

Educação Sob Medida: Personalização da Avaliação por Competências com Inteligência Artificial

Luana Dorizo de Melo

Trabalho de Conclusão de Curso
MBA em Inteligência Artificial e Big Data

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Educação Sob Medida: Personalização da Avaliação
por Competências com Inteligência Artificial

Luana Dorizo de Melo

Luana Dorizo de Melo

Educação Sob Medida: Personalização da Avaliação por Competências com Inteligência Artificial

Trabalho de conclusão de curso apresentado ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial.

Orientadora: Profa. Dra. Mariana Curi.

USP - São Carlos

2025

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

D699e Dorizo de Melo, Luana
Educação Sob Medida: Personalização da Avaliação
por Competência com Inteligência Artificial / Luana
Dorizo de Melo; orientadora Mariana Curi;
coorientadora Juliana Moraes. -- São Carlos, 2025.
82 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2025.

1. Avaliação por competências. 2. Redes Neurais.
3. Educação Técnica. 4. Feedback Formativo. 5.
Personalização de Aprendizagem. I. Curi, Mariana ,
orient. II. Moraes, Juliana, coorient. III. Título.

Bibliotecários responsáveis pela estrutura de catalogação da publicação de acordo com a AACR2:

Gláucia Maria Saia Cristianini - CRB - 8/4938
Juliana de Souza Moraes - CRB - 8/6176

DEDICATÓRIA

Dedico este trabalho à minha mãe, exemplo de força, dedicação e amor incondicional. Sua presença constante, o apoio nos momentos mais difíceis e as noites em claro foram fundamentais para que eu chegasse até aqui. Esta conquista é, sobretudo, reflexo do seu carinho e dos sacrifícios compartilhados ao meu lado. Obrigada por acreditar em mim e caminhar junto nesta jornada.

Ao SENAC Lapa Tito, pela oportunidade de aplicar este projeto nas turmas de Informática para Internet, e ao corpo técnico e pedagógico, pelas valiosas orientações e pelo direcionamento que contribuíram para a construção do caminho percorrido.

E, por fim, a todos que acreditaram neste projeto, oferecendo motivação, apoio e contribuições que tornaram possível a realização deste resultado.

*A minha mãe pela compreensão,
carinho e apoio incansável.*

AGRADECIMENTOS

À Dra. Solange Rezende, por seus ensinamentos e pela valiosa contribuição ao meu crescimento científico.

Às Dras. Roseli Romero e Juliana Moraes, pelo incentivo constante e pelo apoio nos momentos de maior dificuldade.

Ao Diretor do SENAC Lapa Tito, Sr. Ulisses Defonso Matano, pelo compromisso com a educação e pelo apoio institucional ao longo de minha trajetória acadêmica.

Aos colegas de curso, pela parceria, pela troca de conhecimento e pela amizade construída durante esta jornada.

Expresso, assim, minha profunda gratidão a todos que, de diferentes formas, ofereceram suporte, ensinamento e motivação, elementos fundamentais para a realização deste trabalho.

EPÍGRAFE

“O sucesso nasce do querer, da determinação e persistência em se chegar a um objetivo. Mesmo não atingindo o alvo, quem busca e vence obstáculos, no mínimo fará coisas admiráveis.”

José de Alencar

RESUMO

DORIZO DE MELO, Luana. **Educação Sob Medida: Personalização da Avaliação por Competências com Inteligência Artificial**. 2025. 82 f. Monografia (MBA em Ciências de Dados) – Centro de Ciências Matemáticas Aplicadas à Indústria, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

