

Ferramentas No-Code/Low-Code aplicadas ao desenvolvimento de Inteligência Artificial e de *Machine Learning*: Uma revisão sistemática da literatura

Jonas da Silva Rabelo¹, Otávio Noura Teixeira¹ (Orientador), Ingrid N. Mendes²
(Coorientadora)

¹Faculdade de Engenharia de Computação (FECOMP), Campus Universitário de Tucuruí (CAMTUC), Universidade Federal do Pará (UFPA)

²Programa de Pós-Graduação em Engenharia Elétrica – Universidade Federal do Pará (UFPA) Belém – Brasil

{jonasrabelo.contato, onoura, nami128}@gmail.com

Resumo. *Este trabalho apresenta uma Revisão Sistemática da Literatura sobre o uso de Ferramentas No-Code e Low-Code (LC/NC) no desenvolvimento de soluções de Inteligência Artificial e Machine Learning. O objetivo é mapear e analisar as plataformas utilizadas, identificando características, benefícios, limitações e tendências. A revisão seguiu as diretrizes de Kitchenham e considerou estudos publicados entre janeiro de 2020 e agosto de 2025 nas bases ACM Digital Library, IEEE Xplore, ScienceDirect, Scopus e SpringerLink. Após os critérios de inclusão e exclusão, 67 estudos foram selecionados. Os resultados mostram que as ferramentas LC/NC ampliam o acesso ao desenvolvimento de IA e ML, especialmente para usuários sem formação técnica avançada. Contudo, foram identificadas limitações relacionadas à flexibilidade, personalização e dependência de ecossistemas, além da predominância de estudos descritivos e de viabilidade.*

Abstract: *This study presents a Systematic Literature Review on the use of No-Code and Low-Code (LC/NC) tools in the development of Artificial Intelligence and Machine Learning solutions. The objective is to map and analyze the platforms employed in this context, identifying their main characteristics, benefits, limitations, and usage trends. The review followed Kitchenham's guidelines and considered studies published between January 2020 and August 2025 from the ACM Digital Library, IEEE Xplore, ScienceDirect, Scopus, and SpringerLink databases. After applying the inclusion and exclusion criteria, 67 studies were selected. The results indicate that LC/NC tools broaden access to AI and ML development, particularly for users without advanced technical backgrounds. However, limitations related to flexibility, advanced customization, and ecosystem dependency were identified, along with a predominance of descriptive and feasibility studies.*

Palavras-chave: *Low-Code; No-Code; Artificial Intelligence; Aprendizado de Máquina; Revisão Sistemática;*

Keywords: *Low-Code; No-Code; Inteligência Artificial; Machine Learning; Systematic Review.*

1. Introdução

A Inteligência Artificial (IA) e o *Machine Learning* (ML) têm desempenhado um papel importante na transformação digital de diversos setores, como saúde, indústria e serviços. Embora as soluções de IA/ML sejam amplamente utilizadas, seu desenvolvimento requer conhecimento especializado em programação, estatística,

engenharia e modelagem de dados, envolvendo etapas que exigem raciocínio matemático complexo e proficiência em técnicas computacionais [Graaff *et al.*, 2023]. Além disso, muitos especialistas de área - como profissionais de saúde, recursos humanos, logística e administração - possuem um entendimento limitado sobre programação, o que reduz a capacidade de usar IA de maneira autônoma [Hamdan *et al.*, 2023].

No cenário atual, as plataformas LC/NC estão se destacando por tornar a IA e o ML mais acessíveis, disponibilizando interfaces intuitivas, automações e componentes já configurados que simplificam bastante a complexidade técnica. Pesquisas indicam que ferramentas *no-code* podem oferecer desempenho competitivo em aplicações práticas: por exemplo, modelos desenvolvidos em ambientes *no-code* mostraram capacidade de classificar fraturas de clavícula em radiografias de forma eficaz, conforme demonstrado em estudos aplicados à saúde e radiologia [Dasegowda *et al.*, 2024]. Além disso, o AirOps foi empregado para extração de informação de documentos regulatórios em farmacologia pediátrica, utilizando modelos de linguagem de grande escala (LLMs) [Zaoui *et al.*, 2025]. Outras plataformas identificadas nos estudos analisados, como Orange Data Mining para diagnósticos neurológicos e oftalmológicos [Abishek *et al.*, 2025; Shin *et al.*, 2024; Davidraj *et al.*, 2025], MANILA para *benchmarking* de modelos e *fairness* [D'Aloisio, 2025], e WEKA para química computacional e toxicologia [Diaz *et al.*, 2024 e 2025], também demonstram que as ferramentas LC/NC podem ser aplicadas em contextos diversificados, incluindo medicina, química, indústria e bioinformática.

Apesar deste progresso, atualmente, a produção acadêmica que trata de LC/NC para o desenvolvimento de IA/ML ainda está fragmentada e heterogênea. Estudos indicam uma falta de padronização conceitual e inconsistências quanto a definições de plataformas “*no-code*”, “*low-code*” e ferramentas de AutoML, frequentemente classificadas de forma equivocada na literatura [Li e Wu, 2022]. Outras revisões ressaltam que essa ambiguidade conceitual contribui para interpretações divergentes acerca do papel dessas ferramentas e do nível de automação que realmente oferecem [Sufi, 2023]. Adicionalmente, estudos comparativos mostram uma ampla variação em maturidade, integração, escopo funcional e suporte ao ciclo completo de ML entre diferentes plataformas LC/NC, impossibilitando análises sistemáticas e a formação de conclusões gerais sobre o seu uso [Raghavendran e Elragal, 2023].

Assim sendo, esta Revisão Sistemática da Literatura tem como objetivo principal mapear, classificar e analisar estudos que empregam ferramentas LC/NC aplicadas ao desenvolvimento de aplicações de IA/ML. Diferentemente de estudos anteriores que abordam aspectos isolados [Li e Wu, 2022; Sufi, 2023] ou plataformas específicas [Raghavendran e Elragal, 2023], este trabalho apresenta o primeiro mapeamento sistemático abrangente do ecossistema LC/NC para IA/ML, analisando 67 estudos publicados entre 2020 e 2025 nas principais bases de dados acadêmicas. A revisão contribui para a área ao: (i) categorizar 91 ferramentas em três grupos (comerciais, open-source e acadêmicas); (ii) identificar tendências emergentes como integração com IA generativa (34% dos estudos recentes) e especialização por domínio; (iii) mapear domínios de aplicação, evidenciando predominância da saúde (30% dos estudos); e (iv) revelar lacunas metodológicas, incluindo escassez de estudos comparativos rigorosos (apenas 6% dos trabalhos), apontando direções para pesquisas futuras.

2. Fundamentação Teórica

Os termos *No-Code* e *Low-Code* têm sido amplamente empregados na literatura recente para descrever abordagens que visam reduzir a complexidade do desenvolvimento de aplicações baseadas em Inteligência Artificial e *Machine Learning*. Entretanto, observa-se que não há uma definição conceitual única e consolidada para esses termos, sendo comum a utilização de definições operacionais baseadas em características funcionais das plataformas [Sufi, 2023; Li e Wu, 2022].

Estudos de análises comparativas indicam que plataformas *No-Code* e *Low-Code* compartilham o objetivo de abstrair o código-fonte e automatizar etapas do ciclo de desenvolvimento de modelos de aprendizado de máquina, diferenciando-se principalmente pelo grau de intervenção técnica exigida do usuário. Em uma revisão prática sobre algoritmos em ambientes *No-Code* e *Low-Code*, os autores destacam que essas plataformas se caracterizam pelo uso de interfaces visuais, componentes pré-configurados e fluxos guiados, permitindo que usuários concentrem-se na definição do problema e na interpretação dos resultados, em vez da implementação algorítmica propriamente dita [Sufi, 2023].

2.1 Contexto e Evolução das Plataformas LC/NC

O desenvolvimento de plataformas *No-Code* e *Low-Code* insere-se em um movimento mais amplo de democratização tecnológica, no qual se busca reduzir barreiras de entrada para o desenvolvimento de soluções de software. Esse fenômeno tem sido particularmente relevante no contexto de Inteligência Artificial e *Machine Learning*, áreas tradicionalmente caracterizadas por elevada complexidade técnica e dependência de conhecimento especializado em matemática, estatística e programação [Graaff *et al.*, 2023].

O conceito de *citizen developer* — profissional de domínio capaz de criar soluções tecnológicas sem formação técnica aprofundada — tornou-se central neste debate. Estudos indicam que especialistas em áreas como saúde, engenharia, finanças e administração possuem profundo conhecimento do problema de negócio, mas frequentemente carecem de habilidades de programação para traduzi-lo em soluções de IA/ML [Hamdan *et al.*, 2023]. As plataformas LC/NC emergem como resposta a essa lacuna, permitindo que o conhecimento de domínio seja diretamente aplicado na construção de modelos preditivos.

2.1.1 Abstração e Automação como Estratégias Fundamentais

A principal estratégia adotada por essas plataformas consiste na abstração progressiva da complexidade técnica. Enquanto o desenvolvimento tradicional de ML exige domínio de bibliotecas como TensorFlow, PyTorch ou scikit-learn, codificação de *pipelines* de pré-processamento, seleção manual de algoritmos e ajuste fino de hiperparâmetros, as plataformas LC/NC encapsulam essas etapas em interfaces visuais, componentes pré-configurados e mecanismos de automação [Raghavendran e Elragal, 2023].

