



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PRÓ-REITORIA DE GRADUAÇÃO
DEPARTAMENTO ENGENHARIAS E TECNOLOGIA
CURSO BACHARELADO INTERDISCIPLINAR EM TECNOLOGIA DA
INFORMAÇÃO

MIDHIÃ DE QUEIROZ ELIAS

**REVISÃO SISTEMÁTICA DA LITERATURA SOBRE USO DE GAMIFICAÇÃO E
MACHINE LEARNING NA PREDIÇÃO DE DESEMPENHO ACADÊMICO**

PAU DOS FERROS

2026

MIDHIÃ DE QUEIROZ ELIAS

**REVISÃO SISTEMÁTICA DA LITERATURA SOBRE USO DE GAMIFICAÇÃO E
MACHINE LEARNING NA PREDIÇÃO DE DESEMPENHO ACADÊMICO**

Monografia apresentada à Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Bacharela Interdisciplinar em Tecnologia da Informação.

Orientadora: Náthalee Cavalcanti de Almeida Lima, Profa. Dra.

PAU DOS FERROS

2026

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

E42r Elias, Midhiã de Queiroz.
 Revisão sistemática da literatura sobre uso de
 gamificação e machine learning na predição de
 desempenho acadêmico / Midhiã de Queiroz Elias. -
 2026.
 44 f. : il.

 Orientador: Náthalee Cavalcanti de Almeida
 Lima.
 Monografia (graduação) - Universidade Federal
 Rural do Semi-árido, Curso de Tecnologia da
 Informação, 2026.

 1. Gamificação. 2. Machine learning. 3.
 Desempenho acadêmico. 4. Programação. I. Lima,
 Náthalee Cavalcanti de Almeida, orient. II.
 Título.

Ficha catalográfica elaborada por sistema gerador automático em conformidade
com AACR2 e os dados fornecidos pelo(a) autor(a).
Biblioteca Campus Pau dos Ferros
Bibliotecária: Erlanda Maria Lopes da Silva
CRB: 15/966

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

MIDHIÃ DE QUEIROZ ELIAS

**REVISÃO SISTEMÁTICA DA LITERATURA SOBRE USO DE GAMIFICAÇÃO E
MACHINE LEARNING NA PREDIÇÃO DE DESEMPENHO ACADÊMICO**

Monografia apresentada à Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Bacharela Interdisciplinar em Tecnologia da Informação.

Defendida em: 16 / 06 / 2026.

BANCA EXAMINADORA

Náthalee Cavalcanti de Almeida Lima, Profa. Dra. (UFERSA)
Presidente

Laysa Mabel de Oliveira Fontes, Profa. Dra. (UFERSA)
Membro Examinador

Bruno Borges da Silva, Prof. (UFERSA)
Membro Examinador

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me sustentado e concedido forças para continuar nesta jornada. Mesmo nos momentos em que pensei em desistir, Ele sempre esteve ao meu lado, guiando meus passos e me fortalecendo.

À minha família, especialmente ao meu pai, à minha mãe e à minha irmã, por serem minha base e meu porto seguro. Obrigada por todo o apoio, incentivo e por acreditarem em mim em todos os momentos. Amo vocês infinitamente.

Aos meus amigos Débora, Fernanda, Armando, Clara e Geovana, por compartilharem comigo esta caminhada. Ter vocês ao meu lado tornou essa jornada mais leve, divertida e especial.

À minha orientadora, Profa. Dra. Náthalee Cavalcanti de Almeida Lima, pela paciência, dedicação, apoio e por todas as oportunidades que me proporcionou ao longo deste trabalho.

À banca examinadora, pelo tempo dedicado à avaliação deste trabalho e pelas valiosas contribuições que certamente enriqueceram esta pesquisa.

EPÍGRAFE

"Para que todos vejam, e saibam, e considerem, e juntamente entendam que a mão do SENHOR fez isso, e o Santo de Israel o criou."

Isaías 41:20

RESUMO

As disciplinas introdutórias de programação representam um desafio significativo para estudantes dos cursos da área de tecnologia, estando frequentemente associadas a dificuldades de aprendizagem e elevados índices de reprovação. Nesse contexto, a gamificação surge como uma estratégia capaz de tornar o processo de ensino-aprendizagem mais interativo e motivador, estimulando o engajamento e o rendimento acadêmico dos estudantes. Além disso, técnicas de *Machine Learning* podem ser utilizadas para prever alunos em risco de baixo desempenho, possibilitando a adoção antecipada de intervenções pedagógicas. Este trabalho apresenta uma Revisão Sistemática da Literatura com o objetivo de investigar como a gamificação associada ao *Machine Learning* tem sido aplicada na predição do desempenho acadêmico em disciplinas introdutórias de programação no ensino superior. A metodologia contemplou etapas de busca em bases como o *ACM*, *IEEE Xplore*, *Scopus*, *Science Direct* e *Web of Science*, seleção, avaliação da qualidade e extração de dados dos estudos analisados. Ao todo, foram selecionados 30 artigos. Os resultados indicaram que algoritmos como Redes Neurais, *Random Forest*, SVM e KNN são amplamente empregados na predição do desempenho estudantil, sendo as Redes Neurais Artificiais (RNAs) as que apresentaram melhor desempenho. Além disso, estratégias gamificadas apresentaram contribuições positivas para o engajamento e a aprendizagem. Também foram identificadas métricas de avaliação como *Accuracy*, *F1-score*, *Precision*, *Recall*, R^2 e *AUC*, sendo a *Accuracy* a métrica mais utilizada nos estudos analisados. Observou-se, ainda, uma tendência crescente na adoção de abordagens que integram gamificação e técnicas de *Machine Learning*, com o objetivo de aumentar o engajamento dos estudantes e possibilitar a identificação precoce de alunos com risco de baixo desempenho acadêmico. Contudo, a literatura revela que ainda é reduzido o número de estudos que combinam essas duas abordagens de forma integrada para a detecção antecipada de estudantes em situação de risco acadêmico, evidenciando uma lacuna de pesquisa que merece maior atenção por parte da comunidade científica.

Palavras-chave: gamificação; machine learning; desempenho acadêmico; programação.

ABSTRACT

Introductory programming courses represent a significant challenge for students in technology-related programs, often being associated with learning difficulties and high failure rates. In this context, gamification emerges as a strategy capable of making the teaching-learning process more interactive and motivating, fostering student engagement and academic performance. Furthermore, Machine Learning techniques can be used to predict students at risk of poor performance, enabling the early adoption of pedagogical interventions. This study presents a Systematic Literature Review aimed at investigating how gamification combined with Machine Learning has been applied to predict academic performance in introductory programming courses in higher education. The methodology included search, selection, quality assessment, and data extraction stages conducted across databases such as ACM, IEEE Xplore, Scopus, ScienceDirect, and Web of Science. A total of 30 studies were selected. The results indicate that algorithms such as Neural Networks, Random Forest, SVM, and KNN are widely employed in student performance prediction, with Artificial Neural Networks (ANNs) showing the best performance. In addition, gamification strategies demonstrated positive contributions to student engagement and learning. Evaluation metrics such as Accuracy, F1-score, Precision, Recall, R^2 , and AUC were also identified, with Accuracy being the most frequently used metric among the analyzed studies. Furthermore, a growing trend was observed in the adoption of approaches that integrate gamification and Machine Learning techniques to increase student engagement and enable the early identification of students at risk of poor academic performance. However, the literature reveals that the number of studies combining these two approaches in an integrated manner for the early detection of academically at-risk students is still limited, highlighting a research gap that deserves greater attention from the scientific community.

Keywords: gamification; machine learning; academic performance; programming.

