



UNIVERSIDADE FEDERAL DE PERNAMBUCO

CENTRO DE INFORMÁTICA

GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

JOÃO GUILHERME PONTES DE PAIVA

**Estratégias computacionais para identificação e tratamento de fraudes em
plataformas de aprendizado autodirigido**

RECIFE - PE

2025

JOÃO GUILHERME PONTES DE PAIVA

Estratégias computacionais para identificação e tratamento de fraudes em plataformas de aprendizado autodirigido

Trabalho de Conclusão de Curso de Graduação em Ciência da Computação da Universidade Federal de Pernambuco, apresentado à coordenação do Curso como requisito parcial para obtenção do título de bacharel em Ciência da Computação.

Orientador: Prof. Alex Sandro Gomes

RECIFE - PE

2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Paiva, João Guilherme Pontes de.

Estratégias computacionais para identificação e tratamento de fraudes em plataformas de aprendizado autodirigido / João Guilherme Pontes de Paiva. - Recife, 2025.

43 p, tab.

Orientador(a): Alex Sandro Gomes

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Informática, Ciências da Computação - Bacharelado, 2025.

Inclui referências.

1. Fraudes online. 2. Inteligência artificial. 3. Plataformas de aprendizado autodirigido. 4. Técnicas computacionais para detecção de fraudes. I. Gomes, Alex Sandro. (Orientação). II. Título.

370 CDD (22.ed.)

JOÃO GUILHERME PONTES DE PAIVA

**Estratégias computacionais para Identificação e tratamento de Fraudes em
Plataformas de Aprendizado Autodirigido**

Trabalho de Conclusão de Curso de
Graduação em Ciência da Computação da
Universidade Federal de Pernambuco,
apresentado à coordenação do Curso como
requisito parcial para obtenção do título de
bacharel em Ciência da Computação.

Aprovado em: 08 de Abril de 2025

BANCA EXAMINADORA

Prof. Dr Alex Sandro Gomes (Orientador)

Universidade Federal de Pernambuco

Prof. Dr. Ricardo Massa Ferreira Lima (Examinador Interno)

Universidade Federal de Pernambuco

AGRADECIMENTOS

Primeiramente, agradeço a Deus por me permitir estar aqui e dar mais um passo importante em minha trajetória.

Sou grato(a) a todos que, de alguma forma, contribuíram para a realização deste estudo.

Em especial, agradeço aos pesquisadores e educadores que disponibilizaram dados e compartilharam suas experiências, enriquecendo a nossa análise.

Agradeço também à instituição e ao meu orientador, Alex, pelo suporte essencial durante o desenvolvimento deste trabalho.

E, por fim, agradeço a todos que acompanharam esta apresentação. Espero que as reflexões aqui discutidas possam contribuir para o avanço de soluções cada vez mais eficazes e éticas no campo do ensino digital.

Muito obrigado!

EPÍGRAFE

“Disciplina é fazer o que precisa ser feito, mesmo quando você não quer fazer”.

– Jocko Willink

RESUMO

O aprendizado autodirigido tem se destacado como uma abordagem educacional que permite aos cursistas conduzir de forma autônoma o seu processo de aprendizagem, especialmente em plataformas de ensino a distância. Porém, a ausência de supervisão direta nesses ambientes favorece o surgimento de práticas fraudulentas, como a utilização de respostas automatizadas ou a realização de atividades por terceiros, comprometendo a integridade e a eficácia do processo educacional.

Este trabalho visa investigar padrões comportamentais que possam ser indicativos de fraudes em plataformas de aprendizado autodirigido, utilizando técnicas de análise de dados e mineração de processos.

A pesquisa será conduzida por meio de uma revisão bibliográfica para identificar indicadores e padrões comportamentais típicos de práticas fraudulentas, bem como explorar ferramentas computacionais que possam ser aplicadas na análise e monitoramento desses ambientes.

Os resultados obtidos evidenciam que a combinação de técnicas como *Learning Analytics*, *Deep Learning* e a análise de indicadores de engajamento e desempenho pode ser eficaz na detecção de fraudes. Além disso, a pesquisa aponta que o design instrucional e o uso de ambientes virtuais interativos desempenham um papel fundamental na prevenção dessas práticas, promovendo maior comprometimento e autenticidade no processo de aprendizado.

Com base nessas descobertas, propõe-se um conjunto de diretrizes e métodos para dificultar práticas fraudulentas e fortalecer a credibilidade das plataformas de ensino a distância. A implementação dessas estratégias pode contribuir para um ambiente de aprendizado mais seguro, confiável e alinhado aos princípios de integridade acadêmica, beneficiando tanto os alunos quanto as instituições educacionais.

Palavras-chave: aprendizado autodirigido, fraude, plataformas de ensino, análise de dados, técnicas de detecção de fraude.

ABSTRACT

Self-directed learning has been highlighted as an educational approach that allows students to conduct their learning process autonomously, especially on distance learning platforms. However, the absence of direct supervision in these environments favors the emergence of fraudulent practices, such as the use of automated responses or the performance of activities by third parties, compromising the integrity and effectiveness of the educational process.

This work aims to investigate behavioral patterns that may be indicative of fraud in self-directed learning platforms, using data analysis and process mining techniques.

The research will be conducted through a literature review to identify indicators and behavioral patterns typical of fraudulent practices, as well as exploring computational tools that can be applied to the analysis and monitoring of these environments.

The results obtained show that the combination of techniques such as Learning Analytics, Deep Learning and the analysis of engagement and performance indicators can be effective in detecting fraud. In addition, the research points out that instructional design and the use of interactive virtual environments play a key role in preventing these practices, promoting greater commitment and authenticity in the learning process.

Based on these findings, a set of guidelines and methods is proposed to hinder fraudulent practices and strengthen the credibility of distance learning platforms. Implementing these strategies can contribute to a safer, more reliable learning environment in line with the principles of academic integrity, benefiting both students and educational institutions.

Keywords: self-directed learning, fraud, teaching platforms, data analysis, fraud detection techniques.

LISTA DE QUADROS

- | | | |
|-----------------|---|----|
| Quadro 1 | Principais métodos de detecção de fraudes em plataformas de aprendizado | 23 |
| Quadro 2 | Comparação entre modelos de aprendizado para prevenção de fraudes | 27 |

LISTA DE ABREVIATURAS E SIGLAS

SIGLA	DESCRIÇÃO
ASD	Aprendizado autodirigido
SDL	Self-directed learning
IJSDL	International Journal of Self-Directed Learning
ABNT	Associação Brasileira de Normas Técnicas
IA	Inteligência Artificial
MFA	Múltiplos Fatores de Autenticação
NLP	Processamento de Linguagem Natural (Natural Language Processing)
MOOP	Massive Open Online Course
LMS	Learning Management System

SUMÁRIO

1 INTRODUÇÃO	10
2 REFERENCIAL TEÓRICO	11
2.1 Aprendizado Autodirigido em Ambientes Virtuais	11
2.2 Fraudes em Plataformas de Ensino a Distância	13
3. Método	15
3.1 OBJETIVOS	15
3.3 Busca na Literatura	16
4 RESULTADOS	20
4.1 Técnicas Computacionais para Detecção de Fraudes	21
Comparação entre Métodos Tradicionais e Computacionais	21
Modelo 1: Learning Analytics para Validação de Autoria	21
Modelo 2: Deep Learning para Detecção de Plágio	22
Análise Comparativa dos Modelos	23
Considerações Finais	24
4.2 Indicadores e Métricas de Avaliação em Ambientes Virtuais	24
Indicadores de Engajamento e Desempenho	25
Avaliação em Ambientes Virtuais Tridimensionais	25
Dashboards e Visualização de Dados	26
Indicadores de Integridade Acadêmica	26
Comparação entre Indicadores e sua Aplicabilidade	27
Conclusão	27
4.3 Soluções e Estratégias de Prevenção de Fraudes	28
Estratégias Pedagógicas para Redução de Fraudes	28
Uso de Tecnologias para Detecção e Prevenção de Fraudes	29
Avaliação de Impacto e Desafios Éticos	30
Conclusão	30
5 DISCUSSÃO	32
5.1 Recomendações para o design de plataformas	32
5.2 Recomendações para o design instrucional	34
6 CONSIDERAÇÕES FINAIS	38
REFERÊNCIAS	39

1 INTRODUÇÃO

O aprendizado autodirigido, caracterizado pela autonomia do cursista em conduzir seu próprio processo de aprendizagem, tem ganhado destaque no cenário educacional global. Com o avanço das tecnologias digitais, plataformas de ensino a distância oferecem a milhões de pessoas a oportunidade de adquirir conhecimentos e habilidades, independentemente de sua localização geográfica ou disponibilidade de tempo. Essa democratização do acesso ao conhecimento promove a inclusão e capacitação de indivíduos, contribuindo para o desenvolvimento pessoal e profissional.

