social. Ao dialogar criticamente com essas experiências, a proposta de um framework de governança algorítmica para o e-MEC/SINAES pode identificar parâmetros de sucesso que sejam adaptáveis ao contexto brasileiro, mas que preservem a ideia de que a IA deve servir à qualidade e à equidade da educação superior, e não substituí-las por uma lógica puramente tecnocrática de gestão por indicadores.

3. Metodologia

Trata-se de um estudo de natureza qualitativa, de caráter exploratório-analítico, desenvolvido sob a forma de estudo de casos múltiplos centrado em macroprocessos e artefatos associados ao e-MEC e ao ciclo avaliativo do SINAES. A opção pela abordagem qualitativa justifica-se pelo interesse em compreender sentidos, racionalidades e práticas que estruturam o uso (atual e potencial) de dados e de modelos algorítmicos na regulação e avaliação da educação superior, mais do que medir efeitos ou testar hipóteses causais. Nessa perspectiva, buscou-se apreender como normas, rotinas administrativas, fluxos de informação e percepções de atores institucionais se articulam na construção de um ecossistema de governança algorítmica no âmbito do MEC e das IES.

O corpus empírico foi constituído por duas grandes fontes de dados. Em primeiro lugar, realizou-se uma análise documental normativa e técnica, contemplando leis (a exemplo da Lei nº 10.861/2004 – SINAES e Lei nº 13.709/2018 – LGPD), decretos (com destaque para os Decretos nº 9.235/2017 e nº 12.456/2025), portarias e notas técnicas do MEC e do INEP, além de manuais, relatórios e comunicados oficiais relacionados ao e-MEC, aos instrumentos de avaliação do SINAES e às políticas de transformação digital no setor educacional. Em segundo lugar, foram realizadas entrevistas semiestruturadas com atores envolvidos diretamente na condução e/ou no suporte aos processos regulatórios e avaliativos: gestores institucionais, profissionais da área de avaliação (incluindo Procuradores Educacionais Institucionais) e equipes de Tecnologia da Informação responsáveis pela gestão de sistemas acadêmico-regulatórios. As entrevistas buscaram explorar percepções sobre desafios de interoperabilidade, qualidade de dados, riscos e expectativas em relação ao uso de IA nos sistemas de gestão.

Tanto os documentos quanto as transcrições das entrevistas foram submetidos a análise de conteúdo com codificação temática, inspirada na tradição de Bardin, em que se realizaram etapas de leitura flutuante, definição de unidades de registro, categorização e inferência interpretativa. Inicialmente, elaborou-se um quadro de categorias dedutivas, derivadas do referencial teórico-normativo do estudo, abrangendo: (a) LGPD e proteção de dados; (b) explicabilidade e transparência algorítmica; (c) interoperabilidade e governança de dados; e (d) vieses e desigualdades reproduzidas ou amplificadas por sistemas algorítmicos. Em seguida, procedeu-se à identificação de categorias indutivas, emergentes do próprio material empírico, tais como: barreiras operacionais à digitalização e ao uso de IA; lacunas informacionais entre sistemas e bases de dados; e processos de aprendizado organizacional desencadeados por mudanças normativas e tecnológicas.

A codificação foi realizada de forma iterativa, com sucessivos ciclos de refinamento das categorias à luz do diálogo entre o material empírico, a literatura especializada e o marco regulatório da educação superior. A triangulação entre fontes (documentos normativos, materiais técnicos e entrevistas) e entre perspectivas analíticas (político-normativa, organizacional e sociotécnica) buscou fortalecer a validade interpretativa do estudo, em consonância com a compreensão de avaliação como processo ético-político e formativo (DIAS SOBRINHO, 2008) e com os referenciais internacionais de garantia da qualidade (ENQA, 2015). Ao longo do processo analítico, foram registradas decisões de inclusão/exclusão de códigos, bem como ambiguidades e tensões interpretativas, compondo uma trilha de auditoria que reforça a transparência metodológica e oferece subsídios para futuras replicações ou aprofundamentos da pesquisa.