Essa abstração manifesta-se em diferentes níveis. No nível mais básico, plataformas *No-Code* eliminam completamente a necessidade de escrita de código, substituindo-a por interações visuais do tipo *drag-and-drop*, formulários configuráveis e

assistentes guiados. Em um nível intermediário, plataformas *Low-Code* mantêm a programação como recurso opcional ou complementar, permitindo que usuários avançados estendam funcionalidades quando necessário, enquanto usuários iniciantes operem exclusivamente por meio de interfaces gráficas.

2.1.2 O Papel do AutoML no Ecossistema LC/NC

O AutoML (*Automated Machine Learning*) representa um componente tecnológico fundamental nesse ecossistema, automatizando tarefas como engenharia de características (*feature engineering*), seleção de modelos, otimização de hiperparâmetros e validação cruzada. Embora nem todas as plataformas LC/NC incorporem AutoML, e nem toda solução de AutoML seja necessariamente *No-Code* ou *Low-Code*, observa-se uma convergência crescente entre essas abordagens [Sufi, 2023].

Essa convergência explica-se pela complementaridade funcional: enquanto o AutoML foca na automação algorítmica do processo de construção de modelos, as plataformas LC/NC concentram-se na simplificação da interação humano-computador e na redução da barreira de entrada técnica. Plataformas como Google AutoML e Microsoft Azure ML Studio exemplificam essa integração, oferecendo recursos de AutoML embutidos em interfaces *No-Code/Low-Code* [Kok *et al.*, 2024].

Entretanto, é importante distinguir que AutoML refere-se primariamente a técnicas algorítmicas de otimização automatizada, podendo ser implementado tanto em ambientes que exigem programação quanto em plataformas LC/NC. Essa distinção conceitual é relevante para evitar a sobreposição terminológica identificada como limitação na literatura [Li e Wu, 2022; Sufi, 2023].

2.1.3 Democratização da IA e Implicações para Diferentes Perfis de Usuários

A democratização da Inteligência Artificial por meio de plataformas LC/NC implica em mudanças no perfil dos desenvolvedores de soluções de IA/ML. Tradicionalmente, o desenvolvimento de modelos preditivos concentrava-se em cientistas de dados, engenheiros de *machine learning* e pesquisadores com formação avançada em áreas técnicas. As plataformas LC/NC ampliam esse espectro, permitindo que profissionais de diferentes formações participem do processo de construção de modelos.

Estudos empíricos indicam que médicos, enfermeiros, administradores, engenheiros civis e outros especialistas de domínio têm utilizado plataformas *No-Code* para desenvolver soluções de diagnóstico médico, previsão de demanda, manutenção preditiva e otimização de processos, sem necessidade de conhecimento aprofundado em programação [Hamamoto *et al.*, 2024; Lee *et al.*, 2024; Nguyen *et al.*, 2023].

Essa democratização, contudo, não implica na substituição integral de profissionais técnicos. A literatura sugere um modelo de complementaridade, no qual plataformas LC/NC aceleram a prototipagem e validação inicial de hipóteses, enquanto especialistas técnicos atuam em fases subsequentes de otimização, customização avançada e implantação em ambientes de produção críticos [Raghavendran e Elragal, 2023].

2.2 Definição Operacional Adotada neste Trabalho

Diante da diversidade conceitual observada na literatura, este trabalho adota um critério operacional explícito para distinguir plataformas *No-Code* e *Low-Code*, conforme recomendado em diretrizes para revisões sistemáticas [Kitchenham, 2012].

Plataformas *No-Code* são aquelas que não exigem escrita de código por parte do usuário final, permitindo o desenvolvimento de aplicações exclusivamente por meio de interfaces gráficas, interações do tipo *drag-and-drop*, formulários configuráveis e assistentes guiados. Essas plataformas eliminam completamente a necessidade de conhecimento de programação, possibilitando que especialistas de domínio - como profissionais de saúde, engenharia, finanças e administração - desenvolvam soluções de IA/ML aplicando diretamente seu conhecimento do problema de negócio [Hamdan *et al.*, 2023].

Plataformas *Low-Code* referem-se às soluções que reduzem substancialmente a necessidade de programação, mas permitem ou pressupõem algum nível de interação com código para customização, integração ou extensão de funcionalidades. Essas plataformas mantêm a programação como recurso opcional ou complementar, oferecendo maior equilíbrio entre usabilidade e capacidade de customização técnica [Li e Wu, 2022; Montes-Sánchez *et al.*, 2025].

Adicionalmente, foi adotada a categoria *Low-Code/No-Code* (Híbrida) para representar plataformas que suportam ambos os modos de operação, permitindo que usuários escolham entre desenvolvimento puramente visual ou com intervenção programática conforme suas necessidades e competências técnicas. Essa abordagem híbrida reflete a realidade de muitas plataformas comerciais modernas que buscam atender simultaneamente *citizen developers* e desenvolvedores técnicos [Raghavendran e Elragal, 2023].

Esse critério de classificação foi adotado com o objetivo de garantir consistência, transparência e reprodutibilidade na análise das plataformas identificadas nesta revisão, reconhecendo que a fronteira entre essas categorias nem sempre é absolutamente delimitada na prática, mas constitui um espectro contínuo de níveis de abstração.

3. Metodologia

A presente Revisão Sistemática da Literatura (RSL) foi conduzida com base nas diretrizes propostas por Kitchenham [Kitchenham, 2012], que estruturam o processo em três fases principais: planejamento, condução e relato. O protocolo previamente elaborado orientou rigorosamente cada etapa metodológica, garantindo transparência, reprodutibilidade e alinhamento às questões de pesquisa. As seções a seguir descrevem detalhadamente os procedimentos adotados. As etapas da RSL foram: (1) definição das questões de pesquisa; (2) construção das strings; (3) busca nas bases; (4) triagem; (5) extração e síntese.

De início, foram definidas as questões de pesquisas (QP) para o desenvolvimento da RSL (Passo 1), que são:

- **QP1.** “Quais são as ferramentas LC/NC utilizadas no desenvolvimento de soluções em Inteligência Artificial e/ou *Machine Learning*?”
- **QP2.** “Quais são as principais características dessas ferramentas (ex. área de aplicação; tarefas: classificação, predição, *clustering*; limitações e potencialidades; etc)?”

- **QP3.** “Quais os benefícios do uso de ferramentas LC/NC em comparação a programação tradicional?”
- **QP4.** “Quais aspectos das plataformas LC/NC mais contribuem para o desenvolvimento de soluções de Inteligência Artificial e *Machine Learning*?”.

Dessas QPs foram extraídas as *strings* de buscas, que contêm as palavras-chaves do estudo desta RSL (passo 2):

("no-code" OR "low-code") AND “artificial intelligence”
("no-code" OR "low-code") AND “machine learning”

A estratégia de busca priorizou o uso de termos amplos (“artificial intelligence” e “machine learning”) em combinação com “no-code” e “low-code”, com o objetivo de capturar estudos que abordassem plataformas LC/NC aplicadas ao desenvolvimento de soluções inteligentes de forma abrangente. Optou-se por não incluir termos específicos de subáreas, como “deep learning”, “computer vision” ou “natural language processing”, pois tais termos representam subconjuntos de IA/ML e poderiam introduzir viés temático ou restringir indevidamente a recuperação de estudos que utilizam essas técnicas sem explicitá-las no título, resumo ou palavras-chave. Assim, a definição das *strings* buscou maximizar a coerência com as questões de pesquisa e garantir abrangência conceitual, mantendo alinhamento com o escopo da revisão, garantindo uma cobertura abrangente das bases de dados definidas no Passo 3: ACM Digital Library, IEEE Xplore, ScienceDirect, Scopus e SpringerLink.

Após a aplicação dos critérios de inclusão e exclusão (Passo 4) definidos no protocolo desta RSL (tabela 1), os estudos recuperados por meio das *strings* de busca foram gradualmente filtrados.

Quadro 1. Critérios de inclusão e exclusão


Critérios de Inclusão (CI)	Critérios de Exclusão (CE)
CI-01. Publicações entre 2020 e 2025.	CE-01. Estudos que não abordem diretamente ferramentas LC/NC para IA/ML.
CI-02. Artigos em inglês ou português.	CE-02. Artigos sem acesso ao texto completo.
CI-03. Estudos que abordem ferramentas LC/NC aplicadas ao desenvolvimento de aplicações em IA e/ou <i>Machine Learning</i> .	CE-03. Estudos que tratam apenas de AutoML, sem conexão com plataformas LC/NC.
CI-04. Capítulos de livro, artigos revisados por pares, revistas e conferências.	CE-04. Estudos que apenas mencionam LC/NC como parte de um processo maior, sem foco direto em seu uso ou análise.

Fonte: Elaborado pelo autor (2026)

O recorte temporal a partir de 2020 foi definido com o objetivo de capturar a fase mais recente de consolidação das plataformas LC/NC aplicadas à IA/ML, período no qual se observa maior maturidade tecnológica e expansão de aplicações práticas, conforme evidenciado nos estudos analisados. Além disso, o intervalo selecionado permite contemplar as transformações recentes associadas à integração com modelos de IA generativa, cuja adoção se intensifica a partir de 2022.

A Figura 1 apresenta o fluxograma PRISMA [PAGE et al., 2021] do processo de identificação, triagem e inclusão dos estudos.

Figura 1: Fluxograma PRISMA



Fonte: Adaptado de Page et al. (2021)

Os dados extraídos dos estudos incluídos na revisão foram organizados em uma planilha de extração, contendo informações como identificação do estudo, tipo de plataforma *No-Code/Low-Code*, domínio de aplicação, técnicas de IA/ML, benefícios, limitações e evidências apresentadas. A planilha completa de extração de dados encontra-se disponível publicamente no repositório Zenodo [Rabelo, 2026].