Apesar de suas inúmeras vantagens, o aprendizado autodirigido enfrenta desafios significativos, especialmente em relação à autenticidade e à integridade do processo. A ausência de supervisão direta e a flexibilidade inerente a esses ambientes permitem que alguns cursistas recorram a comportamentos fraudulentos, como o uso de bots para responder questionários, compartilhamento de respostas entre alunos ou a manipulação de dados de interação. Essas práticas não somente distorcem os resultados do aprendizado, mas também comprometem a credibilidade das plataformas e a eficácia do ensino.

Diante desses desafios, surge a necessidade de investigar como estratégias computacionais podem auxiliar na identificação, prevenção e mitigação de fraudes. A análise de dados comportamentais e a mineração de processos apresentam-se como ferramentas promissoras para compreender as interações dos usuários e desenvolver mecanismos que não somente detectem práticas fraudulentas, mas também desincentivem seu uso, promovendo um ambiente mais ético e transparente. Além disso, estratégias pedagógicas e de design instrucional podem atuar na conscientização dos alunos sobre a importância da integridade acadêmica, reduzindo sua predisposição a adotar comportamentos inadequados.

Este trabalho visa principalmente investigar e propor estratégias computacionais e educacionais que contribuam para a identificação, prevenção e desincentivo de fraudes em plataformas de aprendizado autodirigido. Além de explorar técnicas para detectar comportamentos suspeitos, busca-se compreender

as motivações que levam os cursistas a adotar essas práticas e propor soluções que reduzam a necessidade e o incentivo ao uso de fraudes.

Adicionalmente, este estudo visa propor métodos de avaliação e diretrizes que reduzam as ocorrências de fraude e promovam a integridade em experiências de aprendizado em plataformas de ensino online. Ao investigar mecanismos preventivos e proativos, espera-se contribuir para um ambiente de aprendizado mais seguro e efetivo, beneficiando tanto alunos quanto instituições de ensino. O referencial teórico, apresentado na seção 2, explora os fundamentos do aprendizado autodirigido em ambientes virtuais, discutindo suas vantagens, desafios e os impactos da autonomia do aluno na eficácia do aprendizado. Além disso, são analisadas as fraudes mais comuns em plataformas educacionais online e suas implicações para a credibilidade dessas plataformas.

Na seção 3, são detalhados os objetivos da pesquisa e a metodologia adotada, incluindo a estratégia de busca na literatura. Essa parte descreve os critérios utilizados para a seleção de estudos relevantes e a abordagem empregada para estruturar a análise sobre técnicas de detecção de fraudes.

Os resultados são apresentados na seção 4, onde são discutidas as principais técnicas computacionais aplicadas à identificação de fraudes, como Learning Analytics e Deep Learning. Além disso, são abordados indicadores e métricas de avaliação em ambientes virtuais, bem como estratégias pedagógicas e tecnológicas para prevenir práticas fraudulentas, garantindo maior integridade acadêmica.

Em seguida, a seção 5 aprofunda a discussão dos achados da pesquisa, trazendo recomendações para o design de plataformas educacionais e do próprio processo instrucional, para minimizar fraudes e promover uma experiência de aprendizado mais segura e confiável.

Por fim, a seção 6 apresenta as considerações finais, destacando as principais contribuições deste estudo, suas limitações e sugestões para futuras pesquisas.

2 REFERENCIAL TEÓRICO

2.1 Aprendizado Autodirigido em Ambientes Virtuais

O aprendizado autodirigido (ASD) é uma abordagem educacional no qual o aluno assume o controle sobre seu processo de aprendizagem, decidindo o ritmo, os métodos e os conteúdos a serem estudados. Essa modalidade tem se destacado com o avanço das tecnologias digitais e a disseminação de plataformas de ensino a distância, permitindo maior flexibilidade e personalização da experiência educacional. O aprendizado autodirigido promove autonomia e protagonismo, características fundamentais para o desenvolvimento de competências no século XXI, de acordo com Şen e Yalabik (2003).

O aprendizado autodirigido em ambientes virtuais oferece diversas vantagens que o tornam uma abordagem educacional atrativa e adaptada às demandas contemporâneas. A flexibilidade de tempo e espaço permite que os estudantes acessem conteúdos a qualquer momento e de qualquer lugar, ajustando o aprendizado às suas necessidades individuais e promovendo a autonomia para definir o ritmo dos estudos (Ramalho et al., 2024). Além disso, a personalização do aprendizado é um ponto-chave, por possibilitar ao aluno escolher métodos e recursos alinhados às suas metas e estilos, tornando o processo mais eficaz e significativo (Andrade Filho et al., 2024). Outra vantagem é desenvolver competências essenciais, como curiosidade, iniciativa e habilidades de resolução de problemas, estimuladas pela liberdade de gerir o próprio aprendizado, o que também fomenta a autossuficiência e a capacidade de enfrentar desafios de forma independente (Roque, 2024). Por fim, a combinação dessas vantagens “flexibilidade, personalização e estímulo ao desenvolvimento de competências” faz do aprendizado autodirigido em ambientes virtuais uma estratégia de ensino relevante e alinhada às demandas da sociedade atual, onde a adaptabilidade e a capacidade de aprendizado contínuo são atributos indispensáveis.

Apesar de suas vantagens, o aprendizado autodirigido em ambientes virtuais enfrenta desafios significativos que podem impactar a eficácia do processo educacional. A falta de supervisão direta pode levar à procrastinação e à dificuldade

em manter a motivação ao longo do tempo, especialmente em contextos onde os alunos não possuem habilidades de autogestão bem desenvolvidas. Além disso, a ausência de interações presenciais pode limitar a troca de experiências e o apoio social, fatores importantes para o engajamento e a retenção do conhecimento (Costa & Franco, 2005). Outro desafio crítico é a possibilidade de práticas fraudulentas, como a delegação de atividades a terceiros ou o uso de respostas automatizadas, que comprometem a integridade do processo e a confiabilidade das avaliações (Flores et al., 2020).

O aprendizado autodirigido tem encontrado ampla aplicação em plataformas digitais, que oferecem recursos diversificados para atender às demandas de diferentes perfis de estudantes. Essas plataformas disponibilizam conteúdos interativos, como vídeos, quizzes e simulações, que facilitam a aquisição e a retenção do conhecimento (Meneghello, 2019). Além disso, novos produtos vêm utilizando sistemas de recomendação baseados em inteligência artificial para personalizar o material apresentado, ajustando-se aos alunos, ao analisar os pontos fortes, os pontos fracos e os estilos de aprendizagem de cada aluno, os algoritmos de IA e de ML podem adaptar o conteúdo, o ritmo e os métodos de ensino para otimizar os resultados da aprendizagem (Glicorea et al., 2023). Outro aspecto relevante é a possibilidade de monitorar o desempenho por meio de métricas e relatórios detalhados, permitindo intervenções personalizadas e promovendo um aprendizado mais eficiente, adicionando isso, ao planejamento de estudos, no qual os alunos podem escolher intervalos de tempo para estudo em uma tabela semanal e possuem relatórios para acompanhamento de progresso (Şen e Yalabik 2003). Essas ferramentas transformam o aprendizado autodirigido em uma experiência dinâmica e acessível, promovendo maior alcance e inclusão educacional.