Este trabalho apresenta o desenvolvimento e a validação do LikertIA, um sistema de avaliação por competências apoiado em Inteligência Artificial (IA), concebido para atender às demandas de cursos técnicos e profissionalizantes no contexto educacional brasileiro. A pesquisa parte da constatação de que os modelos tradicionais de avaliação, centrados em provas objetivas e notas finais, não capturam integralmente o desenvolvimento das competências cognitivas, técnicas e socioemocionais dos estudantes, limitando a personalização do ensino e o acompanhamento do progresso real ao longo do curso. A proposta fundamenta-se na necessidade de uma abordagem avaliativa mais formativa, contínua e baseada em dados, em consonância com autores como Perrenoud (1999), Zabala e Arnau (2010) e Nicol e Macfarlane-Dick (2006), além de dialogar com as diretrizes pedagógicas do SENAC São Paulo. O objetivo central consistiu em criar um protótipo capaz de integrar instrumentos avaliativos estruturados em escala de Likert à análise automatizada de dados por meio de Inteligência Artificial, oferecendo relatórios individualizados e dashboards interativos que apoiem tanto alunos quanto docentes na identificação de pontos fortes, lacunas de aprendizagem e estratégias de replanejamento. A metodologia adotada compreendeu cinco etapas principais: (i) elaboração de instrumentos avaliativos baseados na escala de Likert, aplicados a 16 Unidades Curriculares (UCs); (ii) coleta e armazenamento seguro das respostas em banco de dados MySQL, em conformidade com a Lei Geral de Proteção de Dados (LGPD); (iii) processamento automatizado por meio de modelos de Inteligência Artificial, utilizando redes neurais para classificar estudantes em diferentes perfis de desempenho; (iv) geração de relatórios individuais e comparativos, complementados por análises textuais produzidas por IAs generativas (ChatGPT e Gemini); e (v) disponibilização de dashboards interativos para acompanhamento em tempo real por parte de docentes e discentes. Os resultados, obtidos a partir de um conjunto simulado de 81 alunos e 2.196 respostas, demonstraram a viabilidade técnica e pedagógica da proposta. O modelo alcançou acurácia superior a 82% na classificação entre estudantes de bom e baixo desempenho, enquanto os relatórios individualizados apresentaram potencial para apoiar o feedback formativo contínuo. O comparativo entre as IAs generativas evidenciou complementaridade: o ChatGPT produziu análises mais narrativas e descritivas, enquanto o Gemini privilegiou sínteses objetivas e diagnósticos pragmáticos, enriquecendo o processo avaliativo. A discussão dos achados reforça que o LikertIA contribui para superar lacunas identificadas na literatura, ao unir avaliação por competências, escalas psicométricas e IA explicável (XAI) em um fluxo pedagógico coerente e aplicável ao ensino técnico. Do ponto de vista das contribuições, destaca-se a inovação na integração entre dados subjetivos (respostas em escala Likert) e análises automatizadas por IA, a oferta de feedback contínuo e personalizado e a aderência às marcas formativas do SENAC São Paulo, como protagonismo discente, interdisciplinaridade e visão crítica. Como limitações, ressalta-se que os testes foram realizados em ambiente simulados, e encontra-se em fase de planejamento para aplicação em turmas reais. Trabalhos futuros incluem a ampliação do sistema para outros cursos e modalidades educacionais, a comparação de diferentes algoritmos de *machine learning*, a incorporação de métricas socioemocionais mais complexas e o aprofundamento da análise ética relacionada à transparência e à mitigação de vieses algorítmicos. Conclui-se que a proposta se mostra inovadora e promissora para a transformação dos processos avaliativos em cursos técnicos, promovendo uma educação mais personalizada, justa e orientada por evidências.

Palavras-chave: Avaliação por competências. Educação Técnica. Feedback Formativo.
Personalização da Aprendizagem.

ABSTRACT

DORIZO DE MELO, Luana. **Tailored Education:** Personalization of Competency-Based Assessment with Artificial Intelligence. 2025. 82 f. Monografia (MBA em Ciências de Dados) – Centro de Ciências Matemáticas Aplicadas à Indústria, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

This study presents the development and validation of LikertIA, a competency-based assessment system supported by Artificial Intelligence (AI), designed to meet the demands of technical and vocational education in the Brazilian context. The research stems from the recognition that traditional assessment models, focused on exams and final grades, fail to fully capture the development of students' cognitive, technical, and socio-emotional competencies, thereby limiting both the personalization of teaching and the monitoring of real progress throughout the course. The proposal is grounded in the need for a more formative, continuous, and data-driven assessment approach, in line with authors such as Perrenoud (1999), Zabala and Arnau (2010), and Nicol and Macfarlane-Dick (2006), while also aligned with the pedagogical guidelines of SENAC São Paulo. The main objective was to create a prototype capable of integrating Likert-scale instruments with automated data analysis through AI models, providing individualized reports and interactive dashboards to support both students and teachers in identifying strengths, learning gaps, and re-planning strategies. The methodology was structured in five stages: (i) development of Likert-scale assessment instruments applied to 16 Curricular Units (UCs); (ii) secure data collection and storage in a MySQL database, in compliance with Brazil's General Data Protection Law (LGPD); (iii) automated processing through Artificial Intelligence models, employing neural networks to classify students into different performance profiles; (iv) generation of individual and comparative reports, complemented by textual analyses produced by generative AIs (ChatGPT and Gemini); and (v) provision of interactive dashboards for real-time monitoring by teachers and students. Results, based on a simulated dataset of 81 students and 2,196 responses, demonstrated both the technical and pedagogical feasibility of the proposal. The model achieved an accuracy rate above 82% when classifying students into high or low performance groups, while individualized reports proved valuable in supporting continuous formative feedback. The comparative analysis of generative AIs highlighted complementarities: ChatGPT produced more narrative and descriptive analyses, whereas Gemini favored concise summaries and pragmatic diagnostics, thus enriching the assessment process. The findings indicate that LikertIA contributes to filling gaps identified in the literature by integrating competency-based assessment, psychometric scales, and explainable AI (XAI) into a coherent pedagogical workflow applicable to technical education. From a scientific and pedagogical perspective, the main contributions include the innovative integration of subjective data (Likert-scale responses) with AI-based automated analysis, the provision of continuous and personalized feedback, and the alignment with SENAC São Paulo's educational principles, such as student protagonism, interdisciplinarity, and critical vision. As limitations, it is noted that the tests were conducted in a simulated environment and are currently in the planning stage for implementation with real student groups. Future work involves expanding the system to other courses and educational modalities, comparing different machine learning algorithms, incorporating more complex socio-emotional metrics, and deepening the ethical analysis related to transparency and bias mitigation. In conclusion, the proposed system is innovative and promising for transforming assessment processes in technical education, fostering a more personalized, fair, and evidence-based learning experience.