4. Desenvolvimento do tema e resultados

4.1 Mapeamento operacional do e-MEC e oportunidades de uso de IA

A análise dos fluxos e artefatos do e-MEC evidenciou um conjunto de macroprocessos particularmente sensíveis à automação inteligente. Na etapa de triagem e checagem documental, que compreende verificações de integridade, presença de anexos obrigatórios e validação de metadados, observou-se elevada incidência de retrabalho, decorrente de inconsistências formais e da heterogeneidade dos sistemas acadêmicos utilizados pelas IES. Nesse ponto, a simulação de rotinas baseadas em visão computacional combinada a regras híbridas (modelos de aprendizado de máquina associados a verificações determinísticas) mostrou potencial para cruzar declarações das IES com documentos comprobatórios, sinalizar lacunas documentais e priorizar dossiês por grau de criticidade. Os resultados sugerem ganhos relevantes em termos de redução de tempos médios de análise, padronização de verificações e diminuição de erros de natureza procedimental, desde que apoiados por políticas claras de tratamento de dados e trilhas de auditoria, em conformidade com a LGPD.

Na etapa subsequente, de roteamento e análise de mérito, o estudo identificou oportunidades para o uso de algoritmos de classificação temática capazes de inferir, a partir do conteúdo da demanda, seu tipo predominante (autorização, reconhecimento/renovação, mudança de endereço, ampliação de vagas, credenciamento para EAD, entre outros). A simulação de modelos dessa natureza indicou que o roteamento inteligente pode apoiar a alocação de processos em equipes com expertise específica, bem como sugerir matrizes de verificação adequadas a cada tipo de pleito. Em cenários controlados, essa lógica produziu maior consistência entre casos semelhantes e contribuiu para reduzir assimetrias de tratamento entre IES, além de comprimir o intervalo entre submissão e despacho, o que reforça a relevância de abordagens baseadas em evidências para a gestão de prazos e filas regulatórias.

Outra frente identificada diz respeito ao atendimento regulatório assistido. A partir do mapeamento de dúvidas recorrentes das IES e das principais causas de indeferimento ou diligência, foram simulados protótipos de chatbots regulatórios treinados em bases normativas (leis, decretos, portarias, manuais do INEP/MEC), com respostas versionadas e acompanhadas de referências explícitas às fontes. Os testes indicaram que tais ferramentas tendem a reduzir a assimetria informacional entre MEC/INEP e instituições, oferecendo orientação padronizada sobre requisitos documentais e procedimentos, o que, em tese, poderia diminuir o volume de submissões incompletas ou inadequadas. Ao mesmo tempo, os resultados reforçam a necessidade de supervisão humana qualificada e de mecanismos de atualização contínua desses assistentes, sob pena de cristalizar interpretações normativas ultrapassadas.

4.2 Analytics explicável e predição de risco no SINAES

No âmbito do SINAES, a pesquisa concentrou-se na exploração de uma camada preditiva aplicada a séries históricas de indicadores (CPC, IGC, ENADE, IDD), combinadas a informações sobre corpo docente, infraestrutura, organização didático-pedagógica e variáveis contextuais (perfil socioeconômico discente, localização geográfica, natureza jurídica da IES, entre outras). A construção de modelos de risco buscou estimar a probabilidade de deterioração de resultados em horizontes temporais de médio prazo, permitindo a identificação antecipada de cursos e instituições em situação potencialmente crítica.

Os experimentos com técnicas de explicabilidade (como métodos tipo SHAP) mostraram que é possível destacar, para cada previsão, quais variáveis contribuíram de forma mais relevante para o aumento ou redução do risco estimado. Essa explicabilidade, quando acoplada a painéis de decisão (dashboards) voltados às equipes de avaliação e supervisão, tem potencial para apoiar a priorização de visitas in loco, a definição de

planos de melhoria e a orientação de ações indutivas, em sintonia com a lógica do closing the loop adotada em sistemas internacionais de garantia da qualidade.