2.2 Fraudes em Plataformas de Ensino a Distância

Embora não haja unanimidade sobre o tema, a maioria dos estudos aponta para uma prevalência maior de condutas antiéticas por parte dos alunos em ambientes de ensino a distância. De acordo com Diego (2017), as principais razões internas incluem a falta de responsabilidade, preguiça, desrespeito às regras

acadêmicas, desinteresse ou baixa motivação para estudar, além da baixa autoestima. Por outro lado, Valizadeh (2022) destaca fatores externos que também contribuem significativamente para essas práticas, como a influência de colegas, pressão por boas notas para agradar os pais, ausência de punições ou consequências quando apanhados, falta de preparo adequado, desejo de ajudar amigos e problemas técnicos enfrentados durante a realização da prova. Esses fatores revelam a complexidade das questões éticas e técnicas que permeiam o ambiente de ensino a distância.

Os métodos mais comuns de transgressão em ambientes de ensino a distância foram destacados por Yazdi (2023), evidenciando o uso diversificado de recursos e estratégias pelos estudantes. O estudo revelou que a prática mais recorrente é a utilização de livros de texto durante as provas, com 100% dos casos analisados. Além disso, obter ajuda de outros colegas e compartilhar respostas representa 71,4% das situações relatadas, seguido por buscar conselhos de familiares (42,8%) e o uso do navegador da Internet, bem como de cadernos escolares manuscritos, ambos com 35,7%. Esses dados reforçam a tendência dos alunos utilizarem tanto recursos acessíveis quanto redes sociais para superar os desafios das avaliações online, muitas vezes em detrimento das normas acadêmicas.

Fraudes acadêmicas impactam negativamente tanto os alunos quanto as instituições de ensino, comprometendo a integridade do aprendizado e a credibilidade dos diplomas emitidos. Alunos que recorrem a essas práticas deixam de absorver os conhecimentos essenciais, o que pode gerar consequências futuras, como a necessidade de novas condutas antiéticas para compensar lacunas no aprendizado. Além disso, a competição desleal afeta outros alunos, que se sentem pressionados a acompanhar aqueles que obtêm notas mais altas por meios desonestos. Segundo Downes (2017), um caso emblemático ocorreu na prestigiada Universidade de Harvard, onde cerca de metade dos alunos do curso de Introdução ao Congresso foi investigada por transgressões acadêmicas em um exame final. Foram observadas similaridades marcantes em suas respostas, incluindo erros tipográficos idênticos. Como resultado, um número sem precedentes de estudantes

foi forçado a se retirar por um tempo da universidade, prejudicando seus planos de carreira por até dois anos. As consequências foram amplas, afetando desde a reputação dos alunos envolvidos até a própria instituição, que enfrentou críticas de pais e ex-alunos pela forma como tratou o incidente. Entre os implicados, estavam atletas de destaque, incluindo capitães do time de basquete, cuja saída impactou o APR (Taxa de Progresso Acadêmico) da equipe, ameaçando até mesmo sua elegibilidade em competições da NCAA. O episódio também expôs falhas na comunicação das políticas acadêmicas por parte do corpo docente, questionando a qualidade do ensino oferecido.

3. MÉTODO

3.1 Objetivos

Este trabalho visa analisar e sistematizar os padrões de comportamento associados a práticas fraudulentas em plataformas de aprendizado autodirigido, a partir da literatura existente e do uso de técnicas de análise de dados e mineração de processos. Por meio dessa investigação, busca-se identificar métodos já utilizados para detecção e mitigação de fraudes, avaliando sua aplicabilidade e eficácia nesses ambientes.

Além disso, pretende-se reunir e organizar estratégias que possam ser adotadas para dificultar tais práticas e incentivar um aprendizado mais autêntico, promovendo diretrizes que fortaleçam a integridade e a confiabilidade das plataformas de ensino a distância. Dessa forma, o estudo visa fornecer uma base teórica consolidada que auxilia no aprimoramento de sistemas de monitoramento e avaliação no contexto do aprendizado autodirigido.

3.2 Tipo de Estudo

Este estudo caracteriza-se como uma pesquisa aplicada, ao buscar desenvolver estratégias computacionais para identificação e mitigação de fraudes em plataformas de aprendizado autodirigido. Além disso, visa compreender os fatores que contribuem para a ocorrência dessas práticas, analisando tanto os aspectos técnicos quanto os comportamentais que favorecem condutas antiéticas nesses ambientes.

O estudo investiga padrões de comportamento fraudulento a partir da revisão da literatura e da análise de ferramentas computacionais voltadas à detecção dessas práticas. Dessa forma, a pesquisa não somente identifica métodos para coibir fraudes, mas também busca entender os fatores que motivam os alunos a recorrerem a esses subterfúgios. Compreendendo as causas, é possível propor soluções mais eficazes, tanto tecnológicas quanto pedagógicas, buscando entender

a complexidade do problema e levantar possíveis soluções, sem necessariamente mensurar quantitativamente a ocorrência das fraudes.

Além disso, trata-se de um estudo bibliográfico e documental, fundamentado na análise de artigos científicos, relatórios técnicos e materiais acadêmicos relevantes. A pesquisa mapeia métodos computacionais eficazes na identificação e prevenção de fraudes, explorando técnicas como *learning analytics* e *deep learning*, além de soluções baseadas no design das plataformas para reforçar a integridade acadêmica. A partir dessa revisão, é possível identificar as limitações dos modelos tradicionais e propor abordagens inovadoras que aumentem a transparência e a confiabilidade nos processos avaliativos de ambientes autodirigidos.

Com essa abordagem, o estudo pretende contribuir para a construção de um ambiente de aprendizado mais ético e confiável, unindo tecnologia e estratégias educacionais para minimizar as oportunidades e motivações para fraudes acadêmicas.

3.3 Busca na Literatura

A revisão da literatura foi conduzida para mapear conceitos, estratégias e soluções relacionadas à identificação e prevenção de fraudes em plataformas de aprendizado autodirigido. Para isso, foram consultadas fontes acadêmicas reconhecidas, incluindo artigos científicos, conferências e relatórios técnicos, priorizando estudos que abordam temas como integridade acadêmica, *learning analytics*, *deep learning* aplicado à detecção de plágio e estratégias de avaliação em ambientes virtuais.

A principal ferramenta utilizada para a busca foi o *Google Scholar* (Google Acadêmico), devido à sua ampla indexação de periódicos, conferências e repositórios acadêmicos. Foram empregadas combinações de palavras-chave em português e inglês, tais como: *fraudes acadêmicas em EAD*, *deteção de plágio online*, *learning analytics for academic integrity*, *deep learning for plagiarism detection*, *self-directed learning integrity*, entre outras. A seleção dos artigos seguiu critérios de relevância, priorizando publicações recentes e amplamente citadas na área.

Além do Google Scholar, foram analisadas fontes complementares, como periódicos indexados em bases de dados científicas e publicações institucionais. Os materiais revisados forneceram uma visão abrangente das tecnologias e metodologias atualmente empregadas para mitigar práticas fraudulentas em ambientes digitais, além de evidências empíricas sobre sua eficácia.

Com essa abordagem, a pesquisa bibliográfica estruturou a fundamentação teórica do estudo, permitindo a identificação de lacunas existentes e contribuindo para a formulação de propostas inovadoras voltadas à integridade acadêmica em plataformas autodirigidas.