LISTA DE FIGURAS

Figura 1 - Etapas da Revisão Sistemática da Literatura	23
Figura 2 - Estudos por Base de Dados	30
Figura 3 - Critérios de Exclusão, Inclusão e Qualidade	32
Figura 4 - Tarefas de <i>Machine Learning</i>	34
Figura 5 - Algoritmos utilizados	35
Figura 6 - Métricas de avaliação	37
Figura 7 - Elementos de gamificação	40
Figura 8 - Relação do desempenho	41

LISTA DE QUADROS

Quadro 1 - Questões de Pesquisa	24
Quadro 2 - Strings utilizadas na condução da pesquisa	25
Quadro 3 - Critérios de Inclusão e Exclusão	26
Quadro 4 - Critérios de Qualidade	27
Quadro 5 - Formulário de Extração dos dados	27

LISTA DE ABREVIATURAS E SIGLAS

AUC	Área Sob a Curva (<i>Area Under the Curve</i>)
CS1	Disciplina Introdutória de Programação (<i>Computer Science 1</i>)
ED	Extração de Dados
KNN	K Vizinhos Mais Próximos (<i>K-Nearest Neighbors</i>)
LSM	Sistema de Gerenciamento da Aprendizagem (<i>Learning Management System</i>)
LSTM	Memória de Longo e Curto Prazo (<i>Long Short-Term Memory</i>)
ML	Aprendizado de Máquina (<i>Machine Learning</i>)
QL	Questão de Qualidade
QP	Questão de Pesquisa
RNA	Rede Neural Artificial
RSL	Revisão Sistemática da Literatura
STEM	Ciência, Tecnologia, Engenharia e Matemática (<i>Science, Technology, Engineering and Mathematics</i>)
SVM	Máquina de Vetores de Suporte (<i>Support Vector Machine</i>)

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivos	15
1.2	Apresentação do Trabalho	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Revisão Sistemática da Literatura	17
2.1.1	Planejamento	17
2.1.2	Condução	18
2.1.3	Relato Dos Resultados	18
2.2	Gamificação	19
2.2.1	Elementos de Gamificação	19
2.3	<i>Machine Learning</i>	20
2.3.1	Tarefas de <i>Machine Learning</i>	20
2.3.2	Algoritmos de <i>Machine Learning</i>	21
3	METODOLOGIA	23
3.1	Planejamento	24
3.1.1	Questões de Pesquisa	24
3.1.2	Strings de Busca	25
3.1.3	Critérios de Inclusão e Exclusão	26
3.1.4	Critérios de Qualidade	26
3.1.5	Formulário de Extração de Dados	27
3.2	Condução	28
3.2.1	Critérios de Inclusão e Exclusão.....	29
3.2.2	Critérios de Qualidade e Extração dos dados	29
3.3	Relato Dos Resultados	29
4	RESULTADOS E DISCUSSÕES	30
4.1	Seleção e Qualidade dos Estudos	31
4.2	Extração dos Dados	32
4.2.1	Tarefas de <i>Machine Learning</i>	33
4.2.2	Algoritmos de <i>Machine Learning</i>	34
4.2.3	Métricas de validação dos Modelos	36
4.2.4	Gamificação e Ferramentas de Aprendizagem	38

4.2.5	Predição de Desempenho Acadêmico com ML	40
4.2.6	Limitações e lacunas encontradas na literatura	41
5	CONSIDERAÇÕES FINAIS	43
	REFERÊNCIAS	45

1 INTRODUÇÃO

As disciplinas introdutórias de programação apresentam desafios significativos para os estudantes, sendo frequentemente associadas a dificuldades de aprendizagem, baixo desempenho acadêmico e elevados índices de reprovação. Os cursos pertencentes às áreas STEM (Ciência, Tecnologia, Engenharia e Matemática) apresentam menores taxas de conclusão quando comparados a cursos de outras áreas do conhecimento, evidenciando desafios relacionados ao desempenho acadêmico e à permanência dos estudantes (Tenente, 2025). Essas áreas costumam exigir conhecimentos matemáticos e de raciocínio lógico mais aprofundados, o que pode dificultar a adaptação dos alunos, especialmente daqueles que apresentam lacunas provenientes da educação básica. Além disso, estudos apontam que, na área de Tecnologia da Informação, a taxa de evasão pode ultrapassar 38% (SEMESP, 2023, p. 68). Diante desse cenário, torna-se necessária a adoção de estratégias que tornem o processo de ensino-aprendizagem mais dinâmico e eficaz, contribuindo para a permanência, o engajamento e o desempenho acadêmico dos estudantes.

Tendo em vista essa dificuldade, muitos estudos focam na integração da gamificação, utilizando elementos de jogos para motivar os alunos a aprenderem. Os jogos auxiliam os professores a criarem ambientes onde os alunos aprendem de forma dinâmica e com propósito educacional. Isso gera uma competição saudável que motiva a participação nas atividades, utilizando elementos como pontos, *rankings* e *badges* (medalhas) para desenvolver o interesse dos estudantes (Vasconcelos et al., 2025).

A gamificação ajuda no desempenho acadêmico porque o ensino interativo faz com que os alunos sintam mais vontade de aprender. Ela surgiu como uma ferramenta pedagógica que utiliza o engajamento dos jogos para estimular os estudantes. O estudo de Arkabaev et al. (2026) mostra que a gamificação gerou um aumento de 68% na motivação dos alunos, transformando o estudo em uma atividade estimulante e não em uma obrigação. Além disso, utilizar jogos ajuda o aluno a aprender mais rápido, reduzindo em até 35% o tempo que ele levaria para entender os conceitos dados em sala.

Sendo assim, é notável que os educadores precisam identificar cedo os

alunos com risco de desistência ou que estão com dificuldades. O uso de técnicas de predição com *Machine Learning* no âmbito educacional tem se mostrado eficaz para identificar padrões de desempenho e prever resultados. Estudos apontam a importância da previsão de desempenho logo na fase inicial do curso, permitindo a implementação de intervenções pedagógicas que auxiliem no processo de aprendizagem dos estudantes (Llanos; Bucheli; Restrepo-Calle, 2023). A plataforma TôSabendo valida o uso de algoritmos como Árvores de Decisão para prever o rendimento acadêmico dos estudantes, permitindo que os professores realizem estratégias pedagógicas antes que a reprovação ocorra (Oliveira, 2023).

Dessa forma, este estudo propõe a realização de uma Revisão Sistemática da Literatura (RSL), conduzida por meio da plataforma online gratuita Parsifal, que auxilia na execução das etapas da revisão de forma padronizada. O objetivo é identificar o estado da arte das pesquisas relacionadas às áreas de Informática na Educação, Gamificação e ML. Busca-se analisar as principais abordagens, tendências e contribuições nesses campos, bem como mapear lacunas na literatura, a fim de direcionar futuras investigações. Diante desse contexto, surge o seguinte questionamento: como as ferramentas de gamificação têm sido utilizadas em conjunto com técnicas de ML para análise e predição do desempenho acadêmico?

1.1 Objetivos

Investigar, por meio de uma Revisão Sistemática da Literatura, se a aplicação da gamificação em conjunto com técnicas de ML contribui para a melhoria da aprovação nas disciplinas introdutórias de programação no ensino superior.

Para alcançar esse objetivo, o estudo busca identificar quais técnicas de ML são mais utilizadas na literatura para a análise e predição do desempenho acadêmico dos estudantes, bem como analisar de que forma a gamificação contribui para o engajamento e a aprendizagem. Além disso, pretende mapear as principais ferramentas de gamificação utilizadas para avaliar o desempenho dos alunos e investigar quais características das plataformas de aprendizagem influenciam o desempenho final na disciplina. O estudo também busca avaliar como o uso de ML em plataformas de aprendizagem pode auxiliar na identificação precoce de estudantes em risco de baixo desempenho, além de identificar quais métricas de

avaliação são consideradas mais adequadas para validar modelos de ML na predição de desempenho em ambientes gamificados. Por fim, pretende mapear lacunas e aspectos ainda pouco explorados na literatura sobre a integração entre gamificação e ML para predição de desempenho.

1.2 Apresentação do Trabalho

A estrutura do trabalho tem a seguinte divisão: a Seção 2 apresenta a fundamentação teórica. Na Seção 3, é apresentada a metodologia, descrevendo os fundamentos metodológicos adotados. A Seção 4 apresenta os resultados e discussões, mostrando os resultados obtidos nos estudos e respondendo às questões de pesquisa. A Seção 5 apresenta as considerações finais e, por fim, as referências.