As plataformas identificadas nos estudos incluídos foram classificadas de acordo com três aspectos principais: tipo de abordagem (*No-Code* ou *Low-Code*), natureza da plataforma e técnicas de IA/ML suportadas.

Quanto ao tipo de plataforma, adotou-se uma classificação em três categorias: *No-Code*, *Low-Code* e *No-Code / Low-Code (Híbrida)*. Quanto à natureza, as plataformas foram categorizadas como comerciais, open-source ou acadêmicas, levando em conta o modelo de licenciamento, o contexto de desenvolvimento e o grau de maturidade descrito nos estudos analisados. As técnicas de IA/ML suportadas foram

identificadas a partir das tarefas relatadas, como classificação, regressão, *clustering*, AutoML, visão computacional e processamento de linguagem natural.

4. Resultados

4.1 Visão geral dos estudos selecionados

Esta seção expõe os resultados decorrentes da análise dos 67 estudos selecionados. Os trabalhos abordam o uso de ferramentas LC/NC para desenvolvimento de soluções de IA/ML em diferentes domínios de aplicação. Os resultados estão estruturados com base na identificação das ferramentas, domínios e particularidades das plataformas.

4.2 Distribuição temporal dos estudos

A Figura 2 apresenta a distribuição temporal dos estudos. Observa-se um crescimento acentuado a partir de 2023, com pico em 2024. O ano de 2025 apresenta dados parciais (até agosto). O comportamento indica uma tendência de crescimento acelerado do interesse acadêmico no tema.

Figura 2: Artigos por ano




Fonte: Elaborado pelo autor (2026)

4.3 Distribuição dos estudos por continentes

Conforme apresentado na figura 3, a Ásia lidera com 34 estudos, seguida pela Europa (25) e América do Norte (17). Estados Unidos (16), China (9) e Alemanha (8) são os países com maior produção.

Ressalta-se que parte dos estudos analisados apresenta autoria distribuída entre pesquisadores afiliados a instituições de diferentes países. Nesses casos, um mesmo artigo foi associado a mais de um país e, consequentemente, a mais de um continente, o que explica o fato de o total de ocorrências no gráfico ultrapassar o número total de estudos incluídos na revisão.

Figura 3: Artigos por continentes



Fonte: Elaborado pelo autor (2026)

4.4 Ferramentas No-Code e Low-Code identificadas

Foi identificado um conjunto diversificado de ferramentas. Para facilitar a análise e a apresentação dos resultados, as plataformas foram organizadas em três categorias: Plataformas Comerciais Consolidadas (Quadro 1), Plataformas *Open-Source*/Híbridas e Especializadas (Quadro 2) e Plataformas Acadêmicas ou Específicas de Estudo (Quadro 3). Essa categorização permite uma visão estruturada do ecossistema de ferramentas identificadas, considerando o tipo de plataforma, os domínios de aplicação e os estudos nos quais foram utilizadas.

O Quadro 1 apresenta as plataformas *No-Code* e *Low-Code* comerciais consolidadas identificadas nos estudos analisados. Observa-se que essas ferramentas são amplamente utilizadas em diferentes domínios de aplicação, com destaque para saúde, indústria, serviços, negócios e cadeia de suprimentos. De modo geral, essas plataformas oferecem ambientes integrados, interfaces visuais e suporte ao desenvolvimento e à implantação de modelos de IA e ML, sendo frequentemente avaliadas em contextos aplicados e estudos de caso.

Quadro 2. Plataformas Comerciais Consolidadas

Ferramenta	Tipo	Domínios de aplicação	Artigos
Microsoft Power Platform	Low-Code / No-Code	Negócios; Construção civil.; SMEs	[Kok <i>et al.</i> , 2024], [Martinez e Cisterna, 2023], [Sufi, 2023]
Google AutoML (Vertex AI)	Low-Code / No-Code	Negócios, saúde, aplicações gerais	[Kok <i>et al.</i> , 2024], [Raghavendran e Elragal, 2023], [Antonson <i>et al.</i> , 2024], [Sufi, 2023]
Amazon SageMaker	Low-Code / No-Code	Negócios e aplicações corporativas	[Kok <i>et al.</i> , 2024], [Raghavendran e Elragal, 2023]

Google AppSheet / OutSystems / Appian / SetXRM / vf-OS Platform / Aure-BPM	Low-Code / No-Code	Pesquisa científica multidisciplinar	[Sufi, 2023]
Microsoft Azure Machine Learning Studio	Low-Code / No-Code	Farmácia; Transporte; Serviços.	[Singh <i>et al.</i> , 2023], [Sufi, 2023], [Li e Wu, 2022], [Raghavendran e Elragal, 2023]
Microsoft Azure Custom Vision	Low-Code / No-Code	Reconhecimento de comprimidos	[Ashraf <i>et al.</i> , 2024]
No-Code Machine Learning Application / A Visual Programming Paradigm (DL-IDE) / IoT-Pilot / Alpaca ML / Power Automate / Block WiSARD / Cognimates / Deep Scratch / eCraft2Learn / LearningML / Milo / Orange / Personal Image Classifier (PIC) / RapidMiner / Scratch Nodes ML / SnAIp / Gest / Deep Visual	Low-Code / No-Code	Multidomínio (educação, ciência de dados, IA aplicada)	[Li e Wu, 2022]
Mendix	Low-Code	Saúde (predição de câncer de mama)	[Agarwal e Das, 2025], [Sufi, 2023], [Ren <i>et al.</i> , 2022]
Oracle APEX / Oracle ML	Low-Code	Aplicações corporativas e analíticas	[Pastierik, 2024]
Synapse / Databricks	Low-Code	Digitalização organizacional; projetos de negócio	[Raghavendran e Elragal, 2023]
ML-Quadrat / DriotData	Low-Code	Serviços inteligentes	[Li e Wu, 2022], [Moin <i>et al.</i> , 2022]
DEEP:PHI	No-Code	Diagnóstico médico	[Lee <i>et al.</i> , 2024]
LandingLens	No-Code	Odontologia	[Hamdan <i>et al.</i> , 2023; 2025]
ChatGPT-4	No-Code	Oftalmologia	[Choi e Yoo, 2025]
AirOps	No-Code	Saúde (farmacologia pediátrica).	[Zaoui <i>et al.</i> , 2025]
Microsoft Lobe	No-Code	Visão computacional em saúde	[Bhaumik <i>et al.</i> , 2021], [Kling <i>et al.</i> , 2022]
DataRobot	No-Code	Interação humano-IA	[Graaff <i>et al.</i> , 2023]

DEEPCRAFT Studio / Edge Impulse / NanoEdgeAI Studio / Neuton.AI / SenseI AutoML / SensiML	No-Code	Manutenção preditiva; IoT biomédico	[Montes-Sánchez <i>et al.</i> , 2025]
Teachable Machine	No-Code	Diagnóstico médico	[Hamamoto <i>et al.</i> , 2024], [Li e Wu, 2022]
Trinity	No-Code	Dados espaciais complexos.	[Li e Wu, 2022], [Iyer <i>et al.</i> , 2021]
Zauberzeug Learning Loop	No-Code	Agricultura, robótica	[Glahe e Trappe, 2023]
Obviously Ai	No-Code	Cadeia de suprimentos	[Jauhar <i>et al.</i> , 2024]

Fonte: Elaborado pelo autor (2026)

O Quadro 2 reúne plataformas *Open-Source*, híbridas ou especializadas, essas ferramentas caracterizam-se, em sua maioria, por atender a domínios específicos, como saúde, bioinformática, quimioinformática, visão computacional, engenharia e manutenção preditiva. Observa-se também a presença de plataformas com foco em tarefas particulares, como segmentação de imagens, *benchmarking* de modelos, aprendizado por reforço e análise de dados espaciais, refletindo a diversidade funcional dessas soluções.

Quadro 3. Plataformas *Open-Source*/Híbridas e Especializadas

Ferramenta	Tipo	Domínios de aplicação	Artigos
Pyrus	Low-Code / No-Code	Modelagem de dados médicos	[Singh e Margaria, 2024], [Li e Wu, 2022], [Zweihoff e Steffen, 2021]
ADD-Lib	Low-Code / No-Code	Modelagem de dados médicos	[Singh e Margaria, 2024]
AGENTFORGE	Low-Code	Aprendizado por reforço.	[Fernandes e Oulasvirta, 2025]
BrainFusion	Low-Code	Análise multimodal de sinais fisiológicos	[Li <i>et al.</i> , 2025]
Cuvis.ai	Low-Code	Processamento e classificação de imagens	[Hanson <i>et al.</i> , 2024]
cidalsDB	Low-Code	Descoberta de fármacos / Quimioinformática	[Harigua-Souiai <i>et al.</i> , 2024]
KNIME	Low-Code	Farmácia, química e indústria	[Moreira-Filho <i>et al.</i> , 2024], [Chen, H. <i>et al.</i> ,

			2025], [Thongkhhome <i>et al.</i> , 2024]
EasyFL	Low-Code	Aprendizado federado	[Zhuang <i>et al.</i> , 2022]
MATLAB Regression Learner app / MATLAB App Designer	Low-Code	Engenharia civil e estruturas.	[Nguyen <i>et al.</i> , 2023]
MANILA	Low-Code	<i>Benchmarking</i> de modelos e <i>fairness</i> .	[D’Aloisio, 2025]
NeuroGeMS	Low-Code	Pesquisa biomédica multimodal.	[Budhraja <i>et al.</i> , 2025]
OS4ML	Low-Code	Desenvolvimento e experimentação de modelo de ML	[Rall <i>et al.</i> , 2024]
Orange Data Mining	No-Code	Saúde (oftalmologia, neurologia).	[Davidraj <i>et al.</i> , 2025], [Shin <i>et al.</i> , 2024], [Abishek <i>et al.</i> , 2025]
WEKA	No-Code	Química computacional, QSAR, toxicologia.	[Diaz <i>et al.</i> , 2024 e 2025]
Atomistica Online	No-Code	Química computacional	[Diaz <i>et al.</i> , 2024]
CVall	No-Code	Visão computacional.	[Hieu e Hung, 2025]

Fonte: Elaborado pelo autor (2026)

O Quadro 3 apresenta plataformas *No-Code* e *Low-Code* propostas em contextos acadêmicos ou desenvolvidas especificamente para estudos individuais. Essas soluções abrangem múltiplos domínios de aplicação, incluindo saúde, indústria, energia, políticas públicas, Internet das Coisas e aprendizado de máquina em geral. Em muitos casos, essas plataformas são apresentadas como provas de conceito ou ferramentas experimentais, sendo avaliadas por meio de estudos de caso, experimentos controlados ou demonstrações de viabilidade.