3.3.1 Critérios de Inclusão

Foram considerados para a revisão artigos científicos publicados nos últimos dez anos, priorizando estudos revisados por pares e disponibilizados em acesso aberto nos idiomas português, inglês e espanhol. A seleção incluiu materiais que abordam fraudes acadêmicas em ambientes virtuais, detecção de plágio, aprendizado autodirigido e estratégias computacionais, como *learning analytics* e *deep learning*, aplicadas à integridade acadêmica. Além disso, foram incluídas pesquisas que apresentassem soluções práticas e metodologias voltadas para a mitigação de práticas fraudulentas em plataformas de ensino digital.

3.3.2 Critérios de Exclusão

Foram excluídos da revisão artigos sem revisão por pares, publicações muito desatualizadas, trabalhos que abordassem fraudes exclusivamente em contextos presenciais e estudos que tratassem somente de aspectos jurídicos ou administrativos da integridade acadêmica, sem relação com soluções tecnológicas ou metodológicas aplicáveis ao aprendizado autodirigido. Também foram descartadas fontes cujo acesso ao texto completo não estivesse disponível gratuitamente ou que não trouxessem contribuições relevantes para os objetivos da pesquisa.

3.4 Extração de Dados

Após a seleção dos estudos, os dados relevantes foram extraídos e organizados para identificar padrões, metodologias e soluções aplicáveis à prevenção de fraudes em plataformas de aprendizado autodirigido. Foram analisados aspectos como os tipos de fraudes abordados, estratégias computacionais utilizadas para detecção e mitigação, eficiência dos métodos testados e desafios enfrentados na implementação dessas soluções.

Além disso, buscaram-se extrair informações sobre o impacto das estratégias mencionadas na literatura, incluindo sua aplicabilidade prática, limitações e possíveis adaptações para diferentes contextos educacionais. Os dados foram categorizados para facilitar a análise comparativa entre as abordagens pedagógicas e tecnológicas discutidas nos estudos revisados.

3.5 Análise Crítica dos Estudos

A análise crítica dos estudos selecionados foi realizada com base na relevância, confiabilidade e aplicabilidade das metodologias e soluções propostas. Foram avaliadas a consistência teórica dos artigos, a validade das evidências apresentadas e a adequação dos métodos de pesquisa empregados. Além disso, foram comparadas as diferentes abordagens tecnológicas e pedagógicas, identificando suas vantagens e limitações no combate a fraudes acadêmicas.

Outro aspecto considerado na análise foi a viabilidade de implementação das estratégias em plataformas de aprendizado autodirigido, considerando fatores como custo, complexidade técnica e aceitação por parte dos usuários. Essa avaliação crítica permitiu compreender não somente as soluções já existentes, mas também as lacunas na literatura que podem ser exploradas para o desenvolvimento de novas abordagens.

3.6 Interpretação dos Dados

A interpretação dos dados extraídos dos estudos selecionados foi realizada com base em uma análise comparativa das diferentes abordagens identificadas na literatura. Buscou-se compreender como as estratégias de prevenção e detecção de fraudes acadêmicas em ambientes virtuais podem ser aplicadas especificamente em plataformas de aprendizado autodirigido, considerando suas particularidades e desafios.

Os dados foram analisados qualitativamente, destacando padrões recorrentes nos estudos, bem como divergências e lacunas existentes. Foram identificados os métodos mais eficazes na mitigação de fraudes, suas limitações e os contextos em que apresentaram melhores resultados. Além disso, a interpretação levou em conta a viabilidade de implementação dessas estratégias, considerando aspectos como acessibilidade tecnológica, impacto na experiência do usuário e implicações éticas.

Com essa abordagem, a interpretação dos dados permitiu não somente consolidar o conhecimento existente sobre o tema, mas também sugerir possíveis melhorias e adaptações das estratégias analisadas, contribuindo para o desenvolvimento de soluções mais eficientes para a integridade acadêmica em ambientes de aprendizado autodirigido.

4 RESULTADOS

4.1 Técnicas Computacionais para Detecção de Fraudes

A evolução tecnológica desempenha um papel duplo no contexto da integridade acadêmica: ao mesmo tempo, em que proporciona novas oportunidades para o aprendizado digital, amplia as possibilidades de práticas fraudulentas. Métodos tradicionais de detecção de plágio, baseados somente na comparação de trechos textuais, já não são suficientes para identificar estratégias mais avançadas, como paráfrases sofisticadas, tradução interlinguística e alterações estruturais que dificultam a detecção automatizada. Esse cenário exige a adoção de técnicas computacionais mais robustas, como *learning analytics* e *deep learning*, que ampliam a capacidade de identificação de fraudes acadêmicas.

4.1.1 Comparação entre Métodos Tradicionais e Computacionais

As ferramentas convencionais de detecção de plágio, como Turnitin e SafeAssign, utilizam bases de dados extensas para comparar novos textos com conteúdos previamente armazenados. No entanto, sua eficácia é reduzida quando os textos são reescritos criativamente ou traduzidos entre idiomas sem referência à fonte original. Isso justifica a necessidade de soluções mais avançadas, que não somente detectam semelhanças diretas, mas também analisam padrões estilísticos e estruturas linguísticas.

Nesse sentido, abordagens modernas baseadas em técnicas de Inteligência Artificial têm se mostrado promissoras. Este estudo analisou dois modelos distintos que utilizam técnicas avançadas para garantir a integridade acadêmica: um baseado em *learning analytics*, voltado à autenticação da autoria, e outro fundamentado no uso de *deep learning* para a detecção de plágio.

4.1.2 Modelo 1: Learning Analytics para Validação de Autoria

O primeiro modelo analisado, desenvolvido por Amigud et al. (2017), utiliza *learning analytics* para validar tanto a autoria quanto a identidade do aluno. O sistema se baseia na análise de padrões estilísticos característicos da escrita de

cada estudante, criando perfis linguísticos individualizados a partir de um conjunto de textos previamente submetidos.

A principal vantagem desse modelo está na sua capacidade de detectar inconsistências na autoria de documentos. Caso um aluno submeta um texto cuja estrutura linguística difira significativamente de suas produções anteriores, o sistema emite alerta para os instrutores avaliarem possíveis irregularidades. Os testes realizados demonstraram uma taxa de precisão de 93% na identificação de autoria, superando os 12% alcançados por avaliadores humanos.

Além da alta precisão, um dos diferenciais desse método é sua integração com plataformas de gestão de aprendizado (*LMS*), permitindo uma implementação escalável e não intrusiva. No entanto, sua dependência de um histórico de textos prévios do estudante pode ser um desafio em contextos onde a produção textual é limitada. Além disso, sua eficácia pode ser reduzida caso o aluno adote estratégias para modificar intencionalmente seu estilo de escrita ao longo do tempo.

4.1.3 Modelo 2: Deep Learning para Detecção de Plágio

O segundo modelo analisado, proposto por Hambi e Benabbou (2020), emprega *deep learning* para aprimorar a detecção de plágio, utilizando duas arquiteturas neurais complementares: *Siamese Long Short-Term Memory (SLSTM)* e *Convolutional Neural Network (CNN)*. Enquanto a SLSTM é responsável por identificar padrões textuais complexos, a CNN classifica os diferentes tipos de plágio, diferenciando, por exemplo, cópias literais de paráfrases sofisticadas.

O sistema opera em três etapas principais:

1. **Transformação textual:** os textos são processados e convertidos em vetores semânticos por meio da técnica *Doc2Vec*, preservando o contexto e o significado das palavras.
2. **Identificação de similaridades:** a arquitetura SLSTM analisa os padrões textuais para verificar a presença de plágio mesmo em casos de reformulação sintática.

3. **Classificação do plágio:** a CNN refina os resultados, categorizando os textos plagiados e identificando qual tipo específico de fraude está presente.