2 FUNDAMENTAÇÃO TEÓRICA

A Fundamentação Teórica apresenta os principais conceitos e abordagens que sustentam esta pesquisa. Inicialmente, são discutidos os fundamentos da Revisão Sistemática da Literatura (RSL), metodologia adotada para a condução do estudo. Em seguida, são abordados os conceitos de gamificação e ML, destacando suas aplicações no contexto educacional e sua relevância para a análise e predição do desempenho acadêmico dos estudantes.

2.1 Revisão Sistemática da Literatura

A Revisão Sistemática da Literatura (RSL) é uma metodologia com o objetivo de identificar, avaliar e interpretar as pesquisas relevantes na área em estudo. De acordo com as diretrizes de Kitchenham (2004), a RSL segue passos estruturados que se dividem em três partes: Planejamento, Condução e Relato dos Resultados.

2.1.1 Planejamento

A fase de planejamento da RSL tem o objetivo de verificar a necessidade de realizar uma revisão sistemática sobre determinada área de pesquisa. A RSL busca fazer uma análise completa dos estudos, minimizando o viés do pesquisador (Kitchenham, 2004).

Nesta etapa, é elaborado o protocolo de revisão, que funciona como um roteiro de estudo, reduzindo assim os vieses. A primeira parte do planejamento é a elaboração das questões de pesquisa, uma vez que elas são a atividade mais importante do planejamento e direcionam todo o estudo. A definição das perguntas é fundamental porque elas guiam todo o processo, uma vez que todas as etapas seguintes são conduzidas com o objetivo de responder às perguntas estabelecidas.

A partir das questões de pesquisa elaboradas, são definidas as *strings* de busca, que consistem em combinações de palavras-chave e operadores booleanos utilizados para identificar estudos relevantes em bases de dados científicas que apresentam o maior número de estudos realizados na área da computação e tecnologia.

Posteriormente, são elaborados os critérios de inclusão e exclusão dos trabalhos, que servem para validar e selecionar os estudos. Em seguida, critérios de qualidade são definidos. De acordo com Kitchenham (2004), os critérios de qualidade são utilizados para aumentar a confiabilidade dos resultados da revisão, permitindo selecionar estudos com maior rigor metodológico e confiabilidade dos estudos. Por fim, é elaborado o formulário com os dados que serão extraídos.

2.1.2 Condução

A fase da condução da Revisão Sistemática da Literatura é o processo de execução do protocolo definido. Nessa etapa, são realizadas as buscas dos estudos nas bases de dados, a aplicação dos critérios de inclusão e exclusão, a avaliação da qualidade dos estudos e a extração dos dados e síntese dos dados.

Inicialmente, são realizadas buscas nas bases de dados científicas por meio das strings definidas no protocolo de pesquisa. Em seguida, os estudos retornados passam por um processo de seleção, no qual são aplicados os critérios de inclusão e exclusão. Essa etapa ocorre em duas fases: primeiramente, realiza-se a leitura dos títulos e resumos dos trabalhos recuperados; posteriormente, é realizada a leitura completa dos artigos para verificar sua conformidade com os critérios estabelecidos.

Após a seleção dos estudos, é realizada a avaliação da qualidade metodológica, com o objetivo de garantir a confiabilidade dos resultados e reduzir possíveis vieses. Por fim, realiza-se a extração dos dados por meio de formulários padronizados, nos quais são coletadas as informações necessárias para responder às questões de pesquisa. A execução dessas etapas garante maior rigor metodológico ao processo de revisão, contribuindo para a confiabilidade dos resultados obtidos.

2.1.3 Relato dos resultados

A fase de relato dos resultados em uma RSL consiste na elaboração do relatório final, que apresenta a análise dos dados extraídos dos estudos selecionados e os resultados obtidos ao longo do processo de revisão.

2.2 Gamificação

A gamificação consiste na utilização de elementos de jogos em contextos que não são jogos, com o objetivo de aumentar o engajamento, a motivação e a participação dos indivíduos em determinadas atividades. No contexto educacional, a gamificação tem sido aplicada como uma estratégia para tornar o processo de ensino-aprendizagem mais dinâmico e atrativo, incentivando os estudantes a participarem das atividades em sala de aula (Murr; Ferrari, 2020).

Para isso, são utilizados elementos comuns em jogos. Esses elementos funcionam como mecanismos de incentivo, permitindo que os alunos acompanhem seu progresso, recebam recompensas por suas conquistas e consigam acompanhar o seu desempenho. No ensino de programação, a gamificação pode ser aplicada de diferentes formas, desde a utilização de quizzes e competições em sala de aula até o desenvolvimento de plataformas e jogos educacionais que apresentam missões, desafios e tarefas relacionadas aos conteúdos estudados, tornando a aprendizagem mais envolvente, contribuindo para o desenvolvimento das habilidades dos estudantes e para a melhoria do desempenho acadêmico (Murr; Ferrari, 2020).

No ensino de programação, a gamificação tem recebido destaque devido aos desafios enfrentados pelos estudantes em disciplinas introdutórias, frequentemente associadas a dificuldades de aprendizagem e elevados índices de reprovação. Nesse contexto, a utilização de elementos de jogos pode contribuir para aumentar o interesse dos alunos, estimular sua participação nas atividades e favorecer a permanência no processo de aprendizagem.

2.2.1 Elementos de Gamificação

Os elementos mais utilizados na gamificação são pontos, níveis, medalhas (*badges*), desafios, *rankings* e *feedback* imediato. Os pontos podem ser atribuídos aos alunos de acordo com seu desempenho e acertos nas atividades propostas. Os desafios consistem em tarefas que devem ser cumpridas pelos estudantes ao longo do processo de aprendizagem. As medalhas funcionam como recompensas pelo cumprimento de objetivos e pela realização de atividades. Os níveis permitem acompanhar a progressão do aluno, que avança conforme completa desafios e

acumula pontos. Já o *feedback* possibilita que os estudantes acompanhem seu desempenho durante a execução das atividades, identificando seus acertos e aspectos que precisam ser melhorados (Murr; Ferrari, 2020).

A combinação desses elementos permite criar experiências de aprendizagem mais interativas e motivadoras, uma vez que mecanismos como *feedback* imediato, desafios progressivos e sistemas de recompensas podem contribuir para aumentar a motivação dos estudantes e estimular sua participação nas atividades educacionais. Dessa forma, os elementos de gamificação desempenham papel importante na promoção do engajamento e no apoio ao processo de aprendizagem.

Além de favorecer o engajamento dos estudantes, ambientes gamificados geram uma grande quantidade de dados relacionados ao comportamento e desempenho dos usuários. Esses dados podem ser analisados por técnicas de ML, possibilitando a identificação de padrões e a realização de previsões sobre o desempenho acadêmico.

2.3 Machine Learning

Machine Learning é uma aplicação da Inteligência Artificial que permite ensinar máquinas a aprender, identificar padrões e tomar decisões a partir dos dados fornecidos. Para isso, são utilizados algoritmos e conjuntos de dados para criar modelos de ML, que são treinados com o objetivo de aprender com as informações disponíveis e realizar previsões ou classificações. Dessa forma, as máquinas conseguem melhorar seu desempenho à medida que novos dados são processados (Harve, 2021).

2.3.1 Tarefas de Machine Learning

As principais tarefas de ML envolvem o aprendizado supervisionado e o aprendizado não supervisionado. O aprendizado supervisionado tem como objetivo prever valores de saída com base em um conjunto de dados de entrada, sendo que o sistema aprende a partir de exemplos previamente fornecidos. Nesse tipo de aprendizado, destacam-se as tarefas de classificação e regressão. A classificação utiliza algoritmos para rotular dados em categorias específicas, enquanto a

regressão consiste em um modelo de previsão utilizado para estimar valores contínuos, podendo ser aplicada para prever o desempenho acadêmico, habilidades de aprendizagem e outros fatores relacionados aos estudantes.

Já o aprendizado não supervisionado tem como objetivo identificar associações, padrões e a forma como os dados estão organizados, sem a necessidade de exemplos previamente rotulados. Entre suas principais tarefas está o clustering, uma técnica que organiza os dados em grupos com características semelhantes, permitindo a identificação de padrões entre os dados analisados (Mitchell, 1997; Hastie; Tibshirani; Friedman, 2009).