Quadro 4. Plataformas Acadêmicas ou Específicas de Estudo

Ferramenta	Tipo	Domínios de aplicação	Artigos
Dash	Low-Code	Aplicações industriais de IA	[Wang <i>et al.</i> , 2023]

Intelligent Service Platform (ISP)	Low-Code	Serviços inteligentes; classificação de textos policiais;	[Hu <i>et al.</i> , 2025]
GraphModo	Low-Code	Construção visual de modelos de <i>deep learning</i>	[Yang <i>et al.</i> , 2025]
InstructPipe	Low-Code	Prototipação de pipelines de <i>Machine Learning</i>	[Zhou <i>et al.</i> , 2025]
SeLoC-ML	Low-Code	Implantação de ML em dispositivos industriais	[Ren <i>et al.</i> , 2022]
CURSOR	No-Code	Sistemas de recomendação	[Alihosseini e Sharbaf, 2024]
Ember	No-Code	Processamento de dados	[Suri <i>et al.</i> , 2021]
MultiML	No-Code	Construção geral de modelos de <i>Machine Learning</i>	[Zhang <i>et al.</i> , 2024]
QSAR-Lit	No-Code	Descoberta de fármacos; quimioinformática; QSAR	[Sanches <i>et al.</i> , 2025]
SmartSeg	No-Code	Saúde; biomecânica	[Burton <i>et al.</i> , 2024]
Plataformas LC/NC específicas de estudo (não nomeadas)	Lo-Code / No-Code	Multidomínio (saúde, indústria, energia, políticas públicas, IoT, ML Geral).	[Martínez e Azqueta-Alzúaz, 2023], [Schötteler <i>et al.</i> , 2021], [Ozan, 2021], [Rao <i>et al.</i> , 2024], [Konin <i>et al.</i> , 2022], [Di Sipio <i>et al.</i> , 2020], [Aksyonov <i>et al.</i> , 2025], [Phoo-In <i>et al.</i> , 2024], [Chen, B. <i>et al.</i> , 2025], [Dasegowda <i>et al.</i> , 2024], [Kim <i>et al.</i> , 2023], [Zhao <i>et al.</i> , 2024], [Gomes, 2023]

Fonte: Elaborado pelo autor (2026)

4.4.1 Análise Integrada do Ecossistema de Ferramentas

A análise das 91 ferramentas identificadas revela padrões consistentes quanto à natureza, escopo e domínios de aplicação das plataformas LC/NC para IA/ML.

Distribuição por natureza: Das 91 plataformas identificadas, aproximadamente 56% são comerciais consolidadas (Quadro 1), 19% são open-source ou especializadas (Quadro 2) e 25% são acadêmicas ou específicas de estudo (Quadro 3). Observa-se que, embora as plataformas comerciais sejam predominantes, há participação significativa de soluções acadêmicas, especialmente quando consideradas as plataformas desenvolvidas especificamente para estudos individuais.

Especialização por domínio: Observa-se uma tendência crescente à especialização funcional. Enquanto plataformas generalistas como Microsoft Power

Platform e Google AutoML atendem múltiplos domínios, ferramentas como DEEP:PHI (diagnóstico médico), LandingLens (odontologia), cidalsDB (descoberta de fármacos) e WEKA (química computacional) concentram-se em nichos específicos, oferecendo recursos otimizados para contextos particulares.

4.5. Distribuição das plataformas *No-Code* e *Low-Code*

A Tabela 2 apresenta a distribuição quantitativa das plataformas identificadas na revisão sistemática, classificadas de acordo com o tipo de abordagem adotada. Observa-se uma predominância de plataformas *No-Code*, que correspondem a 50 soluções (54,95%), indicando uma forte tendência à abstração total da programação no desenvolvimento de aplicações de Inteligência Artificial e *Machine Learning*.

As plataformas *Low-Code* representam 35 soluções (38,46%), configurando um grupo expressivo que privilegia a redução do esforço de programação, ao mesmo tempo em que mantém maior flexibilidade técnica para customização, integração e extensão de funcionalidades.

Por fim, as plataformas classificadas como *Low-Code / No-Code* (híbridas) totalizam 6 soluções (6,59%), evidenciando a existência de abordagens que combinam características de ambos os paradigmas, permitindo tanto o desenvolvimento sem escrita de código quanto a inclusão opcional de código em cenários mais avançados. Esses resultados reforçam a diversidade de estratégias adotadas pelas plataformas analisadas e indicam que, embora o paradigma *No-Code* seja predominante, abordagens *Low-Code* continuam relevantes em contextos que demandam maior controle técnico.

Tabela 1. Distribuição quantitativa das plataformas identificadas

Classificação	Quantidade de Plataformas	Percentual
<i>No-Code</i>	50	54,95%
<i>Low-Code</i>	35	38,46%
<i>Low-Code / No-Code</i> (Híbridas)	6	6,59%

Fonte: Elaborado pelo autor (2026)

Do total de 91 plataformas identificadas, 13 correspondem a soluções desenvolvidas especificamente para os estudos analisados, sem denominação formal explícita. Essas plataformas foram classificadas conforme descrito nos próprios artigos (7 como *No-Code* e 6 como *Low-Code*) e incluídas na análise quantitativa para representar de forma mais fiel o ecossistema efetivamente investigado. Embora não possuam identificação nominal, sua inclusão justifica-se por atenderem aos critérios de LC/NC estabelecidos nesta revisão.

4.6 - Análise comparativa dos estudos

A análise comparativa dos estudos evidencia diferenças consistentes entre as plataformas *No-Code* e *Low-Code*, bem como entre soluções comerciais, open-source e acadêmicas. Observa-se que plataformas comerciais são predominantes em aplicações práticas, especialmente na área da saúde, com foco em tarefas de classificação,

regressão e AutoML, destacando-se pela facilidade de uso e rapidez no desenvolvimento.

Em contrapartida, plataformas *open-source* e especializadas apresentam maior flexibilidade e controle sobre o *pipeline* de *Machine Learning*, sendo mais frequentes em contextos técnicos e experimentais, como bioinformática, química computacional e aplicações científicas. Já as plataformas acadêmicas concentram-se principalmente em provas de conceito e validações experimentais, explorando novas abordagens e modelos de interação com sistemas de IA/ML.

Considerando o tipo de abordagem, as plataformas *No-Code* destacam-se pela democratização do acesso e pela redução da barreira técnica, enquanto as *Low-Code* oferecem maior equilíbrio entre usabilidade e capacidade de customização, sendo mais adequadas a cenários que demandam ajustes específicos nos modelos.

A partir do mapeamento sistemático apresentado, que identificou e categorizou 91 plataformas distribuídas em contextos comerciais, *open-source* e acadêmicos, torna-se possível analisar criticamente os achados à luz das questões de pesquisa que orientaram esta revisão. A seção seguinte sintetiza os resultados obtidos, conectando-os diretamente às perguntas norteadoras e discutindo suas implicações teóricas e práticas para o desenvolvimento de soluções de IA/ML por meio de plataformas LC/NC.

5. Discussão

Esta seção analisa de forma crítica os dados apresentados, conectando-os diretamente às questões de pesquisa (QPs) e identificando padrões observados nos estudos analisados.

5.1. QP1: Ferramentas utilizadas

Em resposta à QP1, foram identificadas 91 plataformas *Low-Code* e *No-Code* aplicadas ao desenvolvimento de soluções de Inteligência Artificial e *Machine Learning* nos 67 estudos analisados. Essas ferramentas distribuem-se em três categorias principais: plataformas comerciais consolidadas, soluções *open-source* ou especializadas e ferramentas acadêmicas ou desenvolvidas especificamente para estudos individuais.

A predominância de plataformas comerciais indica que o avanço das abordagens LC/NC para IA/ML está fortemente associado a demandas organizacionais e estratégias de transformação digital. Essas soluções tendem a oferecer suporte ao ciclo completo de desenvolvimento de modelos, incluindo preparação de dados, treinamento, validação e implantação, favorecendo sua adoção em ambientes corporativos.

As plataformas *open-source* e especializadas constituem um segundo grupo relevante, frequentemente associadas a domínios específicos como saúde, bioinformática e aplicações industriais. Esse conjunto revela a permanência de iniciativas voltadas à maior flexibilidade técnica e customização, mesmo diante da expansão de soluções comerciais integradas.