Os testes realizados demonstraram uma precisão de 98,33%, um desempenho significativamente superior ao de ferramentas convencionais. Além disso, esse modelo apresenta alta adaptabilidade, podendo ser treinado para diferentes idiomas e domínios acadêmicos. No entanto, sua aplicação requer infraestrutura computacional robusta, o que pode dificultar sua implementação em instituições com recursos limitados.

4.1.4 Análise Comparativa dos Modelos

Os resultados indicam que ambas as abordagens analisadas oferecem avanços significativos em relação aos métodos tradicionais, mas possuem características distintas que influenciam sua aplicabilidade.

Quadro 1 - Principais métodos de detecção de fraudes em plataformas de aprendizado

Critério	Learning Analytics	Deep Learning
Objetivo principal	Identificação de autoria	Detecção avançada de plágio
Precisão	93%	98,33%
Requer dados prévios?	Sim, textos anteriores do aluno	Não
Capacidade de adaptação	Média	Alta
Necessidade computacional	Baixa	Alta
Principais desafios	Pode ser contornado por alunos que alteram intencionalmente seu estilo de escrita	Exige alto poder computacional

Fonte: Autoria própria, 2025.

O modelo de *learning analytics* se destaca pela sua abordagem não intrusiva e pela capacidade de monitoramento contínuo da autoria, sendo ideal para plataformas autogeridas que incentivam a produção textual frequente. Já o modelo baseado em *deep learning* demonstra um desempenho superior na detecção de plágio sofisticado, sendo mais indicado para ambientes onde a verificação de originalidade textual é a prioridade, como submissão de trabalhos acadêmicos mais extensos.

4.1.5 Considerações Finais

A aplicação de *learning analytics* e *deep learning* representa um avanço significativo na mitigação de fraudes acadêmicas. Os modelos analisados demonstraram que o uso de inteligência artificial pode superar as limitações dos métodos convencionais, oferecendo soluções mais precisas e adaptáveis. No entanto, a escolha do modelo mais adequado depende do contexto e das necessidades da instituição.

Plataformas de aprendizado autogerido podem se beneficiar da integração dessas tecnologias, combinando a análise de autoria para monitoramento contínuo com a detecção avançada de plágio para avaliações de maior complexidade. À medida que a inteligência artificial evolui, espera-se que novas abordagens surjam para complementar esses modelos, ampliando ainda mais a eficácia na promoção da integridade acadêmica.

4.2 Indicadores e Métricas de Avaliação em Ambientes Virtuais

As plataformas de aprendizado autogerido têm se consolidado como uma alternativa eficaz ao ensino tradicional, permitindo que os alunos definam seus próprios ritmos e trajetórias de estudo. No entanto, a ausência de supervisão direta por instrutores impõe desafios na avaliação do engajamento e do desempenho dos estudantes. Para lidar com essa limitação, a utilização de indicadores e métricas torna-se essencial, possibilitando o monitoramento do progresso do aluno e a personalização de intervenções pedagógicas.

A definição e implementação desses indicadores têm sido amplamente exploradas na literatura. Oliveira et al. (2012) destacam que os indicadores não somente auxiliam na mensuração da eficiência dos processos educacionais, mas também servem como base para ajustes pedagógicos e aprimoramento das plataformas. Embora inicialmente voltados para o ensino a distância mediado, esses indicadores podem ser adaptados para o aprendizado autodirigido, promovendo maior autonomia e controle sobre o próprio processo de aprendizagem.

4.2.1 Indicadores de Engajamento e Desempenho

O engajamento dos alunos em ambientes virtuais pode ser mensurado por meio de diversas métricas. Ahmadi et al. (2023) sugerem que a frequência de login, o tempo de interação com conteúdos específicos e a quantidade de atividades realizadas são variáveis essenciais para avaliar o nível de comprometimento do estudante. Em plataformas autodirigidas, essas métricas tornam-se ainda mais relevantes, por permitirem identificar padrões de desengajamento e agir proativamente para reverter esse quadro.

Além disso, Oliveira et al. (2012) ressaltam que indicadores operacionais, como cumprimento de cronogramas e prazos de atividades, podem ser incorporados para auxiliar os alunos a manterem um ritmo de estudo adequado. Quando combinados com dados de desempenho, como taxas de acertos em avaliações e evolução do tempo dedicado a cada módulo, esses indicadores oferecem uma visão detalhada sobre a progressão do estudante e podem servir como base para o ajuste de estratégias instrucionais.

4.2.2 Avaliação em Ambientes Virtuais Tridimensionais

A expansão das plataformas digitais trouxe novas abordagens para a avaliação do aprendizado, incluindo a utilização de ambientes tridimensionais interativos. Anjos et al. (2016) propõem o Modelo de Avaliação da Aquisição de Conhecimento (MAAC), que mede o progresso cognitivo dos alunos com base no tempo de interação e no desempenho em atividades práticas. Essa abordagem se mostra altamente relevante para plataformas autodirigidas que utilizam simulações,

uma vez que permite um acompanhamento detalhado da evolução do aprendizado e possibilita ajustes personalizados na trajetória educacional do estudante.

Outra aplicação promissora desses modelos é a avaliação de habilidades sensório-motoras, onde dispositivos hápticos são utilizados para capturar parâmetros como precisão e trajetória de movimento. Esses dados fornecem feedback imediato ao aluno, promovendo um maior controle sobre o próprio desenvolvimento e permitindo um aprendizado mais dinâmico e adaptativo.

4.2.3 Dashboards e Visualização de Dados

A organização e análise dos indicadores em ambientes virtuais são otimizadas pelo uso de dashboards educacionais, que centralizam informações de engajamento, desempenho e interações em uma interface intuitiva. Rezende (2016) destaca que esses painéis visuais auxiliam tanto os alunos quanto os administradores das plataformas, permitindo uma melhor compreensão do progresso acadêmico e facilitando a identificação de dificuldades que possam exigir intervenção.

No contexto do aprendizado autodirigido, dashboards podem ser utilizados para apresentar relatórios personalizados, destacando padrões de estudo, sugerindo ajustes no planejamento e alertando sobre possíveis riscos de evasão ou queda de desempenho. Além disso, Oliveira et al. (2012) sugerem o uso da matriz de necessidades, que estrutura métricas em tabelas organizadas, permitindo a identificação de pontos críticos no aprendizado e orientando possíveis melhorias no design instrucional das plataformas.

4.2.4 Indicadores de Integridade Acadêmica

A integridade acadêmica é um dos aspectos mais críticos em ambientes de aprendizado digital, onde a supervisão direta é reduzida. Hambi e Benabbou (2020) apontam que práticas fraudulentas, como plágio, representam um desafio significativo, especialmente em plataformas autodirigidas. Para mitigar esses problemas, soluções baseadas em *deep learning* empregaram-se para identificar irregularidades com alta precisão.

Modelos computacionais podem ser incorporados de forma automatizada às plataformas, utilizando métricas como taxa de similaridade textual e análise semântica para detectar plágio e garantir a autenticidade da produção acadêmica. Além de atuar na prevenção de fraudes, essas ferramentas possibilitam o fornecimento de feedback detalhado aos alunos, auxiliando no desenvolvimento de uma escrita mais autêntica e reforçando a autorregulação no aprendizado.

4.2.5 Comparação entre Indicadores e sua Aplicabilidade

Os indicadores analisados apresentam diferentes níveis de aplicabilidade e complexidade, dependendo do contexto educacional em que são implementados. A tabela a seguir resume os principais indicadores discutidos e sua relevância para plataformas de aprendizado autodirigido (Quadro 2).