Um exemplo sintético recorrente na simulação foi o de cursos com queda consecutiva de desempenho em avaliações externas, combinada a altas taxas de evasão e rotatividade de coordenação de curso. Nessas situações, os modelos tendiam a acionar um “alerta vermelho”, sugerindo inspeção documental mais aprofundada e eventual priorização para avaliação in loco. Confirmadas, em análise qualitativa, fragilidades em aspectos como práticas pedagógicas, acompanhamento discente ou gestão acadêmica, os resultados apontavam para a pertinência de ações indutivas específicas (formação docente, revisão de PPC, políticas de permanência), em diálogo com parâmetros como experiência discente (OfS/NSS) e trajetória acadêmica e desfechos de egressos (TEQSA/QILT). Tal desenho reforça a ideia de que analytics explicável não substitui o julgamento profissional, mas pode qualificá-lo ao evidenciar padrões e hipóteses de forma transparente.

4.3 Parâmetros internacionais adaptados ao contexto brasileiro

A análise comparativa de referenciais de garantia da qualidade evidenciou um conjunto de dimensões recorrentes que podem ser traduzidas em parâmetros de sucesso para o uso de IA na avaliação da educação superior no Brasil. A experiência do OfS/NSS, no Reino Unido, destaca a satisfação e a experiência do estudante como eixo estruturante, incorporando percepções sobre qualidade do ensino, avaliação, apoio acadêmico, recursos e voz discente. Já o ecossistema TEQSA/QILT, na Austrália, opera com indicadores que acompanham progressão, retenção, conclusão e empregabilidade, incluindo a perspectiva de empregadores e egressos. A MSCHE, nos Estados Unidos, enfatiza evidências de aprendizagem e ciclos de melhoria contínua, enquanto os ESG/ENQA-EQAR, na Europa, consolidam a centralidade da aprendizagem centrada no estudante, da informação pública fidedigna e da participação de múltiplos atores na governança da qualidade.

A partir desses referenciais, o estudo derivou cinco eixos de metas e indicadores-chave de desempenho (KPIs) a serem considerados em iniciativas de uso de IA no SINAES: (a) experiência e satisfação discente; (b) progressão, retenção e conclusão; (c) empregabilidade e renda de egressos; (d) evidências de aprendizagem e desenvolvimento de competências; e (e) transparência pública e inteligibilidade dos resultados para a sociedade. Os resultados indicam que a incorporação desses eixos ao desenho de modelos preditivos e dashboards regulatórios pode contribuir para deslocar o foco de uma visão estritamente classificatória da avaliação para uma perspectiva mais formativa e multidimensional, em sintonia com o projeto formativo nacional. Ao mesmo tempo, a pesquisa reforça a necessidade de uma adaptação crítica desses parâmetros, evitando importações mecânicas de modelos estrangeiros que desconsiderem desigualdades regionais, heterogeneidade institucional e finalidades públicas da educação superior.

4.4 Dados como infraestrutura pública para a avaliação e a regulação

Os achados empíricos relacionados à infraestrutura de dados apontam que a principal limitação para o uso responsável de IA na avaliação reside menos na ausência de tecnologias e mais na fragmentação e na qualidade desigual dos bancos de dados disponíveis. A literatura de dados e infraestruturas destaca que análises robustas dependem de dicionários de dados padronizados, metadados ricos, versionamento, documentação de linhagem e políticas de acesso claramente estabelecidas, elementos que ainda se apresentam de forma assimétrica no ecossistema da educação superior brasileira.