O *Deep Learning* (Aprendizado Profundo) utiliza redes neurais com um grande número de camadas e parâmetros para aprender padrões complexos a partir dos dados. Já o *Ensemble Learning* consiste na combinação de múltiplos modelos de aprendizagem de máquina com o objetivo de obter maior precisão e robustez nos resultados (Shinde; Shah, 2018).

Essas tarefas têm sido amplamente utilizadas no contexto educacional para analisar o comportamento dos estudantes, identificar padrões de aprendizagem e apoiar a predição do desempenho acadêmico.

2.3.2 Algoritmos de *Machine Learning*

Os algoritmos de ML servem para ensinar as máquinas a realizar tarefas. Dentro do ML estão presentes algoritmos como Redes Neurais, *Random Forest*, SVM, KNN, entre outros. O algoritmo de Redes Neurais é usado para reconhecimento de imagens, processamento de linguagem natural e previsões. O *Random Forest* combina várias árvores de decisão para realizar classificações mais precisas. O SVM é um algoritmo de aprendizado supervisionado utilizado para tarefas como a classificação de texto. O KNN é um algoritmo de classificação amplamente utilizado para classificar novos dados ao identificar padrões, como ocorre na detecção de objetos (ENAP, 2020; IBM, 2025).


Esses algoritmos têm sido amplamente empregados em pesquisas educacionais devido à sua capacidade de identificar padrões complexos nos dados dos estudantes e gerar previsões com elevados níveis de precisão. Dessa forma,

tornam-se ferramentas importantes para apoiar processos de monitoramento e tomada de decisão em ambientes educacionais.

3 METODOLOGIA

A Revisão Sistemática da Literatura (RSL) é uma metodologia com o objetivo de identificar, avaliar e interpretar as pesquisas relevantes na área em estudo. Conforme as diretrizes de Kitchenham (2004), a RSL deve seguir um protocolo rigoroso composto por três fases principais: Planejamento, Condução e Relato dos Resultados conforme ilustrado na Figura 1. Essas etapas garantem a transparência, a reprodutibilidade e o rigor metodológico do estudo. As atividades desenvolvidas em cada uma dessas fases são detalhadas nas subseções 3.1, 3.2 e 3.3.

Figura 1 - Etapas da Revisão Sistemática da Literatura



Fonte: Autoria Própria (2026)

Foram utilizadas ferramentas de Inteligência Artificial Generativa, especificamente o ChatGPT (OpenAI) e o NotebookLM (Google), como apoio ao desenvolvimento desta pesquisa. Essas ferramentas auxiliaram em atividades como tradução de artigos, revisão gramatical do texto e esclarecimento de conceitos metodológicos. Todo o conteúdo produzido foi revisado, validado e adaptado pela autora, que assume integral responsabilidade pela originalidade,

precisão e veracidade das informações apresentadas, em conformidade com a Portaria CNPq nº 2.664/2026.

3.1 Planejamento

Na etapa de Planejamento são definidas as questões de pesquisa, as strings de busca, os critérios de inclusão e exclusão, os critérios de qualidade e o formulário de extração dos dados. De acordo com Kitchenham (2004), antes de começar uma RSL, é necessário identificar a necessidade da revisão. A elaboração de uma RSL surge a partir da necessidade de identificar, avaliar e interpretar todas as pesquisas disponíveis sobre a área de forma detalhada e imparcial. A RSL busca fazer uma análise completa dos estudos, minimizando o viés do pesquisador (Kitchenham, 2004).

3.1.1 Questões de Pesquisa

O objetivo desta RSL é investigar se a aplicação da gamificação, em conjunto com as técnicas de ML, contribui para a melhoria da aprovação nas disciplinas introdutórias de programação no ensino superior. Para responder a esse objetivo, foram definidas as questões de pesquisa apresentadas no Quadro 1, as quais orientaram todas as etapas da revisão.

Quadro 1 - Questões de Pesquisa

(continua)

Questão	Descrição
QP01	Quais técnicas e tarefas de <i>Machine Learning</i> são mais utilizadas na literatura para análise e predição do desempenho acadêmico?
QP02	Quais métricas de avaliação são mais adequadas para validar modelos de ML na predição de desempenho acadêmico em ambientes de aprendizagem gamificados?
QP03	De que forma a gamificação contribui para o engajamento e aprendizagem em disciplinas introdutórias de programação?
QP04	Quais ferramentas de gamificação são utilizadas para avaliar o desempenho?
QP05	Quais características de plataformas de aprendizagem influenciam no desempenho final na disciplina?

Quadro 1 - Questões de Pesquisa

(conclusão)

Questão	Descrição
QP06	Como o uso de uma plataforma de aprendizagem com auxílio de ML pode auxiliar na identificação precoce de estudantes com risco de baixo desempenho em disciplinas introdutórias de programação?
QP07	Quais lacunas de pesquisa existem na literatura sobre a aplicação de técnicas de Machine Learning em ambientes de aprendizagem gamificados para a predição do desempenho acadêmico?

Fonte: Autoria Própria (2026)

3.1.2 Strings de Busca

Com as questões de pesquisa definidas, realizou-se a busca por estudos utilizando strings relacionadas ao tema da pesquisa, combinadas por meio dos operadores booleanos AND e OR. As buscas foram realizadas nas bases ACM, IEEE Xplore, ScienceDirect, Scopus e Web of Science, selecionadas por concentrarem um grande volume de publicações nas áreas de Computação e Tecnologia. Em cada base de dados foram utilizadas três strings de busca distintas, com o objetivo de ampliar a recuperação de estudos relevantes e garantir uma cobertura mais abrangente da literatura. Na base ScienceDirect, as strings originalmente definidas no protocolo precisaram ser adaptadas devido às restrições da plataforma quanto à quantidade de conectores booleanos e termos permitidos por consulta. As strings utilizadas estão apresentadas no Quadro 2.

Quadro 2 - Strings utilizadas na condução da pesquisa

(continua)

Base de Dados	String de Busca
ACM IEEE Xplore Scopus Web of Science	(("machine learning" OR "educational data mining") AND ("student performance" OR "academic performance" OR predict*) AND (gamification OR "game-based learning") AND ("computer science education" OR "introductory programming" OR CS1)) (("machine learning" OR "educational data mining") AND ("student performance" OR "academic performance" OR predict*) AND (gamification OR "game-based learning") AND ("introductory programming" OR programming)) (("machine learning" OR "educational data mining" OR "artificial intelligence") AND ("academic performance" OR "student performance" OR predict*) AND (gamification OR "game-based learning") AND (programming OR "computing education" OR "computer science education" OR CS1 OR "introductory programming"))

Quadro 2 - *Strings* utilizadas na condução da pesquisa

(conclusão)

Base de Dados	String de Busca
ScienceDirect	("machine learning" OR "educational data mining") AND ("student performance" OR "academic performance") AND (gamification OR "game-based learning") AND ("introductory programming") ("machine learning" OR "educational data mining") AND ("student performance" OR "academic performance" OR "predict") AND (gamification OR "game-based learning") AND ("introductory programming" OR programming) ("machine learning" OR "educational data mining" OR "artificial intelligence") AND ("student performance" OR "academic performance") AND (gamification OR "game-based learning") AND ("introductory programming")

Fonte: Autoria Própria (2026)

3.1.3 Critérios de Inclusão e Exclusão

Em seguida, foram definidos os critérios de inclusão e exclusão, apresentados no Quadro 3, com o objetivo de selecionar os estudos mais relevantes e garantir o rigor metodológico da revisão.

Quadro 3 - Critérios de Inclusão e Exclusão

Critérios de Inclusão	Critérios de Exclusão
Artigos publicados entre 2015 e 2026	Artigos publicados anterior a 2015
Artigos em Inglês e Português	Artigos com revisões secundárias
Artigos revisados por pares	Trabalhos duplicados
Artigos publicados em periódicos e congressos	Artigos fora do tema

Fonte: Autoria Própria (2026)

3.1.4 Critérios de Qualidade

Posteriormente, foram elaborados os critérios de qualidade, apresentados no Quadro 4, com o objetivo de garantir a confiabilidade das evidências analisadas. Para isso, os estudos selecionados foram submetidos a uma avaliação por meio de um checklist, que permitiu verificar a qualidade metodológica dos trabalhos.