Quadro 2 - Comparação entre modelos de aprendizado para prevenção de fraudes

Indicador	Objetivo	Aplicabilidade em plataformas
Frequência de login e tempo de estudo	Avaliar engajamento	Alto - permite monitoramento contínuo
Cumprimento de cronogramas	Manter ritmo de estudo adequado	Média - depende da estrutura do curso
MAAC (avaliação tridimensional)	Medir progresso cognitivo e sensório-motor	Médio - aplicável a plataformas com simulações interativas
Dashboards educacionais	Consolidar métricas e facilitar visualização	Alto - auxilia na personalização do aprendizado
Análise de plágio por deep learning	Detectar fraudes e garantir integridade acadêmica	Alto - essencial para trabalhos escritos e avaliações online

Fonte: Autoria própria, 2025.

4.2.6 Conclusão

A utilização de indicadores e métricas em plataformas de aprendizado autodirigido é essencial para garantir um acompanhamento eficiente do progresso acadêmico. Os métodos analisados demonstraram que o uso de métricas de

engajamento, dashboards, avaliação tridimensional e análise de plágio pode fornecer insights valiosos tanto para os alunos quanto para os gestores educacionais.

A escolha dos indicadores mais adequados deve considerar o perfil da plataforma e os objetivos do curso, garantindo um equilíbrio entre acompanhamento automatizado e personalização da experiência do estudante. Com o avanço das tecnologias educacionais, espera-se que novas métricas sejam desenvolvidas para aprimorar ainda mais a adaptação do aprendizado e fortalecer a integridade acadêmica no ambiente digital.

4.3 Soluções e Estratégias de Prevenção de Fraudes

O aumento das práticas fraudulentas em plataformas de aprendizado digital desafia a integridade acadêmica, exigindo a adoção de estratégias que combinem abordagens pedagógicas e tecnologias avançadas. A ausência de supervisão direta em ambientes online e a facilidade de acesso a recursos externos comprometem a eficácia dos métodos tradicionais de avaliação, tornando necessária uma abordagem mais estruturada para mitigar fraudes. Estudos indicam que a solução mais eficaz envolve a combinação de estratégias educacionais com tecnologias que promovam transparência e ética no processo de ensino-aprendizagem.

4.3.1 Estratégias Pedagógicas para Redução de Fraudes

Diferentes abordagens pedagógicas são propostas para minimizar práticas fraudulentas. Reformular o design das avaliações, por exemplo, reduz significativamente as oportunidades de plágio e compartilhamento de respostas. Watson e Sottile (2010) destacam que questões subjetivas, que exijam análise crítica e aplicação prática de conceitos, dificultam replicar respostas padronizadas. Além disso, Krsak (2007) recomenda a eliminação de questões de múltipla escolha em avaliações que valem nota, sugerindo, como alternativa, questões de cálculo com números ou variáveis aleatórias, bem como a criação de perguntas que permitam consulta a materiais, favorecendo um aprendizado mais significativo.

Outra estratégia relevante é a restrição do formato das provas. Cluskey et al. (2011) sugerem que medidas como a apresentação de uma questão por vez, a randomização da ordem das perguntas e a limitação do tempo de resposta reduzem a possibilidade de consultas externas e troca de respostas entre os alunos. Além disso, o uso de navegadores bloqueados impede que os estudantes acessem conteúdos não permitidos durante as avaliações, aumentando a confiabilidade dos exames aplicados online.

A conscientização dos alunos sobre as políticas de integridade acadêmica também desempenha um papel crucial na prevenção de fraudes. King et al. (2009) e Tanis (2020) ressaltam a importância de apresentar, desde o início do curso, explicações detalhadas sobre práticas aceitáveis e consequências para aqueles que desrespeitam as regras. Além disso, avaliações formativas, que permitem aos alunos demonstrar progressivamente sua compreensão das normas acadêmicas, contribuem para a construção de um ambiente mais ético e transparente.

4.3.2 Uso de Tecnologias para Detecção e Prevenção de Fraudes

No campo tecnológico, ferramentas de análise de dados e aprendizado de máquina têm se mostrado eficazes na detecção automatizada de padrões fraudulentos. Softwares como Turnitin e SafeAssign são amplamente utilizados para verificar a originalidade de textos acadêmicos, enquanto sistemas de monitoramento remoto, como o Respondus Monitor, permitem a supervisão de provas por meio de webcams e rastreamento de movimentos. Embora essas soluções apresentem bons resultados, preocupações éticas relacionadas à privacidade dos alunos ainda são debatidas. Segundo Cantiello e Geschke (2024), a implementação dessas ferramentas deve ser acompanhada por diretrizes institucionais claras para evitar impactos negativos sobre os estudantes.

Outra estratégia tecnológica eficaz é a diversificação de bancos de questões. Conforme sugerido por Cluskey et al. (2011), a substituição de pelo menos um terço das questões objetivas a cada aplicação de exame reduz significativamente a possibilidade de compartilhamento de respostas. Além disso, técnicas baseadas em aprendizado de máquina podem ser utilizadas para analisar padrões de respostas

incorretas, identificando possíveis casos de fraude e fornecendo subsídios para ajustes pedagógicos.

A implementação de dashboards analíticos é outra solução explorada para monitorar o comportamento dos alunos. Essas ferramentas consolidam dados como frequência de acessos, tempo de conclusão de atividades e desempenho em avaliações, permitindo a identificação precoce de comportamentos atípicos. Rezende (2016) destaca que a visualização dessas métricas auxilia tanto os estudantes, que podem acompanhar sua evolução, quanto os instrutores, que podem intervir antes que dificuldades acadêmicas levem ao desengajamento ou a práticas fraudulentas.

4.3.3 Avaliação de Impacto e Desafios Éticos

Embora as estratégias mencionadas apresentem eficácia na mitigação de fraudes, desafios operacionais e éticos ainda precisam ser considerados. Kleeman (2021) destaca a necessidade de equilibrar a segurança proporcionada por essas ferramentas com o respeito à privacidade dos alunos. O uso de tecnologias de monitoramento remoto, por exemplo, pode gerar ansiedade nos estudantes e levantar preocupações sobre a vigilância excessiva. Scassa (2022) alerta que a aplicação indiscriminada desses sistemas pode acentuar desigualdades acadêmicas, prejudicando alunos que enfrentam dificuldades técnicas ou restrições de acesso a equipamentos adequados.

Além disso, a revisão contínua das políticas de integridade acadêmica é fundamental para garantir que as medidas adotadas acompanhem tanto os avanços tecnológicos quanto a crescente sofisticação das práticas fraudulentas. A introdução de algoritmos de *machine learning* para análise textual, por exemplo, representa um avanço significativo, mas requer adaptações constantes para evitar vieses e garantir uma aplicação justa e eficiente.

4.3.4 Conclusão

A combinação de estratégias pedagógicas e tecnológicas tem se mostrado fundamental para a prevenção de fraudes acadêmicas em ambientes digitais.

Reformular avaliações, diversificar metodologias e conscientizar os alunos sobre a importância da integridade são medidas essenciais para reduzir práticas fraudulentas. Paralelamente, o uso de ferramentas avançadas, como *machine learning*, dashboards analíticos e sistemas de monitoramento remoto, possibilita um controle mais preciso sobre o desempenho e o engajamento dos estudantes.

No entanto, para que essas soluções sejam eficazes, é necessário considerar seus impactos operacionais e éticos. A privacidade dos alunos deve ser preservada, e as políticas institucionais precisam ser continuamente ajustadas para acompanhar as mudanças no cenário educacional. O equilíbrio entre inovação e equidade é o caminho mais promissor para garantir a integridade acadêmica em plataformas de aprendizado digital.

5 DISCUSSÃO

5.1 Recomendações para o design de plataformas

O design de plataformas de aprendizado autodirigido deve equilibrar acessibilidade, usabilidade e mecanismos que garantam a integridade acadêmica. A seguir, são apresentadas recomendações para aprimorar esses sistemas, reduzindo vulnerabilidades a fraudes e fortalecendo a experiência do usuário.