No material analisado, foram identificados desafios relacionados à ausência de identificadores comuns para cursos, IES e eventos avaliativos em diferentes sistemas, à duplicidade de cadastros e à dificuldade de rastrear transformações aplicadas aos dados ao longo de seu ciclo de vida. Esses problemas impactam diretamente a confiabilidade de modelos preditivos, a comparabilidade de indicadores e a possibilidade de auditoria independente dos resultados. A pesquisa indica que tratar dados como infraestrutura pública – e não como subproduto administrativo – implica investir em catálogos de dados, padrões abertos, integração entre bases (censo, ENADE, e-MEC, sistemas internos das IES) e arranjos institucionais de governança que distribuam responsabilidades por produção, curadoria e uso, em consonância com a LGPD e com as orientações da UNESCO para projetos de IA em políticas públicas de educação.

4.5 EAD, modernização regulatória e papel da IA

A revisão do marco regulatório da Educação a Distância, consolidada no Decreto nº 12.456/2025, foi analisada à luz da trajetória histórica da EAD no Brasil, marcada por ciclos de expansão, regulação e busca de qualificação da oferta. A atualização normativa enfatiza a necessidade de revisão de processos regulatórios, de atualização de instrumentos de avaliação e de modernização dos sistemas de informação, com vistas a acompanhar a diversificação de modelos pedagógicos, a intensificação do uso de tecnologias digitais e a ampliação da oferta em regiões antes pouco atendidas.

Nesse cenário, os resultados sugerem que a IA pode atuar como alavanca de simplificação e qualificação da regulação da EAD, por meio de interfaces mais acessíveis e responsivas para as IES, análises mais finas de indicadores de qualidade (incluindo engajamento em ambientes virtuais, permanência em disciplinas online, trajetórias híbridas) e mecanismos de detecção precoce de fragilidades em polos, cursos e instituições. Ao mesmo tempo, a pesquisa alerta para o risco de que modelos algorítmicos, alimentados por dados historicamente marcados por desigualdades, acabem por reproduzir ou intensificar assimetrias regionais e institucionais, se não forem acompanhados de parâmetros explícitos de equidade, mecanismos de correção de vieses e instâncias de participação de usuários e afetados nos processos decisórios.

4.6 Síntese dos resultados empíricos

A partir das análises conduzidas, é possível sintetizar os principais resultados em cinco eixos:

e-MEC e fluxos regulatórios – Em cenários simulados, o uso de IA em triagem e checagem documental mostrou potencial para encurtar prazos e reduzir retrabalho, ao mesmo tempo em que qualifica a padronização de análises.

SINAES e gestão de risco – Modelos de predição de risco, quando articulados a painéis explicáveis, apoiaram a priorização da supervisão e a identificação de cursos/instituições que requerem maior atenção, reforçando o caráter indutivo/fomativo da avaliação.

Parâmetros internacionais – A adaptação de referenciais como ESG/ENQA, MSCHE, OfS/NSS e TEQSA/QILT favoreceu uma leitura multidimensional dos indicadores, ampliando a centralidade da experiência discente, da trajetória acadêmica e da empregabilidade.

Accountability e transparência – Dashboards explicáveis, combinados a registros sistemáticos de decisões e trilhas de auditoria, reforçaram a accountability interna e

externa, tornando mais claro o encadeamento entre dados, análises e decisões regulatórias.

Gargalos estruturais – Os principais obstáculos identificados concentraram-se na qualidade e interoperabilidade dos dados e na capacitação das equipes, tanto nas instâncias governamentais quanto nas IES, o que reforça que a transformação é simultaneamente tecnológica, organizacional e formativa.

4.7 Proposta de framework de governança algorítmica e implicações de política

Com base nos achados empíricos e no referencial teórico, o estudo propõe um framework de governança algorítmica estruturado em seis eixos interdependentes:

Legalidade digital e LGPD – Definição de bases legais claras para o tratamento de dados; explicitação de finalidade, minimização e segurança; respeito aos direitos dos titulares; e realização de Relatórios de Impacto à Proteção de Dados em projetos de alto risco, especialmente quando envolvem decisões automatizadas com efeitos relevantes sobre IES e estudantes.