Quadro 4 - Critérios de Qualidade

Critério	Descrição
QL01	O objetivo do estudo está claramente definido?
QL02	A metodologia utilizada é bem descrita e permite a replicação?
QL03	O contexto de ensino de programação (ex: CS1, linguagens) está explícito?
QL04	O estudo identifica e descreve claramente quais componentes de jogo foram utilizados (ex: pontos, medalhas, <i>rankings</i> , níveis ou <i>feedback</i> imediato)?
QL05	O estudo descreve como a gamificação foi integrada ao conteúdo de programação e avalia o seu impacto na motivação ou engajamento dos estudantes?
QL06	O estudo explica a base teórica ou o motivo psicológico para o uso da gamificação?
QL07	As técnicas de <i>Machine Learning</i> utilizadas são descritas de forma clara e detalhada, especificando os algoritmos, o processo de treinamento e os parâmetros de configuração?
QL08	O dataset utilizado é descrito com clareza, informando a origem dos dados, o tamanho da amostra e quais variáveis ou características foram extraídas para alimentar os modelos?
QL09	O estudo utiliza métricas de avaliação de ML adequadas (Acurácia, F1, etc)?
QL10	Os resultados são consistentes e as limitações/ameaças são discutidas?

Fonte: Autoria Própria (2026)

3.1.5 Formulário de Extração de Dados

Por último, foi elaborado o formulário de extração de dados, apresentado no Quadro 5, utilizado para padronizar a coleta das informações dos estudos selecionados. Os dados extraídos serviram de base para responder às questões de pesquisa e realizar a síntese dos resultados.

Quadro 5 - Formulário de Extração de Dados

(continua)

Código	Dado extraído
ED01	Ano de publicação
ED02	Resumo do estudo
ED03	Técnicas de <i>Machine Learning</i> utilizadas
ED04	Algoritmos de <i>Machine Learning</i> utilizados
ED05	Métricas de avaliação

Quadro 5 - Formulário de Extração de Dados

(conclusão)

Código	Dado extraído
ED06	Uso de gamificação (sim, não)
ED07	Ferramenta de gamificação utilizada
ED08	Tipo de impacto (engajamento, desempenho, motivação)
ED09	Relação com o desempenho (positiva, negativa, neutra)
ED10	Limitações apontadas pelos estudos
ED11	Lacunas identificadas
ED12	Trabalhos futuros sugeridos

Fonte: Autoria Própria (2026)

3.2 Condução

Na fase de condução, os estudos são coletados, selecionados e avaliados para a extração e síntese dos dados. Para auxiliar nesse processo, foi utilizada a ferramenta online Parsifal, que oferece recursos para apoiar o desenvolvimento de Revisões Sistemáticas da Literatura.

O Parsifal é uma plataforma online gratuita que permite importar os estudos retornados a partir das strings de busca definidas na pesquisa. Após a importação, é possível realizar a seleção dos estudos com base nas informações exportadas das bases de dados, como título, resumo e ano de publicação.

Além disso, a plataforma possibilita a criação de formulários de avaliação da qualidade dos estudos, permitindo que apenas os trabalhos aprovados avancem para as etapas seguintes da revisão. Posteriormente, é realizado o processo de extração de dados por meio de um formulário específico, no qual são coletadas as informações necessárias para responder às questões de pesquisa. Ao final, o Parsifal permite exportar os dados obtidos durante a extração para posterior análise dos resultados. Neste trabalho, foi utilizada a versão 2.2.1 da plataforma.

3.2.1 Critérios de Inclusão e Exclusão

A aplicação dos critérios de inclusão e exclusão foi realizada em duas etapas. Inicialmente, foi efetuada a leitura dos títulos e resumos dos estudos recuperados, a fim de verificar sua aderência aos critérios previamente definidos. Em seguida, os trabalhos selecionados foram submetidos à leitura completa, permitindo uma avaliação mais detalhada e a confirmação de sua elegibilidade para compor a revisão.

3.2.2 Critérios de Qualidade e Extração dos dados

A avaliação da qualidade dos estudos selecionados foi realizada por meio da leitura completa dos artigos e da aplicação dos critérios de qualidade previamente definidos. Para cada critério, foi atribuída pontuação 0 quando o estudo não atendia ao critério, 0,5 quando o atendia parcialmente e 1 quando o atendia integralmente. Considerando os dez critérios estabelecidos, a pontuação máxima possível para cada artigo era de 10 pontos. Foi adotada uma pontuação mínima de 7 pontos como critério de qualidade, com o objetivo de garantir que apenas estudos com qualidade metodológica satisfatória fossem incluídos na revisão.

A extração dos dados foi conduzida de forma padronizada por meio de formulários específicos, contemplando informações como ano de publicação, ferramentas empregadas, algoritmos e métricas de avaliação utilizadas. Para apoiar esse processo, foi utilizada a ferramenta Parsifal, que possibilita a aplicação dos critérios de seleção e qualidade, bem como o registro e a exportação dos dados extraídos ao final da revisão.


3.3 Relato dos resultados

Na fase final do estudo, é elaborado o relatório da revisão sistemática, apresentando a análise dos dados extraídos dos estudos selecionados e dos resultados das buscas realizadas.

4 RESULTADOS E DISCUSSÕES

A aplicação das estratégias de busca nas bases de dados selecionadas resultou na identificação de um conjunto de estudos potencialmente relevantes para a pesquisa. A Figura 2 apresenta a distribuição dos estudos ao longo das etapas de filtragem, permitindo visualizar o processo de seleção dos trabalhos.

Figura 2 - Estudos por Base de Dados



Fonte: Autoria Própria (2026)

A Figura 2 apresenta a distribuição dos estudos recuperados por base de dados. Observa-se que a ScienceDirect foi a fonte que retornou o maior número de artigos, concentrando 76,9% dos estudos identificados. Em seguida, a ACM representou 15,9% dos resultados, enquanto a IEEE correspondeu a 3,1%. As bases Scopus e Web of Science apresentaram as menores participações, com 2,1% e 2,0% dos estudos recuperados, respectivamente. Esses resultados evidenciam a predominância da ScienceDirect como principal fonte de publicações relacionadas ao tema investigado. Após a etapa de recuperação dos estudos, os artigos identificados foram submetidos ao processo de seleção e avaliação da qualidade,

com o objetivo de garantir a inclusão apenas dos trabalhos mais relevantes e metodologicamente adequados à pesquisa.

4.1 Seleção e Qualidade dos Estudos


A aplicação das estratégias de busca nas bases de dados resultou na recuperação de 2.245 estudos. Inicialmente, foi realizada a leitura dos títulos e resumos de todos os trabalhos, com o objetivo de aplicar os critérios de inclusão e exclusão definidos no protocolo da revisão. Nessa etapa, 1.776 artigos foram excluídos por não atenderem a pelo menos um dos critérios de inclusão estabelecidos, enquanto 374 foram removidos por serem registros duplicados. Ao final dessa triagem, 95 estudos permaneceram elegíveis para a etapa de avaliação da qualidade. A Tabela 1 apresenta a quantidade de trabalhos recuperados em cada base de dados, bem como o número de estudos remanescentes após a aplicação dos critérios de inclusão e exclusão. Adicionalmente, a Figura 3 resume o processo de seleção dos estudos, apresentando a quantidade de artigos identificados, excluídos e selecionados em cada etapa da revisão.

Tabela 1 - Resultado da Seleção dos Artigos

Base de Dados	Artigos Pré-Selecionados	Artigos Selecionados
ACM	356	16
IEEE	69	17
ScienceDirect	1727	54
Scopus	47	6
Web of Science	46	2
Total	2245	95

Fonte: Autoria Própria (2026)

Figura 3 - Critérios de Exclusão, Inclusão e Qualidade



Fonte: Autoria Própria (2026)

Após a etapa de seleção, os 95 estudos elegíveis foram submetidos à avaliação da qualidade metodológica por meio de um formulário padronizado implementado na ferramenta Parsifal. Essa avaliação foi realizada com base na leitura completa dos artigos, permitindo verificar se os estudos abordaram adequadamente os aspectos relevantes para responder às questões de pesquisa. Os trabalhos que obtiveram pontuação entre 7 e 10 foram considerados aptos para a etapa subsequente, na qual foi realizada a extração dos dados necessários para a síntese e análise dos resultados.