1. Autenticação e Monitoramento Contínuo

- **Múltiplos fatores de autenticação (MFA):** Implementar métodos de autenticação biométrica ou verificação em duas etapas para garantir a identidade do usuário.
- **Análise comportamental:** utilizar *learning analytics* para identificar padrões de comportamento suspeitos, como mudanças bruscas no tempo de resposta ou navegação incomum.
- **Registro de atividade:** manter logs detalhados das interações do usuário, incluindo histórico de acesso e envio de tarefas.

2. Design Adaptativo e Personalizado

- **IA para adaptação de conteúdo:** utilizar algoritmos de aprendizado de máquina para ajustar a complexidade das atividades conforme o desempenho do aluno, reduzindo padrões previsíveis exploráveis por fraudes.
- **Dashboards interativos:** disponibilizar métricas de progresso e engajamento tanto para alunos quanto para administradores, facilitando a identificação de dificuldades e práticas desonestas.

3. Mecanismos de Prevenção de Fraudes

- **Randomização de atividades:** alterar a ordem das questões e opções de resposta para cada tentativa, dificultando o compartilhamento de respostas.
- **Provas supervisionadas por IA:** Implementar reconhecimento facial e análise de padrões de digitação para validar a identidade durante avaliações.
- **Plágio e análise semântica:** integrar ferramentas baseadas em *deep learning* para detectar similaridades textuais e reformulações sintáticas suspeitas.

4. Experiência do Usuário e Engajamento

- **Gamificação:** Incorporar recompensas, desafios e rankings para incentivar a participação ativa sem recorrer a atalhos fraudulentos.
- **Feedback imediato e adaptável:** fornecer correções instantâneas que orientem o aluno a melhorar, reduzindo a necessidade de buscar soluções externas indevidas.
- **Suporte comunitário:** criar fóruns moderados onde alunos possam tirar dúvidas sem recorrer a meios ilegítimos.

5. Transparência e Ética

- **Política de integridade clara:** Exibir, no momento do login e antes das atividades avaliativas, diretrizes sobre boas práticas e consequências para fraudes.
- **Intervenções pedagógicas:** em vez de punições severas imediatas, adotar abordagens educativas para alunos que demonstram tendências a fraudar.

6. Medidas simples e práticas

- **Contrato de compromisso antes das avaliações:** Incluir uma declaração simples que o aluno deve aceitar antes de realizar testes, reforçando a ética acadêmica.
- **Mensagens motivacionais e educativas:** Exibir mensagens que incentivem o aprendizado honesto e expliquem os benefícios da autonomia no estudo.
- **Temporizador para atividades específicas:** Estabelecer um tempo limite razoável para certas atividades, dificultando consultas externas excessivas.

5.2 Recomendações para o design instrucional

O design instrucional em plataformas de aprendizado autodirigido deve equilibrar flexibilidade, engajamento e mecanismos que promovam a autenticidade no aprendizado. A seguir, são apresentadas recomendações para estruturar conteúdos e avaliações que minimizem fraudes e incentivem o desenvolvimento genuíno do conhecimento.

1. Estratégias para Avaliações Autênticas

- **Questões abertas e aplicadas:** priorizar avaliações baseadas em análise crítica, estudos de caso e resolução de problemas reais, reduzindo a eficácia de respostas copiadas.
- **Provas adaptativas:** ajustar automaticamente a complexidade das perguntas com base no desempenho do aluno, tornando mais difícil a memorização de respostas prontas.
- **Atividades colaborativas:** incentivar trabalhos em grupo e debates, promovendo construção de conhecimento coletivo e dificultando fraudes

individuais.

- Trilhas de aprendizado personalizadas: criar caminhos diferentes para cada aluno, evitando que todos realizem as mesmas tarefas, minimizando a possibilidade de compartilhamento de respostas.

2. Feedback e Suporte Contínuo

- Correção automatizada com explicação: em atividades objetivas, oferecer feedback detalhado sobre erros, auxiliando na assimilação dos conceitos.
- Revisões progressivas: permitir reenvios de atividades com melhorias, garantindo que o aprendizado ocorra de forma gradual e aprofundada.
- Monitoramento de dificuldades: utilizar *learning analytics* para identificar padrões de erro e sugerir conteúdos complementares personalizados.

3. Uso de tecnologias para Fortalecer o Aprendizado

- Gamificação: Implementar rankings, desafios e recompensas para aumentar o engajamento e incentivar a aprendizagem contínua.
- Simulações e estudos de caso interativos: criar experiências imersivas que estimulem a aplicação prática dos conhecimentos, reduzindo o incentivo a fraudes.
- Plataformas de IA para tutoria automatizada: disponibilizar assistentes virtuais que orientem os alunos ao longo do curso, reduzindo a necessidade de busca por respostas externas.

4. Construção de uma Cultura de Integridade Acadêmica

- Código de conduta claro e acessível: apresentar diretrizes sobre ética acadêmica interativamente e reforçá-las ao longo do curso.
- Atividades reflexivas sobre integridade: incluir discussões e estudos de caso sobre ética no aprendizado digital para conscientizar os alunos.
- Ambientes de aprendizagem social: criar espaços seguros para troca de dúvidas e experiências, reduzindo o incentivo ao uso de meios fraudulentos.

5. Métodos Simples para Reduzir Fraudes

- **Autoavaliações antes das provas:** Disponibilizar testes opcionais para que os alunos pratiquem antes das avaliações formais, incentivando a preparação.
- **Exibição de estatísticas de progresso:** Mostrar gráficos de desempenho individuais para motivar os alunos a melhorar sem recorrer a fraudes.
- **Pequenos desafios surpresa:** Incluir perguntas ou atividades não previstas no material, incentivando a atenção contínua ao curso.

Essas recomendações garantem que o design instrucional contribua para um aprendizado autogerido mais eficaz, transparente e ético, fortalecendo a credibilidade das plataformas educacionais.

6 CONSIDERAÇÕES FINAIS

Este trabalho investigou estratégias para a identificação, prevenção e desincentivo de fraudes em plataformas de aprendizado autodirigido, analisando padrões comportamentais e explorando abordagens computacionais e pedagógicas para garantir a integridade do processo educacional. A pesquisa evidenciou que práticas fraudulentas, como o uso de respostas automatizadas e a delegação de atividades a terceiros representam desafios significativos para a credibilidade dessas plataformas.

Por meio da revisão bibliográfica e da análise de métodos computacionais, constatou-se que técnicas como *Learning Analytics*, *Deep Learning* e a utilização de indicadores de engajamento e desempenho são promissoras para a detecção de irregularidades. Além disso, estratégias pedagógicas voltadas para o design instrucional e o desenvolvimento de ambientes virtuais interativos demonstraram ser eficazes na mitigação dessas práticas.

Entretanto, além da identificação e prevenção de fraudes, este estudo destacou a importância de estratégias voltadas para o desincentivo ao uso de práticas fraudulentas. Constatou-se que a combinação de um design pedagógico adequado, a conscientização dos cursistas e a implementação de mecanismos que reforcem a importância da integridade acadêmica podem reduzir a motivação para o uso de fraudes. Abordagens como avaliações mais autênticas, metodologias de ensino baseadas em desafios reais e gamificação foram identificadas como formas eficazes de engajar os alunos de maneira legítima, reduzindo sua necessidade de recorrer a práticas desonestas.

A partir desses achados, propôs-se um conjunto de diretrizes e soluções voltadas à promoção da integridade acadêmica em cursos a distância. A adoção dessas recomendações pode contribuir para um ambiente de aprendizado mais

seguro, confiável e transparente, beneficiando tanto os alunos quanto as instituições educacionais.