Transparência e prestação de contas – Documentação técnica acessível (inclusive em linguagem cidadã), logs de funcionamento, trilhas de auditoria, requisitos de explicabilidade e canais formais de contestação e revisão de decisões mediadas por IA.

Ciclo de vida de modelos – Procedimentos de validação, testes de vieses, auditorias independentes, re-treino periódico e versionamento de modelos, de modo a evitar desatualização e degradação de desempenho, em sintonia com recomendações internacionais para sistemas de alto impacto.

Qualidade e interoperabilidade de dados – Adoção de padrões abertos, catálogos de dados, registros de linhagem e políticas de acesso que privilegiem a integridade, a segurança e a responsabilização por usos indevidos ou não autorizados.

Participação e controle social – Mecanismos de envolvimento de IES, estudantes, especialistas e sociedade civil em consultas públicas, comissões e avaliações de impacto algorítmico, reforçando legitimidade e confiança social nos sistemas.

Capacitação contínua – Organização de trilhas formativas e elaboração de guias práticos para equipes do MEC, INEP e IES, de forma a promover apropriação crítica das ferramentas e reduzir a dependência de soluções “caixa-preta”.

Como implicação de política, os resultados indicam que a adoção de IA no campo regulatório educacional deve ser incremental e baseada em evidências, por meio de programas de pilotos controlados, com metas e indicadores de sucesso previamente definidos, relatórios públicos e ajustes iterativos conforme os resultados observados. Recomenda-se que a expansão de soluções algorítmicas esteja condicionada à existência de infraestrutura de dados adequada, arranjos de governança claros e instrumentos normativos (portarias, guias, notas técnicas) que explicitem critérios de explicabilidade, requisitos de documentação e protocolos de auditoria. Tais medidas contribuem para que a IA, em vez de deslocar a finalidade pública da avaliação, se converta em instrumento de fortalecimento da qualidade, da equidade e da transparência na educação superior brasileira.

5. Considerações Finais

Os resultados deste estudo permitem afirmar que a Inteligência Artificial, quando inserida em um arranjo consistente de governança algorítmica, tem potencial concreto para reduzir prazos no e-MEC, qualificar análises regulatórias e priorizar supervisões por risco no âmbito do SINAES, com ganhos em termos de qualidade, transparência e previsibilidade das decisões. A simulação de usos de IA em triagens documentais, roteamento inteligente de processos e analytics explicável evidenciou que tais tecnologias podem fortalecer a função formativa da avaliação, antecipando fragilidades e orientando ações indutivas, desde que mantida a centralidade do julgamento humano qualificado e das finalidades públicas da educação superior.

Ao mesmo tempo, a pesquisa reforça que a IA não é solução neutra nem autossuficiente: sua adoção depende de condições técnico-institucionais e ético-jurídicas que envolvem, necessariamente, o trabalho articulado entre equipes de dados/TI, instâncias jurídicas/LGPD, setores de avaliação (INEP e IES) e instâncias de gestão (MEC e instituições). Essa cooperação intersetorial é condição para mitigar vieses, assegurar explicabilidade, garantir proteção de dados pessoais e consolidar processos de melhoria contínua. Sem investimentos em qualidade e interoperabilidade de dados, em trilhas de capacitação e em mecanismos de participação e controle social, a IA tende a amplificar assimetrias já existentes, em vez de corrigi-las.

A adaptação crítica de referenciais internacionais, como OfS/NSS (Reino Unido), TEQSA/QILT (Austrália), MSCHE (Estados Unidos) e ESG/ENQA-EQAR (Europa), mostrou-se especialmente fecunda para qualificar a leitura dos indicadores nacionais e para reforçar a prestação de contas à sociedade. Ao incorporar dimensões como experiência discente, progressão–retenção–conclusão, empregabilidade e renda de egressos, evidências de aprendizagem e transparência pública, esses referenciais contribuem para deslocar o foco de uma lógica meramente classificatória para uma compreensão multidimensional da qualidade, em sintonia com a perspectiva ético-política de avaliação defendida pela literatura crítica brasileira.