4.2 Extração dos Dados

A etapa de extração dos dados foi realizada de forma padronizada por meio de um formulário estruturado na ferramenta Parsifal, de maneira semelhante ao processo adotado para a avaliação da qualidade dos estudos. Dos 95 artigos submetidos à avaliação de qualidade, 30 obtiveram pontuação entre 7 e 10 e, consequentemente, foram selecionados para a fase de extração dos dados.

Para cada estudo selecionado, foram coletadas informações relacionadas ao ano de publicação, resumo do artigo, técnicas empregadas, métricas de avaliação


utilizadas, algoritmos de ML adotados e métodos de validação aplicados. Além disso, foram extraídos dados específicos sobre a gamificação, incluindo as ferramentas utilizadas, os elementos de gamificação empregados, os impactos observados no desempenho dos participantes e os principais resultados reportados pelos autores. Também foram registradas as limitações identificadas nos estudos, as lacunas de pesquisa apontadas e as sugestões de trabalhos futuros.

A extração sistemática dessas informações possibilitou a organização e a análise dos dados dos 30 estudos selecionados, fornecendo subsídios para responder às questões de pesquisa definidas nesta revisão. A partir dos dados coletados, foi possível identificar as principais tarefas de ML empregadas nos estudos analisados, bem como as abordagens mais utilizadas para a predição do desempenho acadêmico em ambientes educacionais gamificados.

4.2.1 Tarefas de *Machine Learning*

As tarefas de ML têm sido amplamente empregadas na predição do desempenho acadêmico dos estudantes. Em relação à QP01, a Figura 4 apresenta a distribuição das tarefas identificadas nos 30 estudos analisados. Observa-se que a tarefa de Classificação foi a mais utilizada, correspondendo a 25,8% das ocorrências encontradas nos artigos selecionados.

A categoria "Outros" reúne tarefas que não estavam previamente contempladas no formulário de extração de dados, mas que foram identificadas durante a análise dos estudos. Entre elas, destacam-se abordagens como *Bayesian Search*, *Hybrid Reinforcement Learning* e *Dynamic Difficulty Adjustment*. Essa categoria foi necessária porque alguns trabalhos combinaram tarefas tradicionais de ML com métodos adicionais que não faziam parte das opções inicialmente definidas no protocolo de extração dos dados.


Figura 4 - Tarefas de *Machine Learning*

Fonte: Autoria Própria (2026)

4.2.2 Algoritmos de *Machine Learning*

Os algoritmos de ML têm sido amplamente empregados para apoiar a predição do desempenho acadêmico dos estudantes, permitindo identificar padrões de comportamento, desempenho e engajamento a partir dos dados gerados em ambientes educacionais. A escolha do algoritmo influencia diretamente a capacidade dos modelos em realizar previsões precisas, tornando esse aspecto um dos mais investigados na literatura. Nesse contexto, a análise dos estudos selecionados permitiu identificar os algoritmos mais utilizados nas pesquisas relacionadas à predição do desempenho acadêmico. Em relação à QP01, a Figura 5 apresenta a distribuição dos algoritmos identificados nos estudos analisados.

Figura 5 - Algoritmos utilizados



Fonte: Autoria Própria (2026)

Observa-se que as Redes Neurais Artificiais (RNAs) foram os algoritmos mais utilizados, correspondendo a 25,5% das ocorrências. Esse resultado demonstra o interesse da comunidade científica em modelos capazes de identificar padrões complexos nos dados educacionais e fornecer previsões mais precisas sobre o desempenho dos alunos.

Entre os estudos analisados, destaca-se o trabalho de Ramez Nabil et al. (2021), que utilizou uma rede neural do tipo *Long Short-Term Memory* (LSTM) para analisar códigos desenvolvidos por estudantes e detectar erros de sintaxe. Os autores observaram que a combinação da LSTM com elementos de gamificação favoreceu a compreensão dos conceitos de programação, contribuindo para a melhoria do desempenho acadêmico dos participantes.

O algoritmo *Random Forest* foi o segundo mais frequente, representando 10,6% das ocorrências. Por ser um método baseado na combinação de múltiplas árvores de decisão, esse algoritmo é amplamente utilizado devido à sua capacidade de gerar previsões robustas e precisas. No contexto educacional, destaca-se o estudo de Lima, Santana Junior e Matamoros (2025), no qual o *Random Forest* foi empregado para identificar estudantes com risco de evasão por meio da análise de dados acadêmicos.

Com a mesma frequência (10,6%), o *Support Vector Machine* (SVM) também se destacou entre os algoritmos utilizados. Trata-se de um método de aprendizado supervisionado amplamente empregado em tarefas de classificação. No estudo de Christian López e Conrad Tucker (2020), a integração do SVM a um ambiente gamificado mostrou-se eficaz para a predição do desempenho acadêmico dos estudantes.

O algoritmo *K-Nearest Neighbors* (KNN) esteve presente em 4,3% dos estudos analisados. Esse método baseia-se na similaridade entre instâncias para realizar previsões, sendo frequentemente utilizado pela sua simplicidade e eficiência. De acordo com Farhan et al. (2025), o KNN foi capaz de prever o nível de compreensão dos estudantes e identificar aqueles com maior risco de reprovação ou abandono do curso.

O XGBoost foi identificado em 2,1% dos artigos selecionados. Esse algoritmo utiliza a técnica de gradient boosting para construir árvores de decisão de forma sequencial, corrigindo iterativamente os erros dos modelos anteriores. Em razão de sua elevada capacidade preditiva, o XGBoost tem sido aplicado em diferentes cenários educacionais. No estudo de Mairittha et al. (2021), os resultados produzidos pelo algoritmo foram associados a mecanismos de gamificação, contribuindo para o aumento da motivação e do desempenho dos estudantes.

Por fim, a categoria "Outros" representou 36,2% das ocorrências. Essa categoria engloba algoritmos que não estavam previstos no formulário de extração de dados, mas que foram identificados durante a análise dos estudos. Entre eles, destacam-se abordagens como Aprendizado por Reforço, *Naïve Bayes* e Algoritmos Baseados em Regras. A elevada representatividade dessa categoria evidencia a diversidade de métodos empregados na literatura para apoiar a predição do desempenho acadêmico em ambientes educacionais gamificados.


4.2.3 Métricas de avaliação dos Modelos

As métricas de avaliação são cruciais para avaliar o desempenho dos modelos de aprendizagem de máquina, pois servem para garantir que as previsões sejam válidas. Em relação a QP02, nos artigos analisados, as métricas mais utilizadas são *Accuracy*, *Recall*, *F1-score*, R^2 , *Precision* e *AUC*.

Os estudos analisados frequentemente utilizaram mais de uma métrica de avaliação para validar o desempenho dos modelos de ML de forma mais abrangente e confiável. A adoção de múltiplas métricas permite avaliar diferentes aspectos do comportamento dos modelos, fornecendo uma análise mais completa de sua capacidade preditiva. Dessa forma, a combinação de métricas contribui para uma interpretação mais precisa dos resultados obtidos e reduz o risco de conclusões baseadas em apenas uma medida de desempenho.

A Figura 6 apresenta a distribuição das métricas de avaliação utilizadas nos estudos selecionados. Observa-se que os pesquisadores tendem a combinar métricas complementares para analisar o desempenho dos modelos sob diferentes perspectivas, como capacidade de classificação, precisão das previsões e qualidade geral dos resultados.

Figura 6 - Métricas de avaliação



Fonte: Autoria Própria (2026)

A categoria "Outros" engloba métricas que não estavam previstas no formulário de extração de dados, mas que foram identificadas durante a análise dos artigos. Entre elas, destacam-se a Latência Média, a Latência de Adaptação e a Taxa de Engajamento. Essa categoria foi necessária porque alguns estudos

utilizaram, além das métricas tradicionais de avaliação de modelos de ML, métricas específicas relacionadas ao contexto educacional e aos elementos de gamificação empregados, ampliando a análise dos impactos das abordagens propostas.