Adicionalmente, a presença de plataformas desenvolvidas exclusivamente no contexto acadêmico indica que o campo ainda se encontra em processo de consolidação. Muitas dessas ferramentas são apresentadas como provas de conceito, evidenciando lacunas funcionais e oportunidades de inovação metodológica.

Assim, a resposta à QP1 demonstra que o ecossistema LC/NC para IA/ML é caracterizado por diversidade estrutural e diferentes níveis de maturidade tecnológica, refletindo tanto consolidação industrial quanto dinamismo experimental no ambiente acadêmico.

Complementando essa análise estrutural, a seção seguinte examina as características funcionais dessas plataformas.

5.2. QP2: Principais características

A análise da QP2 revela que as principais características das ferramentas LC/NC para IA/ML concentram-se em interfaces gráficas visuais, mecanismos de automação e suporte a diversas técnicas de aprendizado de máquina.

Técnicas de IA/ML suportadas: Os dados extraídos indicam que as técnicas mais frequentemente suportadas pelas plataformas analisadas são:

- Classificação: presente em 26 estudos (38,81%), incluindo classificação de imagens, diagnósticos médicos e categorização de dados estruturados;
- Regressão: identificada em 18 estudos (26,87%), aplicada a previsões numéricas e modelagem de variáveis contínuas;
- AutoML: mencionada em 10 estudos (14,93%), destacando-se como recurso que automatiza etapas do *pipeline* de ML, incluindo seleção de modelos, otimização de hiperparâmetros e pré-processamento;
- *Clustering*: identificado em 6 estudos (8,96%), voltado para agrupamento e descoberta de padrões não supervisionados;
- Visão Computacional/CNN: mencionada em estudos voltados à detecção de objetos, segmentação de imagens e diagnóstico médico por imagem;
- Processamento de Linguagem Natural (NLP): identificado em estudos específicos aplicados ao processamento de texto e extração de informações.

Domínios de aplicação: A extração de dados evidencia predominância dos seguintes domínios:

- Saúde: 20 estudos (30%), abrangendo diagnósticos médicos, detecção de doenças, análise de imagens médicas e farmacologia, representando o domínio mais expressivo nos estudos analisados;
- Indústria: 5 estudos (7,46%), incluindo manutenção preditiva e aplicações industriais;
- Bioinformática/Farmácia: 4 estudos (5,97%), com foco em descoberta de fármacos, química computacional e toxicologia;
- Internet das Coisas (IoT): 3 estudos (4,48%), voltados para serviços inteligentes e aplicações industriais conectadas;
- Educação: 2 estudos (2,99%);

Funcionalidades e limitações: Em relação às limitações, observa-se que apenas parte dos estudos analisados as reporta de forma explícita. Nos trabalhos que abordam esse aspecto, são mencionadas restrições relacionadas à flexibilidade das plataformas, à personalização avançada de modelos e à dependência de ecossistemas específicos, sobretudo em soluções comerciais. Cabe ressaltar que nem todos os estudos reportam limitações de forma explícita. Uma parcela significativa concentra-se na proposição de

ferramentas, na descrição de arquiteturas ou em estudos de viabilidade, sem mencionar restrições técnicas. Nos trabalhos que abordam esse aspecto de forma direta, as principais limitações citadas estão:

- Performance e escalabilidade: apontadas como limitações em 15 menções (22,39%), especialmente em cenários que demandam processamento intensivo;
- Custos elevados: mencionados em 14 menções (20,90%), particularmente no uso de recursos *premium* em plataformas comerciais;
- Limitações de customização: identificadas em 9 menções (13,43%), especialmente relacionadas ao controle limitado sobre hiperparâmetros e arquiteturas de modelos;
- Dependência de fornecedor (*vendor lock-in*): A dependência de fornecedor emerge como uma preocupação recorrente na análise agregada dos estudos, especialmente em plataformas fortemente integradas a ambientes proprietários. Contudo, essa questão nem sempre é apresentada como uma limitação explicitamente declarada pelos autores, sendo identificada principalmente a partir da síntese comparativa dos trabalhos analisados;
- Curva de aprendizado: mencionada em estudos específicos, indicando que algumas plataformas, embora LC/NC, ainda apresentam complexidade para usuários iniciantes.

Apesar das limitações técnicas identificadas, o impacto dessas características na eficiência do desenvolvimento é notável, conforme explorado na sequência.

5.3. QP3: Benefícios vs. Programação tradicional

Em relação à QP3, os dados extraídos dos estudos evidenciam os seguintes benefícios das ferramentas LC/NC em comparação à programação tradicional:

Benefícios mais relatados:

- Democratização e acessibilidade: identificada de forma predominante nos estudos analisados, destacando-se como o benefício mais frequente. As ferramentas LC/NC permitem que usuários sem conhecimento técnico avançado em programação desenvolvam soluções de IA/ML, ampliando o acesso a essas tecnologias para especialistas de domínio;
- Rapidez e produtividade: mencionada de forma recorrente, indicando redução significativa no tempo de desenvolvimento de modelos e validação de hipóteses;
- Integração: presente nos estudos, referindo-se à capacidade de integração com ecossistemas existentes, APIs e serviços em nuvem;
- Facilidade de uso: relatada nos estudos, associada a interfaces intuitivas e fluxos visuais que simplificam a construção de *pipelines* de ML;
- Redução de custos: mencionada em menor frequência que os demais benefícios, embora presente em estudos específicos.

Contextos de aplicação: Os estudos analisados demonstram que as ferramentas LC/NC são particularmente eficazes em contextos onde:

- Não especialistas em programação necessitam desenvolver modelos de ML para resolver problemas específicos de suas áreas;

- A validação rápida de hipóteses é prioritária em relação à otimização extrema de desempenho;
- A padronização e a reprodutibilidade dos processos são requisitos importantes.

Limitações em comparação à programação tradicional: Embora os benefícios sejam expressivos, os dados extraídos não indicam que as ferramentas LC/NC substituam integralmente a programação tradicional. As limitações de customização avançada, controle de hiperparâmetros e flexibilidade arquitetural sugerem que essas plataformas atuam de forma complementar, especialmente em cenários que demandam alto desempenho computacional.

Por fim, para maximizar esses benefícios, certos atributos das plataformas mostram-se determinantes.

5.4. QP4: Aspectos contribuintes

Para a QP4, os dados extraídos evidenciam que os aspectos das plataformas LC/NC que mais contribuem para o desenvolvimento de soluções de IA/ML incluem:

- Usabilidade das interfaces: A facilidade de uso, mencionada de forma recorrente nos estudos, está diretamente relacionada a interfaces visuais baseadas em fluxos de trabalho (*workflows*), *drag-and-drop* e componentes pré-configurados. Essas características reduzem a necessidade de conhecimento técnico aprofundado e permitem experimentação rápida com diferentes configurações de modelos.
- Automação de *pipelines*: A presença de recursos de AutoML, identificada em 10 estudos, automatiza etapas críticas do desenvolvimento de modelos, incluindo seleção de algoritmos, engenharia de características, otimização de hiperparâmetros e validação cruzada. Essa automação contribui significativamente para a rapidez e produtividade relatadas.
- Capacidade de integração: A integração com ecossistemas existentes, mencionada nos estudos, facilita a conexão das plataformas LC/NC com fontes de dados, APIs, serviços em nuvem e sistemas legados. Isso permite que as soluções desenvolvidas sejam incorporadas a fluxos de trabalho organizacionais sem necessidade de reconstrução completa de infraestruturas.
- Suporte a múltiplos *frameworks* e técnicas: Os estudos indicam que plataformas capazes de suportar diversos *frameworks* de ML (TensorFlow, PyTorch, *scikit-learn*, entre outros) e técnicas variadas (classificação, regressão, *clustering*, visão computacional, NLP) ampliam significativamente o escopo de aplicação das ferramentas LC/NC.
- Explicabilidade e *Human-in-the-Loop*: A incorporação de recursos de explicabilidade (XAI) e abordagens *human-in-the-loop* ainda é limitada na literatura analisada. No entanto, esses mecanismos são fundamentais para aumentar a transparência, a confiança e a auditabilidade dos modelos, especialmente em domínios críticos como a medicina e políticas públicas. Estudos que propõem *frameworks No-Code* com suporte à XAI evidenciam uma tendência emergente de integrar interpretação e supervisão humana ao ciclo de desenvolvimento.
- Implantação (*Deployment*): A capacidade de implantação simplificada, permitindo que modelos treinados sejam colocados em produção com poucos

passos, é destacada como aspecto facilitador do ciclo completo de desenvolvimento de soluções de IA/ML.

Cabe destacar que nem todos os estudos incluídos nesta revisão reportam explicitamente limitações técnicas ou metodológicas. Dessa forma, algumas das observações discutidas nesta seção decorrem de uma análise comparativa e agregada dos trabalhos, e não exclusivamente da extração direta de limitações declaradas individualmente pelos autores.

5.5. Tendências e Perspectivas de Pesquisa

A análise temporal e temática dos estudos incluídos revela direcionamentos claros na evolução das plataformas LC/NC aplicadas a IA/ML.

Incorporação de IA Generativa: Dos 41 estudos publicados entre 2024 e 2025, 34% mencionam explicitamente integração com modelos de linguagem de grande escala (LLMs) ou recursos de IA generativa. Plataformas como AirOps [Zaoui et al., 2025] e ChatGPT-4 aplicado a contextos *no-code* [Choi e Yoo, 2025] exemplificam essa tendência. A incorporação de LLMs permite interação em linguagem natural para construção de pipelines e geração automática de código, reduzindo ainda mais a barreira técnica.