Como trabalhos futuros, sugere-se a implementação prática das estratégias propostas em diferentes plataformas de ensino, permitindo uma análise mais aprofundada de sua eficácia em cenários reais. Além disso, investigações adicionais sobre o impacto ético da aplicação de métodos computacionais na avaliação do comportamento dos cursistas podem contribuir para um equilíbrio entre segurança, privacidade e um aprendizado genuíno.

Dessa forma, este estudo busca não somente ampliar o conhecimento sobre fraudes no aprendizado autodirigido, mas também oferecer subsídios para o desenvolvimento de soluções que não somente dificultem e detectem fraudes, mas também promovam uma cultura de integridade e engajamento autêntico, reforçando a credibilidade das plataformas de ensino a distância e aprimorando a experiência educacional.

REFERÊNCIAS

ŞEN, N.; YALABIK, N. An activity planning and progress following tool for self-directed distance learning. In: YAZICI, A.; ŞENER, C. (ed.). **Computer and Information Sciences - ISCIS 2003**. Lecture Notes in Computer Science, v. 2869. Berlin, Heidelberg: Springer, 2003. DOI: https://doi.org/10.1007/978-3-540-39737-3_43.

RAMALHO, Raucy; SILVA, Ana; OLIVEIRA, Leandro; LIMA, Odaize; LIMA, Agnaldo. Educação em nuvem: vantagens e desafios da utilização de plataformas baseadas em cloud computing. **IOSR Journal of Business and Management**, v. 26, p. 53–64, 2024. DOI: <https://doi.org/10.9790/487X-2610025364>.

ANDRADE FILHO, Marcos Antonio Soares de; QUADRADO, Anair Meirelles; GONÇALVES, Silvana Aparecida Borges; SILVA, Daiana Soares da. **Aprendizagem autodirigida e design instrucional: caminhos e possibilidades**. Revista Ibero-Americana de Humanidades, Ciências e Educação, [S. l.], v. 10, n. 7, p. 92–107, 2024. DOI: 10.51891/rease.v10i7.14749. Disponível em: <https://periodicorease.pro.br/rease/article/view/14749>. Acesso em: 26 dez. 2024.

ROQUE, Fernando Wersdy Flor. Aprendizagem autogerida (autodirigida): características, vantagens e desvantagens. **Meu Artigo - UOL**. Disponível em: <https://www.meuartigo.uol.com.br>. Acesso em: 26 dez. 2024.

COSTA, L. L. A. C. da; FRANCO, S. K. **Ambientes virtuais de aprendizagem e suas possibilidades construtivistas**. RENOTE, Porto Alegre, v. 3, n. 1, 2005. DOI: 10.22456/1679-1916.13781. Disponível em: <https://seer.ufrgs.br/index.php/renote/article/view/13781>. Acesso em: 26 dez. 2024.

FLORES, Maria; VEIGA SIMÃO, Ana Margarida; BARROS, Alexandra; FLORES, Paulo; PEREIRA, Diana; FERNANDES, Eva; FERREIRA, Paula; COSTA, Luis. **Ensino e aprendizagem à distância em tempos de COVID-19: um estudo com alunos do ensino superior**. Revista Portuguesa de Pedagogia, v. 55, p. 1–28, 2021. DOI: 10.14195/1647-8614_55_1.

MENEGHELLO, Giulianna Carbonari. **Tecnologias de comunicação e informação na educação: plataformas de aprendizagem digital**. 2019.

GLIGOREA, Ilie; CIOCA, Marius; OANCEA, Romana; GORSKI, Andra-Teodora; GORSKI, Hortensia; TUDORACHE, Paul. Adaptive learning using artificial intelligence in e-learning: a literature review. **Education Sciences**, v. 13, n. 12, p. 1216, 2023. DOI: <https://doi.org/10.3390/educsci13121216>.

DIEGO, L. A. B. Friends with benefits: causes and effects of learners' cheating practices during examination. **IAFOR Journal of Education**, v. 5, n. 2, p. 121–138, 2017. DOI: <https://doi.org/10.22492/ije.5.2.06>.

VALIZADEH, M. Cheating in online learning programs: learners' perceptions and solutions. **Turkish Online Journal of Distance Education**, v. 23, n. 1, p. 195–209, 2022. DOI: <https://doi.org/10.17718/tojde.1050394>.

DOWNES, M. University scandal, reputation and governance. **International Journal of Educational Integrity**, v. 13, n. 8, 2017. DOI: <https://doi.org/10.1007/s40979-017-0019-0>.

AMIGUD, Alexander; ARNEDO-MORENO, Joan; DARADOUMIS, Thanasis; GUERRERO, Ana-Elena. Using learning analytics for preserving academic integrity. **The International Review of Research in Open and Distributed Learning**, v. 18, n. 5, 2017. DOI: <https://doi.org/10.19173/irrodl.v18i5.3103>.

BENABBOU, Faouzia. A new online plagiarism detection system based on deep learning. **International Journal of Advanced Computer Science and Applications**, v. 11, n. 9, p. 470–478, 2020. DOI: <https://doi.org/10.14569/IJACSA.2020.0110956>.

RISQUEZ, A.; O'DWYER, M.; LEDWITH, A. 'Thou shalt not plagiarise': from self-reported views to recognition and avoidance of plagiarism. **Assessment & Evaluation in Higher Education**, v. 38, n. 1, p. 34–43, 2011. DOI: 10.1080/02602938.2011.596926.

CANTIOLO, John; GESCHKE, Renee Hotchkiss. Preventing academic dishonesty in online courses: best practices to discourage cheating. *Journal of Health Administration Education*, v. 40, n. 2, p. 205-230, 2024.

HERNÁNDEZ, J. A.; ORTIZ, A. O.; ANDAVERDE, J.; BURLAK, G. Biometrics in online assessments: a study case in high school students. In: INTERNATIONAL CONFERENCE ON ELECTRONICS, COMMUNICATIONS AND COMPUTERS – CONIELECOMP, 18., 2008, Puebla. **Proceedings** [...]. Puebla: IEEE, 2008. p. 111–116. DOI: <https://doi.org/10.1109/CONIELECOMP.2008.36>.

WATSON, G.; SOTTILE, J. Cheating in the digital age: do students cheat more in online courses? **Online Journal of Distance Learning Administration**, v. 13, n. 1, 2010. Disponível em: <https://www.westga.edu/~distance/ojdla/spring131/watson131.html>. Acesso em: 26 dez. 2024.

KRSAK, A. M. Curbing academic dishonesty in online courses. In: **TCC 2007 – TECHNOLOGY, COLLEGES, AND COMMUNITY CONFERENCE**, 12., 2007, Honolulu. **Proceedings** [...]. Honolulu: TCC, 2007. p. 159–170. Disponível em: <http://www.ncta-testing.org/cctc/>. Acesso em: 26 dez. 2024.

CLUSKEY, G. R.; EHLEN, C. R.; RAIBORN, M. H. Thwarting online exam cheating without proctor supervision. **Journal of Academic and Business Ethics**, v. 4, p. 1–8, 2011.

KING, C. G.; GUYETTE, R. W.; PIOTROWSKI, C. Online exams and cheating: an empirical analysis of business students' views. **Journal of Educators Online**, v. 6, n. 1, p. 1–11, 2009. DOI: <https://doi.org/10.9743/JEO.2009.1.5>.

TANIS, C. J. The seven principles of online learning: feedback from faculty and alumni on its importance for teaching and learning. **Research in Learning Technology**, v. 28, p. 1–25, 2020. DOI: <https://doi.org/10.25304/rlt.v28.2319>.

KLEEMAN, J. Remote proctoring: fairness and compliance. **ITNOW**, v. 62, n. 4, p. 58–59, 2021. DOI: <https://doi.org/10.1093/itnow/bwaa121>.

SCASSA, T. The surveillant university: remote proctoring, AI, and human rights. **Canadian Journal of Comparative and Contemporary Law**, v. 8, n. 1, p. 271–312, 2022.