Além das métricas utilizadas para avaliar o desempenho dos modelos de ML, os estudos analisados também permitiram identificar os recursos de gamificação empregados nos ambientes educacionais. A análise dessas ferramentas e elementos contribui para compreender como as estratégias gamificadas têm sido aplicadas em conjunto com técnicas de ML para apoiar o processo de ensino e aprendizagem.

4.2.4 Gamificação e Ferramentas de Aprendizagem

Esta subseção apresenta os resultados relacionados às questões de pesquisa QP03, QP04 e QP05, abordando as ferramentas de gamificação utilizadas, os elementos empregados e suas contribuições para o aprendizado.

Nos estudos analisados, observou-se a utilização de diversos elementos de gamificação, como pontos, níveis, medalhas, desafios, *rankings* e *feedback* imediato. Esses elementos foram empregados com o objetivo de aumentar a motivação dos estudantes, promover maior engajamento nas atividades acadêmicas e contribuir para a melhoria do desempenho escolar.

Os artigos selecionados também evidenciaram uma ampla variedade de ferramentas e plataformas gamificadas. Em muitos casos, os estudos utilizaram mais de uma ferramenta, de acordo com os objetivos pedagógicos propostos. Entre as soluções identificadas destacam-se ambientes virtuais de aprendizagem, plataformas educacionais, jogos digitais e sistemas desenvolvidos especificamente pelos autores para atender às necessidades de cada contexto educacional.


Entre as ferramentas encontradas, destaca-se o GidgetML, uma versão adaptativa do jogo de programação Gidget que utiliza técnicas de aprendizado de máquina para avaliar e prever a competência dos estudantes. O sistema ajusta dinamicamente o nível de dificuldade das atividades de acordo com o desempenho e o conhecimento demonstrado pelos usuários. Outra ferramenta identificada foi o EvalSeer, um sistema de gerenciamento da aprendizagem (*Learning Management System* – LMS) que combina análise estática e dinâmica de código com técnicas de

Deep Learning para realizar a avaliação automática de exercícios de programação, detectar erros de sintaxe, sugerir correções e fornecer *feedback* imediato em um ambiente competitivo.

Também foi identificada a plataforma Teloprogramo, desenvolvida para apoiar o ensino de programação por meio da correção automática de exercícios e da assistência personalizada na identificação e correção de erros. A plataforma integra recursos de inteligência artificial e elementos de gamificação com o objetivo de aumentar a motivação e o envolvimento dos estudantes. Outra solução encontrada foi a plataforma KruCode, um *framework* voltado para a aprendizagem adaptativa de programação. Essa ferramenta utiliza algoritmos de aprendizado de máquina para recomendar o nível de dificuldade mais adequado para as próximas atividades, considerando métricas relacionadas ao código produzido pelos alunos e ao seu comportamento durante o processo de aprendizagem.

Em relação aos elementos de gamificação empregados nas plataformas analisadas, observou-se a predominância de pontos, medalhas (*badges*), desafios, níveis, *feedback* imediato e *rankings*. Esses elementos foram utilizados para incentivar a participação dos estudantes, promover o acompanhamento contínuo do progresso e estimular a realização das atividades propostas. A Figura 7 apresenta a distribuição dos elementos de gamificação identificados nos estudos analisados. Ressalta-se que a maioria das plataformas utilizou uma combinação de múltiplos elementos, evidenciando a adoção de estratégias complementares para potencializar o engajamento e o desempenho dos estudantes.

Figura 7 - Elementos de gamificação



Fonte: Autoria Própria (2026)


4.2.5 Predição de Desempenho Acadêmico com ML

Em relação à QP06, os estudos analisados investigaram como a aplicação de técnicas de ML pode auxiliar na predição do desempenho acadêmico dos estudantes em ambientes educacionais gamificados. De modo geral, os dados gerados pelas atividades de gamificação foram utilizados como entrada para algoritmos de ML, permitindo identificar padrões de comportamento, níveis de engajamento e desempenho dos alunos ao longo do processo de aprendizagem. Com base nessas informações, os modelos foram capazes de identificar estudantes com risco de reprovação, baixo rendimento ou evasão, possibilitando intervenções pedagógicas mais direcionadas.

A utilização dessas técnicas fornece aos educadores subsídios para acompanhar o progresso dos estudantes de forma mais precisa, permitindo a adoção de estratégias de ensino personalizadas e o direcionamento de esforços para conteúdos em que os alunos apresentam maiores dificuldades. Dessa forma, a combinação entre gamificação e ML contribui para um processo de aprendizagem mais adaptativo e orientado por dados.

A análise dos estudos selecionados revelou resultados predominantemente positivos em relação ao desempenho acadêmico, à motivação e ao engajamento dos estudantes. Conforme apresentado na Figura 8, mais de 90% dos estudos analisados reportaram melhorias após a aplicação conjunta de elementos de gamificação e técnicas de ML. Assim, esses resultados indicam que a integração dessas abordagens pode favorecer o processo de ensino e aprendizagem, promovendo maior participação dos alunos e contribuindo para melhores resultados educacionais.

Figura 8 - Relação do desempenho



Fonte: Autoria Própria (2026)

4.2.6 Limitações e lacunas encontradas na literatura

Em relação à QP07, a análise das limitações e lacunas identificadas nos estudos selecionados permitiu compreender os principais desafios e oportunidades de pesquisa relacionados à aplicação conjunta da gamificação e do ML para a predição do desempenho acadêmico. A identificação desses aspectos é fundamental para direcionar futuras investigações e contribuir para o avanço do conhecimento nessa área.

Os resultados evidenciaram a existência de lacunas na literatura, especialmente no que se refere à integração entre gamificação e técnicas de ML. Embora diversos estudos abordem a utilização da gamificação para promover

motivação e engajamento dos estudantes, e outros se concentram na aplicação de algoritmos de ML para a predição do desempenho acadêmico, a combinação dessas duas abordagens ainda é limitada. Além disso, poucos trabalhos exploram mecanismos de adaptação automática em ambientes gamificados com base em técnicas de ML. Conforme destacado por Miljanovic e Bradbury (2020), ainda são escassos os jogos educacionais capazes de adaptar dinamicamente seus desafios e conteúdos a partir da análise do comportamento e desempenho dos estudantes.

Também foram identificadas limitações metodológicas nos estudos analisados. Muitos trabalhos foram conduzidos em apenas uma instituição de ensino e com amostras reduzidas, o que pode comprometer a generalização dos resultados. Adicionalmente, diversos estudos não utilizaram grupos de controle, dificultando a comprovação de que os efeitos positivos observados foram efetivamente decorrentes da aplicação da gamificação. Outra limitação recorrente refere-se à baixa capacidade de personalização das plataformas educacionais, que frequentemente não conseguem adaptar os desafios e atividades às necessidades individuais dos estudantes.

Embora os resultados reportados pela literatura sejam predominantemente positivos em termos de desempenho acadêmico, motivação e engajamento, as limitações identificadas evidenciam a necessidade de novas pesquisas na área. Nesse contexto, observa-se a oportunidade de desenvolver ambientes educacionais gamificados mais adaptativos, capazes de integrar técnicas de ML para monitorar continuamente o progresso dos estudantes, identificar aqueles com risco de reprovação e detectar conteúdos que apresentam maiores dificuldades de aprendizagem. Tais recursos podem possibilitar intervenções pedagógicas mais precoces e personalizadas, contribuindo para a melhoria do desempenho acadêmico e para a redução dos índices de reprovação e evasão.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo investigar a aplicação da gamificação em conjunto com técnicas de ML para a predição do desempenho acadêmico de estudantes. Para isso, foi conduzida uma Revisão Sistemática da Literatura, permitindo identificar as principais tarefas, algoritmos e métricas de avaliação utilizados, bem como os elementos de gamificação empregados e os desafios existentes nessa área de pesquisa.