Especialização por Domínio: Observa-se migração de plataformas generalistas para soluções verticalizadas. Na área da saúde, que concentra 30% dos estudos analisados, identificam-se ferramentas específicas para diagnóstico por imagem (DEEP:PHI, Microsoft Lobe), radiologia (LandingLens), patologia (Teachable Machine) e farmacologia (AirOps). Essa especialização permite otimização de *workflows* e conformidade regulatória específica de cada domínio.

Expansão para Edge Computing e IoT: Aproximadamente 12% dos estudos recentes (2024-2025) abordam plataformas LC/NC para implantação de modelos em dispositivos de borda e ambientes IoT. Ferramentas como Edge Impulse, NanoEdgeAI Studio e Neuton.AI [Montes-Sánchez et al., 2025] viabilizam manutenção preditiva e inferência local, reduzindo latência e dependência de conectividade.

Explicabilidade e Governança: Identificou-se a incorporação de recursos de explicabilidade (XAI) e governança em 5 dos 67 estudos analisados (7,46%), indicando tendência emergente na literatura. Plataformas como MANILA [D'Aloisio, 2025] introduzem mecanismos de *fairness* e *benchmarking*, enquanto *frameworks* como o proposto em [Martínez e Azqueta-Alzúaz, 2023] focam em XAI *no-code* para políticas públicas.

5.6. Lacunas e Oportunidades de Pesquisa

Apesar dos avanços, permanecem desafios relevantes que configuram oportunidades para pesquisas futuras:

1. **Avaliação comparativa rigorosa:** Apenas 6% dos estudos apresentam comparações controladas entre plataformas LC/NC e desenvolvimento tradicional em termos de acurácia, desempenho computacional e tempo de desenvolvimento. Estudos longitudinais são necessários para quantificar *trade-offs*.
2. **Privacidade e segurança:** Menos de 5% dos estudos abordam explicitamente questões de privacidade, segurança de dados e

conformidade regulatória (GDPR, LGPD, HIPAA), lacuna crítica considerando aplicações sensíveis em saúde e finanças.

3. **Customização avançada:** A tensão entre abstração (usabilidade) e controle técnico (flexibilidade) permanece central. Pesquisas futuras podem explorar arquiteturas híbridas que permitam transição gradual de *No-Code* para *Low-Code* conforme o usuário amadurece.
4. **Sustentabilidade e *vendor lock-in*:** Estratégias para mitigar dependência de fornecedores, portabilidade de modelos entre plataformas e custos de longo prazo constituem temas emergentes ainda sub-representados na literatura.

6. Limitações do estudo

A interpretação dos resultados desta Revisão Sistemática da Literatura deve considerar certas limitações inerentes ao método e ao escopo adotados.

Recorte temporal: Os dados referentes ao ano de 2025 são parciais, abrangendo apenas publicações até o mês de agosto. Isso pode sub-representar as inovações mais recentes, dado o ritmo acelerado de evolução da área de IA generativa e ferramentas associadas.

Delimitação das strings de busca: A estratégia de busca utilizou os termos ("*no-code*" OR "*low-code*") combinados com "*artificial intelligence*" e "*machine learning*", priorizando conceitos amplos relacionados ao desenvolvimento de soluções inteligentes. A inclusão explícita de subáreas específicas, como "*deep learning*", "*computer vision*" ou "*natural language processing*", poderia ampliar a abrangência temática, porém desviaria o foco central desta revisão, que é o mapeamento de plataformas LC/NC aplicadas ao desenvolvimento de IA/ML de forma geral. Ainda assim, reconhece-se que essa delimitação pode ter excluído estudos que abordem aplicações específicas dessas subáreas sem mencionar explicitamente os termos gerais utilizados na string, configurando uma limitação potencial de cobertura.

Crítérios de inclusão linguística e de acesso: Ao restringir a busca a artigos em inglês e português e àqueles com acesso gratuito ao texto completo, é possível que estudos relevantes publicados em outros idiomas ou em repositórios pagos tenham sido omitidos.

Viés de publicação: A maioria dos estudos analisados foca na proposição ou validação de ferramentas, apresentando casos de sucesso. Há escassez de estudos longitudinais ou relatos de falha na adoção de LC/NC, o que pode introduzir um viés de publicação otimista.

Falta de padronização conceitual: Identificou-se uma falta de padronização na literatura quanto às definições de "*No-Code*", "*Low-Code*" e "AutoML". A sobreposição desses termos dificultou a categorização estrita de algumas ferramentas, exigindo decisões interpretativas durante a extração de dados.

Heterogeneidade das plataformas: A alta heterogeneidade das plataformas — que variam de soluções empresariais robustas a protótipos acadêmicos — e a diversidade dos contextos de aplicação (da saúde à aviação) limitam a capacidade de generalização dos resultados e impedem a realização de uma meta-análise quantitativa de desempenho.

7. Considerações Finais

O presente trabalho atingiu seu objetivo principal de mapear e analisar o estado da arte das ferramentas *No-Code* e *Low-Code* aplicadas ao desenvolvimento de Inteligência Artificial e *Machine Learning*. Por meio de uma Revisão Sistemática da Literatura baseada nas diretrizes de Kitchenham, foram analisados 67 estudos publicados entre 2020 e 2025, permitindo uma compreensão estruturada sobre como essas tecnologias estão sendo empregadas para reduzir a complexidade técnica inerente à criação de modelos inteligentes.

Os resultados sintetizados revelam um crescimento quase exponencial do interesse acadêmico na área, especialmente nos últimos dois anos. O mapeamento evidenciou um ecossistema tecnológico robusto e diversificado, composto por plataformas comerciais consolidadas, soluções open-source flexíveis e ferramentas acadêmicas especializadas. As aplicações permeiam setores críticos como saúde, indústria 4.0 e ciência de dados, respondendo às questões de pesquisa ao demonstrar que, embora variem em características, essas ferramentas convergem no objetivo de abstrair a codificação complexa através de interfaces visuais e automação.

As implicações deste estudo apontam para uma efetiva democratização da IA/ML. Ao reduzir as barreiras de entrada técnicas, as plataformas LC/NC empoderaram especialistas de domínio — os chamados "*citizen developers*" — permitindo que profissionais de saúde, engenheiros e gestores participem ativamente da construção de soluções tecnológicas. Isso acelera o ciclo de desenvolvimento, promove a inovação nas pontas da organização e mitiga a escassez de cientistas de dados especializados no mercado.

Os resultados da revisão indicam que, embora algumas limitações sejam reportadas em estudos específicos, as ferramentas *No-Code* e *Low-Code* apresentam elevado potencial para ampliar o acesso ao desenvolvimento de aplicações baseadas em IA e ML. Tais abordagens mostram-se particularmente relevantes quando utilizadas como complemento a métodos tradicionais, contribuindo para a democratização e aceleração do desenvolvimento de soluções inteligentes.

Para trabalhos futuros, recomenda-se a condução de estudos longitudinais que acompanhem a evolução da maturidade dessas plataformas, bem como pesquisas comparativas rigorosas que quantifiquem as diferenças de desempenho e acurácia entre modelos gerados via LC/NC e métodos tradicionais. Adicionalmente, há uma necessidade urgente de desenvolver taxonomias conceituais mais claras para diferenciar *No-Code*, *Low-Code* e AutoML, além de investigar profundamente aspectos de explicabilidade, governança e a integração humano-IA (*human-in-the-loop*), garantindo que a democratização do desenvolvimento não comprometa a segurança e a ética das soluções de Inteligência Artificial.

8. Referências

Abishek, N. et al. Leveraging Neural Networks for Accurate Diagnosis of Eye Diseases in Retinal Fundus Images. In: 2025 INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND AUTONOMOUS SYSTEMS (ICMLAS). 2025 *International Conference on Machine Learning and Autonomous Systems (ICMLAS)*. 10 mar. 2025.

- Aksyonov, K. A.; Sun, L.; Kalinin, I. A.. Developing AI Models Using a Code-Free Platform. In: 2025 INTERNATIONAL RUSSIAN SMART INDUSTRY CONFERENCE (SMARTINDUSTRYCON). *2025 International Russian Smart Industry Conference (SmartIndustryCon)*. 24 mar. 2025.
- Alihosseini, M. A.; Sharbaf, M.. A No-Code Platform for Developing Customizable Recommender Systems for Restaurants. In: 2024 15TH INTERNATIONAL CONFERENCE ON INFORMATION AND KNOWLEDGE TECHNOLOGY (IKT). *2024 15th International Conference on Information and Knowledge Technology (IKT)*. 24 dez. 2024.
- Agarwal, A.; Das, A.. An Integrated Breast Cancer Predictor Leveraging Mendix and Machine Learning. In: 2025 6TH INTERNATIONAL CONFERENCE ON RECENT ADVANCES IN INFORMATION TECHNOLOGY (RAIT). *2025 6th International Conference on Recent Advances in Information Technology (RAIT)*. 6 mar. 2025.
- Antonson, N. W. et al. Novel Technique for the Identification of Hip Implants Using Artificial Intelligence. *The Journal of Arthroplasty*, v. 39, n. 5, p. 1178–1183, 1 maio 2024.
- Ashraf, A. R. et al. Leveraging code-free deep learning for pill recognition in clinical settings: A multicenter, real-world study of performance across multiple platforms. *Artificial Intelligence in Medicine*, v. 150, p. 102844, 1 abr. 2024.
- Bhaumik, U.; Chatterjee, S.; KumarS., Koushlendra. Suryanamaskar Pose Identification and Estimation Using No Code Computer Vision. In: BAJPAI, Manish Kumar; KUMAR SINGH, Koushlendra; GIAKOS, George (Orgs.). *Machine Vision and Augmented Intelligence—Theory and Applications*. Singapore: Springer Singapore, 2021. v. 796 p. 85–90.
- Budhraja, S. et al. NeuroGeMS: An Open-Source GUI Software for Multimodal Modelling in Biomedical Research and Applications. In: MAHMUD, Mufti et al. (Orgs.). *Neural Information Processing*. Singapore: Springer Nature Singapore, 2025. v. 2296 p. 218–232.
- Burton, W.; Gibbons, K.; Economon, K. SmartSeg: machine learning infrastructure software for accelerating medical image segmentation in patient-specific applications. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging and Visualization*, v. 12, n. 1, 2024.
- Chen, B. et al. Knowledge sharing-enabled low-code program for collaborative robots in mix-model assembly. *Journal of Industrial Information Integration*, v. 45, p. 100824, 1 maio 2025.
- Chen, H. et al. Employing a low-code machine learning approach to predict in-hospital mortality and length of stay in patients with community-acquired pneumonia. *Scientific Reports*, v. 15, n. 1, p. 309, 2 jan. 2025.
- Choi, J. Y.; Yoo, T. K.. Development of a novel scoring system for glaucoma risk based on demographic and laboratory factors using ChatGPT-4. *Medical & Biological Engineering & Computing*, v. 63, n. 1, p. 75–87, 1 jan. 2025.
- D’alio, G.. MANILA: A Low-Code Application to Benchmark Machine Learning Models and Fairness-Enhancing Methods. In: *FSE Companion ’25*. New York, NY,