Como agenda de políticas e pesquisa, os achados apontam para a necessidade de consolidar e operacionalizar o framework de governança algorítmica proposto, por meio de: (a) projetos-piloto controlados em fluxos específicos do e-MEC e do SINAES, com métricas de processo e de resultado claramente definidas; (b) publicação sistemática de relatórios de desempenho e de avaliações de impacto, favorecendo o escrutínio público e a aprendizagem institucional; (c) instituição de trilhas de capacitação contínua para equipes do MEC, INEP e IES, voltadas à apropriação crítica de ferramentas de IA; e (d) fortalecimento de uma visão de dados como infraestrutura pública, articulando padronização, interoperabilidade e proteção de direitos em conformidade com a LGPD e com diretrizes internacionais de ética da IA.

Por fim, reconhece-se que este estudo, de natureza qualitativa e centrado em casos múltiplos, possui limitações quanto à generalização estatística de seus achados. Em contrapartida, oferece subsídios analíticos e normativos relevantes para o desenho de políticas de transformação digital na educação superior, sugerindo que a questão central não é se o MEC e o SINAES utilizarão ou não IA, mas como o farão: se por meio de soluções opacas e tecnocráticas, ou sob um regime de governança algorítmica comprometido com qualidade, equidade, transparência e responsabilidade pública.

6. Referências

ALVES, Lucineia. Educação a distância: conceitos e história no Brasil e no mundo. Revista Brasileira de Aprendizagem Aberta e a Distância, v. 10, 2011. Disponível em: <https://seer.abed.net.br/RBAAD/article/view/235>

. Acesso em: 9 out. 2024.

BRASIL. Lei nº 10.861, de 14 de abril de 2004. Institui o Sistema Nacional de Avaliação da Educação Superior – SINAES. Diário Oficial da União, Brasília, DF, 15 abr. 2004.

BRASIL. 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.

BRASIL. Decreto nº 12.456, de 19 de maio de 2025. Dispõe sobre a oferta de educação a distância por Instituições de Ensino Superior e altera o Decreto nº 9.235/2017. Diário Oficial da União, Brasília, DF, 20 maio 2025.

BRASIL. Ministério da Educação. Plano de Transformação Digital do MEC 2025–2026. Brasília, DF: MEC, 2025.

DIAS SOBRINHO, José. Avaliação da educação superior: desafios e perspectivas. EccoS – Revista Científica, n. 17, p. 11–28, 2008.

ENQA – EUROPEAN ASSOCIATION FOR QUALITY ASSURANCE IN HIGHER EDUCATION. Standards and Guidelines for Quality Assurance in the European Higher Education Area (ESG). Brussels: ENQA, 2015.

FLORIDI, Luciano; COWLS, Josh. A unified framework of five principles for AI in society. Harvard Data Science Review, v. 1, n. 1, 2019.

KITCHIN, Rob. The Data Revolution: A Critical Analysis of Big Data, Open Data and Data Infrastructures. 2. ed. London: Sage, 2022.

MSCHE – MIDDLE STATES COMMISSION ON HIGHER EDUCATION. Standards for Accreditation and Requirements of Affiliation. Philadelphia: MSCHE, 2014. (Rev. 2023).

OFFICE FOR STUDENTS (OfS). National Student Survey (NSS): Methodology and Results. London: OfS, 2024.

QILT – QUALITY INDICATORS FOR LEARNING AND TEACHING. Graduate Outcomes Survey (GOS): National Report. Canberra: Australian Government, 2024.

TEQSA – TERTIARY EDUCATION QUALITY AND STANDARDS AGENCY. Higher Education Standards Framework (Threshold Standards) 2021. Canberra: TEQSA, 2021.

UNESCO. Recommendation on the Ethics of Artificial Intelligence. Paris: UNESCO, 2021.