Os resultados evidenciaram que tarefas de classificação e Regressão são amplamente utilizadas para a predição do desempenho acadêmico, com destaque para algoritmos como Redes Neurais Artificiais, *Random Forest* e *Support Vector Machine* (SVM). Em relação à avaliação dos modelos, observou-se a predominância de métricas como *Accuracy*, *Precision*, *Recall* e *F1-score*, utilizadas para validar a capacidade preditiva das abordagens propostas. Além disso, constatou-se que a gamificação tem sido aplicada com sucesso em ambientes educacionais por meio de elementos como pontuação, desafios, níveis, medalhas e *feedback* imediato, contribuindo para o aumento da motivação, do engajamento e do desempenho dos estudantes.

A análise dos estudos selecionados demonstrou que a integração entre gamificação e ML apresenta potencial para apoiar o processo de ensino e aprendizagem, especialmente no ensino de programação. Os resultados indicam que os dados gerados pelas atividades gamificadas podem ser utilizados por modelos de ML para identificar estudantes em risco de reprovação, permitindo a realização de intervenções pedagógicas mais direcionadas. Além disso, diversas plataformas analisadas empregam mecanismos adaptativos capazes de personalizar desafios e atividades de acordo com o perfil e o desempenho dos alunos, favorecendo uma aprendizagem mais eficiente.

Apesar dos resultados promissores, a revisão também evidenciou limitações importantes na literatura. Verificou-se que ainda são escassos os estudos que integram efetivamente gamificação e ML em uma mesma solução educacional. Adicionalmente, muitos trabalhos foram conduzidos em contextos específicos, utilizando amostras reduzidas, uma única instituição de ensino e, em diversos casos, sem a utilização de grupos de controle, o que limita a generalização dos resultados

obtidos. Também foram identificadas limitações relacionadas à personalização dos ambientes gamificados e à adaptação das atividades às necessidades individuais dos estudantes.

Como trabalhos futuros, recomenda-se o desenvolvimento e a avaliação de plataformas educacionais gamificadas que integrem técnicas de ML para monitorar continuamente o desempenho dos estudantes e fornecer experiências de aprendizagem adaptativas. Além disso, sugere-se a realização de estudos com amostras mais amplas, diferentes contextos educacionais e grupos de controle, de modo a fortalecer as evidências sobre a efetividade dessas abordagens. Também se destaca a necessidade de pesquisas voltadas para a identificação precoce de estudantes em risco de reprovação ou evasão, permitindo a implementação de intervenções pedagógicas personalizadas. Dessa forma, a integração entre gamificação e ML configura-se como uma área promissora para o desenvolvimento de soluções educacionais capazes de promover maior engajamento, motivação e melhoria do desempenho acadêmico dos estudantes.

REFERÊNCIAS

ALVES, P. **Métricas de avaliação de modelos em Machine Learning**. PA Analytics, 2026. Disponível em: <https://share.google/9XCq3RN7uoZRmHkGL>. Acesso em: 18 maio 2026.

ARKABAEV, N. *et al.* Adaptive gamification in Python learning: integrating machine learning algorithms for educational process personalization. **Journal of Statistics Applications & Probability**, v. 15, n. 3, p. 519-542, 2026.

ENAP. Fundamentos de Machine Learning: Módulo 3. Brasília, DF: Escola Nacional de Administração Pública, 2020. Disponível em: <https://share.google/B9fdikUYb1nuT7jvD>.

FARHAN, M. *et al.* Gamified cybersecurity training using AI-driven learning analytics in UK STEM programs. In: **INTERNATIONAL CONFERENCE ON CYBER RESILIENCE (ICCR)**, 3., 2025, Dubai. Anais [...]. Dubai: IEEE, 2025. p. 1-8. DOI: 10.1109/ICCR67387.2025.11291825.

HARVE. **Machine Learning: o que é? Guia completo**. [S. l.], 2021. Disponível em: <https://harve.com.br/blog/data-science-blog/machine-learning-o-que-e-guia-completo/>. Acesso em: 1 jun. 2026.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. **The Elements of Statistical Learning: data mining, inference, and prediction**. 2. ed. New York: Springer, 2009.

IBM. **O que são algoritmos de aprendizado de máquina?** Texto de Dave Bergmann. 2025. Disponível em: <https://share.google/nbhlGsUck2CQYQBkb>.

KITCHENHAM, B. **Procedures for performing systematic reviews**. Keele: Keele University, 2004. (Keele University Technical Report TR/SE-0401; NICTA Technical Report 0400011T.1). ISSN 1353-7776.

LIMA, A. C.; SANTANA JUNIOR, O. V.; MATAMOROS, E. P. Uso aplicado de Machine Learning com Random Forest e Self-Organizing Map como modelo preditivo para evasão de alunos. **Ensino de Ciências e Tecnologia em Revista – ENCITEC**, v. 16, n. 1, p. 7-29, 2025.

LLANOS, J.; BUCHELI, V. A.; RESTREPO-CALLE, F. Early prediction of student performance in CS1 programming courses. **PeerJ Computer Science**, [s. l.], v. 9, e1655, 2023. DOI: <https://doi.org/10.7717/peerj-cs.1655>.

LÓPEZ, C.; TUCKER, C. Toward personalized adaptive gamification: a machine learning model for predicting performance. **IEEE Transactions on Games**, v. 12, n. 2, p. 155-168, jun. 2020. DOI: 10.1109/TG.2018.2883661.

MILJANOVIC, M. A.; BRADBURY, J. S. GidgetML: an adaptive serious game for enhancing first year programming labs. In: **IEEE/ACM INTERNATIONAL**

CONFERENCE ON SOFTWARE ENGINEERING: SOFTWARE ENGINEERING EDUCATION AND TRAINING (ICSE-SEET), 42., 2020, Seoul. Anais [...]. Seoul: IEEE, 2020. p. 184-192.

MITCHELL, Tom M. **Machine Learning**. New York: McGraw-Hill, 1997.

MURR, C. E.; FERRARI, G. **Entendendo e aplicando a gamificação: o que é, para que serve, potencialidades e desafios**. Florianópolis: SEAD/UFSC, 2020. (Tutorial 2).

NABIL, R. et al. *EvalSeer: an intelligent gamified system for programming assignments assessment*. In: **INTERNATIONAL MOBILE, INTELLIGENT, AND UBIQUITOUS COMPUTING CONFERENCE (MIUCC)**, 2021, Cairo. Anais [...]. Cairo: IEEE, 2021. p. 235-242. DOI: 10.1109/MIUCC52538.2021.9447629.

OLIVEIRA, G. C. F. **Proposta, desenvolvimento e validação de uma estratégia para predição de desempenho de discentes na plataforma TôSabendo**. 2023. Monografia (Bacharelado em Ciência da Computação) – Instituto de Ciências Exatas e Biológicas, Universidade Federal de Ouro Preto, Ouro Preto, 2023.

SEMESP. **Mapa do ensino superior no Brasil 2023**. 13. ed. São Paulo: Semesp, 2023. Disponível em: <https://share.google/dHRre24ze3DUpdCMB>. Acesso em: 09 maio 2026.

SHINDE, P. P.; SHAH, S. A review of machine learning and deep learning applications. In: **INTERNATIONAL CONFERENCE ON COMPUTING COMMUNICATION CONTROL AND AUTOMATION (ICCUBEA)**, 4., 2018, Pune. Anais [...]. Pune: IEEE, 2018. p. 1-6. DOI: 10.1109/ICCUBEA.2018.8697857.

STRAUSS, E. et al. A importância de utilizar métricas adequadas de avaliação de performance em modelos preditivos de Machine Learning. **Projectus**, Rio de Janeiro, v. 7, n. 2, p. 52-62, 2022. Disponível em: <https://pdfs.semanticscholar.org/78fa/b9dcbbefa1361fef4a7eb0b849d523aae2aa.pdf>

TENENTE, L. 51% dos brasileiros que entram na faculdade não se formam nem 3 anos após o prazo previsto. **G1**, 9 set. 2025. Disponível em: <https://share.google/E8eBTxCNET3XWXFaU>. Acesso em: 09 maio 2026.

VASCONCELOS, N. M.; ARAÚJO, G. C. C.; MORESI, E. A. D. As tecnologias como potencialização da aprendizagem: jogos sérios e inteligência artificial. **Educação por Escrito**, Porto Alegre, v. 16, n. 1, p. 1-16, 2025. DOI: <http://dx.doi.org/10.15448/2179-8435.2025.1.45050>.