- USA: Association for Computing Machinery, 2025. Disponível em: <https://doi.org/10.1145/3696630.3728600>
- Dasegowda, G. et al. No code machine learning: validating the approach on use-case for classifying clavicle fractures. *Clinical Imaging*, v. 112, p. 110207, 1 ago. 2024.
- Davidraj, P. Y. et al. A No-Code Approach to Classifying Neurological Disorders Using Orange Data Mining. In: 2025 3RD INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS, ADVANCED COMPUTING AND COMMUNICATION (ISACC). 2025 3rd International Conference on Intelligent Systems, Advanced Computing and Communication (ISACC). 27 fev. 2025.
- Di Sipio, C.; Di Ruscio, D.; Nguyen, P. T.. Democratizing the development of recommender systems by means of low-code platforms. In: *MODELS '20. New York, NY, USA: Association for Computing Machinery, 2020*. Disponível em: <https://doi.org/10.1145/3417990.3420202>
- Diaz, A. H.; Galdames, F.; Velásquez, P.. Accurate & simple open-sourced no-code machine learning and CDFT predictive models for the antioxidant activity of phenols. *Computational and Theoretical Chemistry*, v. 1239, p. 114782, 1 set. 2024.
- Diaz, A. H. et al. Explainable no-code OECD-compliant machine learning models to predict the mutagenic activity of polycyclic aromatic hydrocarbons and their radical cation metabolites. *Science of The Total Environment*, v. 972, p. 179133, 1 abr. 2025.
- Fernandes, F. E.; Oulasvirta, A. AGENTFORGE: AFlexible Low-Code Platform for Reinforcement Learning Agent Design. In: ROCHA A.P.; STEELS L.; VAN DEN HERIK H.J. (orgs.). INTERNATIONAL CONFERENCE ON AGENTS AND ARTIFICIAL INTELLIGENCE. *Int. Conf. Agent. Artif. Intell.* Science and Technology Publications, Lda, 2025. Disponível em: <<https://doi.org/10.1145/3696630.3728600>>
- Glahe, P.; Trappe, R.. Zauberzeug Learning Loop: A no-code AI Platform. **KI - Künstliche Intelligenz**, v. 37, n. 2–4, p. 195–201, dez. 2023.
- Gomes, L.. Transforming Ideas into Code: Visual Sketching for ML Development. In: *SPLASH 2023. New York, NY, USA: Association for Computing Machinery, 22 out. 2023*. Disponível em: <https://dl.acm.org/doi/10.1145/3618305.3623588>.
- Graaff, Armand; Smit, Danie; Eybers, Sunet. Let's Play Games: Using No-Code AI to Reduce Human Cognitive Load During AI Solution Development. In: *PILLAY, Anban; JEMBERE, Edgar; J. GERBER, Aurona (orgs.). Cham: Springer Nature Switzerland, 2023*.
- Hamamoto, Y. et al. The Histological Detection of Ulcerative Colitis Using a No-Code Artificial Intelligence Model. *International Journal of Surgical Pathology*, v. 32, n. 5, p. 890–894, 2024.
- Hamdan, M. et al. Detection of dental restorations on panoramic radiographs using a no-code computer vision platform. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, v. 139, n. 3, p. e92, 1 mar. 2025.
- Hamdan, M. et al. Detection of dental restorations using no-code artificial intelligence. *Journal of Dentistry*, v. 139, p. 104768, 1 dez. 2023.

- Hanson, N. et al. Cuvis.AI: An Open-Source, Low-Code Software Ecosystem for Hyperspectral Processing and Classification. In: 2024 14TH WORKSHOP ON HYPERSPECTRAL IMAGING AND SIGNAL PROCESSING: EVOLUTION IN REMOTE SENSING (WHISPERS). *2024 14th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. 9 dez. 2024.
- Harigua-Souiai, E. et al. cidalsDB: an AI-empowered platform for anti-pathogen therapeutics research. *Journal of Cheminformatics*, v. 16, n. 1, p. 134, 28 nov. 2024.
- Hieu, P. N. D.; Hung, P. D.. No Code Computer Vision. In: SINGH, Dhananjay; VAN 'T KLOOSTER, Jan-Willem; TIWARY, Uma Shanker (Orgs.). *Intelligent Human Computer Interaction*. Cham: Springer Nature Switzerland, 2025. v. 15557 p. 306–315.
- Hu, Y. et al. Design and Implementation of a Low-Code Intelligent Service Platform. In: 2025 10TH INTERNATIONAL CONFERENCE ON CLOUD COMPUTING AND BIG DATA ANALYTICS (ICCCBDA). *2025 10th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA)*. 24 abr. 2025.
- Iyer, C. V. K. et al. Trinity: A No-Code AI platform for complex spatial datasets. In: LUNGA D. et al. (orgs.). PROCEEDINGS OF THE 4TH ACM SIGSPATIAL INTERNATIONAL WORKSHOP ON AI FOR GEOGRAPHIC KNOWLEDGE DISCOVERY, GEOAI 2021. *Proc. ACM SIGSPATIAL Int. Workshop AI Geogr. Knowl. Discov., GeoAI*. Association for Computing Machinery, Inc, 2021. Disponível em: <https://doi.org/10.1145/3486635.3491072>
- Jauhar, S. K. et al. How to use no-code artificial intelligence to predict and minimize the inventory distortions for resilient supply chains. *International Journal of Production Research*, v. 62, n. 15, p. 5510–5534, 2024.
- Kim, H. et al. No-code MLOps Platform for Data Annotation. In: 2023 IEEE INTERNATIONAL CONFERENCE ON MEMRISTIVE COMPUTING AND APPLICATIONS (ICMCA). *2023 IEEE International Conference on Memristive Computing and Applications (ICMCA)*. 8 dez. 2023.
- Kitchenham, Barbara A. Systematic review in software engineering: where we are and where we should be going. In: *EAST '12. New York, NY, USA: Association for Computing Machinery, 2012*. Disponível em: <https://doi.org/10.1145/2372233.2372235>
- Kling, N. et al. Harnessing Sustainable Development in Image Recognition Through No-Code AI Applications: A Comparative Analysis. In: SANTOSH, Kc; HEGADI, Ravindra; PAL, Umapada (Orgs.). *Recent Trends in Image Processing and Pattern Recognition*. Cham: Springer International Publishing, 2022. v. 1576 p. 146–155.
- Kok, C. L. et al. A Comparative Study of AI and Low-Code Platforms for SMEs: Insights into Microsoft Power Platform, Google AutoML and Amazon SageMaker. In: 2024 IEEE 17TH INTERNATIONAL SYMPOSIUM ON EMBEDDED MULTICORE/MANY-CORE SYSTEMS-ON-CHIP (MCSOC). *2024 IEEE 17th International Symposium on Embedded Multicore/Many-core Systems-on-Chip (MCSOC)*. 16 dez. 2024.
- Konin, A. et al. AI-mediated Job Status Tracking in AR as a No-Code service. In: 2022 IEEE INTERNATIONAL SYMPOSIUM ON MIXED AND AUGMENTED

- REALITY ADJUNCT (ISMAR-ADJUNCT). 2022 *IEEE International Symposium on Mixed and Augmented Reality Adjunct (ISMAR-Adjunct)*. 17 out. 2022.
- Lee, K. H. et al. Automated Diagnosis of Knee Osteoarthritis Using ResNet101 on a DEEP:PHI: Leveraging a No-Code AI Platform for Efficient and Accurate Medical Image Analysis. *Diagnostics*, v. 14, n. 21, 2024.
- Li, L.; Wu, Z.. How Can No/Low Code Platforms Help End-Users Develop ML Applications? - A Systematic Review. In: CHEN, Jessie Y. C. et al. (Orgs.). *HCI International 2022 – Late Breaking Papers: Interacting with eXtended Reality and Artificial Intelligence*. Cham: Springer Nature Switzerland, 2022. v. 13518 p. 338–356.
- Li, W. et al. BrainFusion: a Low-Code, Reproducible, and Deployable Software Framework for Multimodal Brain–Computer Interface and Brain–Body Interaction Research. *Advanced Science*, 2025.
- Martinez, E.; Cisterna, D. USING LOW-CODE AND ARTIFICIAL INTELLIGENCE TO SUPPORT CONTINUOUS IMPROVEMENT IN THE CONSTRUCTION INDUSTRY. In: RYBKOWSKI Z.; LIU M.; SARHAN S. (orgs.). ANNUAL CONFERENCE OF THE INTERNATIONAL GROUP FOR LEAN CONSTRUCTION, IGLC. *Annu. Conf. Int. Group Lean Constr., IGLC*. International Group for Lean Construction, 2023. Disponível em: <https://doi.org/10.24928/2023/0236>
- Martínez, M. P.; Azqueta-Alzúaz, A.. A No Code XAI Framework for Policy Making. In: 2023 19TH INTERNATIONAL CONFERENCE ON DISTRIBUTED COMPUTING IN SMART SYSTEMS AND THE INTERNET OF THINGS (DCOSS-IOT). *2023 19th International Conference on Distributed Computing in Smart Systems and the Internet of Things (DCOSS-IoT)*. 19 jun. 2023.
- Moin, A. et al. ML-quadrat & DriotData: a model-driven engineering tool and a low-code platform for smart IoT services. In: *ICSE '22. New York, NY, USA: Association for Computing Machinery, 2022*. Disponível em: <https://doi.org/10.1145/3510454.3516841>
- Montes-Sánchez, J. M. et al. No-Code Edge Artificial Intelligence Frameworks Comparison Using a Multi-Sensor Predictive Maintenance Dataset. *Big Data and Cognitive Computing*, v. 9, n. 6, 2025.
- Moreira-Filho, J. T. et al. Democratizing cheminformatics: interpretable chemical grouping using an automated KNIME workflow. *Journal of Cheminformatics*, v. 16, n. 1, p. 101, 16 ago. 2024.
- Nguyen, K. L. et al. Low-Code Application and Practical Implications of Common Machine Learning Models for Predicting Punching Shear Strength of Concrete Reinforced Slabs. *Advances in Civil Engineering*, v. 2023, 2023.
- Ouzzani, Mourad et al. Rayyan—a web and mobile app for systematic reviews. *Systematic Reviews*, v. 5, n. 1, p. 210, 5 dez. 2016.
- Ozan, E.. A Novel Browser-based No-code Machine Learning Application Development Tool. In: 2021 IEEE WORLD AI IOT CONGRESS (AIIOT). *2021 IEEE World AI IoT Congress (AIIoT)*. 10 maio 2021.

- Page, M. J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, v. 372, n. 71, 2021. Disponível em: <https://doi.org/10.1136/bmj.n71>
- Pastierik, I.. Deploying Oracle Machine Learning AutoML Models for Oracle APEX Analytics. In: 2024 IEEE 17TH INTERNATIONAL SCIENTIFIC CONFERENCE ON INFORMATICS (INFORMATICS). *2024 IEEE 17th International Scientific Conference on Informatics (Informatics)*. 13 nov. 2024.
- Phoo-In, J.; Leelasantitham, A.; Sukamongkol, Y.. Development of Low-Code Platform for Electrical Power Trading Using Blockchain and Artificial Intelligence. In: 2024 5TH TECHNOLOGY INNOVATION MANAGEMENT AND ENGINEERING SCIENCE INTERNATIONAL CONFERENCE (TIMES-ICON). *2024 5th Technology Innovation Management and Engineering Science International Conference (TIMES-iCON)*. 19 jun. 2024.
- Rabelo, J. S. 2026. Dataset de extração de dados da revisão sistemática sobre ferramentas *No-Code* e *Low-Code* para Inteligência Artificial e *Machine Learning*. Zenodo. DOI: <https://doi.org/10.5281/zenodo.18889634>
- Raghavendran, K. R.; Elragal, A. Low-Code Machine Learning Platforms: A Fastlane to Digitalization. *Informatics*, v. 10, n. 2, 2023.
- Rall, D. et al. OS4ML: Open Space for Machine Learning. In: WANG, Yi-Chi; CHAN, Siu Hang; WANG, Zih-Huei (Orgs.). *Flexible Automation and Intelligent Manufacturing: Manufacturing Innovation and Preparedness for the Changing World Order*. Cham: Springer Nature Switzerland, 2024. p. 47–57.
- Rao, N. et al. AI for Low-Code for AI. In: *IUI '24. New York, NY, USA: Association for Computing Machinery, 2024*. Disponível em: <https://doi.org/10.1145/3640543.3645203>
- Ren, H. et al. SeLoC-ML: Semantic Low-Code Engineering for Machine Learning Applications in Industrial IoT. In: SATTLER, Ulrike et al. (Orgs.). *The Semantic Web – ISWC 2022*. Cham: Springer International Publishing, 2022. v. 13489 p. 845–862.
- Sanches, I. H. et al. QSAR-Lit: A No-Code Platform for Predictive QSAR Model Development-From Data Curation to Virtual Screening. *Journal of the Brazilian Chemical Society*, v. 36, n. 8, 2025.
- Schötteler, S. et al. A No-Code Platform for Tie Prediction Analysis in Social Media Networks. In: AHLEMANN, Frederik; SCHÜTTE, Reinhard; STIEGLITZ, Stefan (Orgs.). *Innovation Through Information Systems*. Cham: Springer International Publishing, 2021. v. 47 p. 475–491.
- Shin, D. et al. Code-Free Machine Learning Approach for EVO-ICL Vault Prediction: A Retrospective Two-Center Study. *Translational Vision Science and Technology*, v. 13, n. 4, 2024.
- Singh, A.; MARGARIA, T.. Enhancing Decision-Making for Imbalanced Medical Datasets Using BDDs and Low-Code/No-Code. *IT Professional*, v. 26, n. 5, p. 92–98, out. 2024.
- Singh, S.; RAMKUMAR, K. R.; KUKKAR, Ashima. Analysis and Implementation of Microsoft Azure Machine Learning Studio Services with Respect to Machine

- Learning Algorithms. In: AGRAWAL, Rajeev et al. (Orgs.). *Modern Electronics Devices and Communication Systems*. Singapore: Springer Nature Singapore, 2023. v. 948 p. 91–106.
- Sufi, F. Algorithms in Low-Code-No-Code for Research Applications: A Practical Review. *Algorithms*, v. 16, n. 2, 2023.
- Sufi, S. et al. Ember: no-code context enrichment via similarity-based keyless joins. *Proc. VLDB Endow.*, v. 15, n. 3, p. 699–712, nov. 2021.
- Thongkhome, P.; Yonezawa, T.; Kawaguchi, N.. Performance Evaluation of KNIME Low Code Platform in Deep Learning Study and Optimal Hyperparameter Tuning. In: TENCON 2024 - 2024 IEEE REGION 10 CONFERENCE (TENCON). *TENCON 2024 - 2024 IEEE Region 10 Conference (TENCON)*. 1 dez. 2024.
- Wang, Y. et al. Dash: A Low Code Development Platform for AI Applications in Industry. In: 2023 IEEE 14TH ANNUAL UBIQUITOUS COMPUTING, ELECTRONICS & MOBILE COMMUNICATION CONFERENCE (UEMCON). *2023 IEEE 14th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*. 12 out. 2023.
- Yang, P. et al. GraphModo: An Easy-to-Use Visual Construction System of Deep Learning Model. In: JEON, Gwanggil; KONG, Xiangjie (Orgs.). *Applied Computational Intelligence, Informatics and Big Data*. Cham: Springer Nature Switzerland, 2025. v. 616 p. 165–176.
- Zaoui, E.; Bousquet, C.; Duclos, C. Extracting Pediatric Information from Summaries of Product Characteristics with a Large Language Model and No-Code. In: ANDRIKOPOULOU E. et al. (orgs.). *STUDIES IN HEALTH TECHNOLOGY AND INFORMATICS. Stud. Health Technol. Informatics*. IOS Press BV, 2025. Disponível em: <https://doi.org/10.3233/SHTI250651>
- Zhang, Y. et al. MultiML: A Machine Learning Model Construction Tool Based on Multidimensional Views. In: 2024 IEEE FIRST INTERNATIONAL CONFERENCE ON DATA INTELLIGENCE AND INNOVATIVE APPLICATION (DIIA). *2024 IEEE First International Conference on Data Intelligence and Innovative Application (DIIA)*. 23 nov. 2024.
- Zhao, P. et al. Reinforcement Learning Training Framework Based on the Low Code and Behavior Tree. In: CHINESE INSTITUTE OF COMMAND AND CONTROL (Org.). *Proceedings of 2024 12th China Conference on Command and Control*. Singapore: Springer Nature Singapore, 2024. v. 1267 p. 384–393.
- Zhou, Z. et al. InstructPipe: Generating Visual Blocks Pipelines with Human Instructions and LLMs. In: *CHI '25. New York, NY, USA: Association for Computing Machinery, 2025*. Disponível em: <https://doi.org/10.1145/3706598.3713905>
- Zhuang, W. et al. EasyFL: A Low-Code Federated Learning Platform for Dummies. *IEEE Internet of Things Journal*, v. 9, n. 15, p. 13740–13754, 1 ago. 2022.
- Zweihoff, P.; Steffen, B.. Pyrus: An Online Modeling Environment for No-Code Data-Analytics Service Composition. In: MARGARIA, Tiziana; STEFFEN, Bernhard (Orgs.). *Leveraging Applications of Formal Methods, Verification and Validation*. Cham: Springer International Publishing, 2021. v. 13036 p. 18–40