Keywords: Competency-based assessment. Neural Networks. Technical Education. Formative Feedback. Personalized Learning.

LISTA DE ILUSTRAÇÕES

Figura 1 - Diagrama da proposta	34
Figura 2 - Entrada no sistema por novo usuário	37
Figura 3 - Login no sistema	38
Figura 4 - Dashboard	38
Figura 5 - Página de progresso	39
Figura 6 - Demonstração da geração de relatório	39
Figura 7 - Processo de avaliação início	40
Figura 8 - Processo de avaliação final	40
Figura 9 - Filtro de alunos	41
Figura 10 - Página administrativa para geração do relatório	42
Figura 11 - Relatório de perfil tecnológico ChatGPT	43
Figura 12 - Gráfico de competências ChatGPT	43
Figura 13 - Relatório detalhado ChatGPT	44
Figura 14 - Relatório de perfil tecnológico Gemini	45
Figura 15 - Gráfico de competências Gemini	45
Figura 16 - Relatório detalhado Gemini	46
Figura 17 - Relatório comparativo de perfil	47
Figura 18 - Ampliação do gráfico	47
Figura 19 - Análise comparativa	48
Figura 20 - Scroll da tela de análise comparativa	48

LISTA DE QUADROS

Quadro 1 - Trabalhos relacionados.....	31
--	----

SUMÁRIO

1. INTRODUÇÃO.....	14
2. FUNDAMENTAÇÃO TEÓRICA	16
2.1. AVALIAÇÃO POR COMPETÊNCIAS COM SUPORTE DE MODELOS DE IA E REDES NEURAIS	16
2.2. AVALIAÇÃO POR COMPETÊNCIAS: CONCEITOS FUNDAMENTAIS.....	16
2.2.1. Escala de Likert: Definição e Funcionamento.....	17
2.2.2. Relação da Escala de Likert com a Avaliação por Competências.....	17
2.2.3. Benefícios da Escala de Likert na Avaliação por Competências	18
2.2.4. Exemplo de Aplicação Prática.....	19
2.3. INTELIGÊNCIA ARTIFICIAL NO CONTEXTO EDUCACIONAL.....	22
2.3.1. Personalização do Ensino	22
2.3.2. Análise de Dados Educacionais.....	23
2.3.3. Assistentes Virtuais e Agentes Inteligentes.....	23
2.3.4. Gamificação com IA.....	24
2.3.5. Avaliação Automatizada.....	24
2.3.6. Promoção do Engajamento e da Inclusão.....	24
2.4. REDES NEURAIS E APRENDIZADO PROFUNDO (DEEP LEARNING).....	25
2.5. AVALIAÇÃO FORMATIVA E PERSONALIZADA COM AGENTES E IA	26
2.6. VANTAGENS DA AVALIAÇÃO BASEADA EM IA E REDES NEURAIS.....	27
2.7. DESAFIOS E LIMITAÇÕES	28
3. TRABALHOS RELACIONADOS	30
4. LIKERTIA: AVALIAÇÃO PERSONALIZADA POR COMPETÊNCIAS COM INTELIGÊNCIA ARTIFICIAL	32
4.1. JUSTIFICATIVA	32
4.2. OBJETIVO GERAL.....	32
4.3. OBJETIVOS ESPECÍFICOS	32
4.4. METODOLOGIA.....	33
4.5. DIFERENCIAIS INOVADORES	34
4.6. IMPLEMENTAÇÃO DO PROTÓTIPO.....	35
4.7. FLUXO DE USO DO PROTÓTIPO.....	36

5.	RESULTADOS E DISCUSSÃO	49
5.1.	DATASETS.....	49
5.2.	CONFIGURAÇÃO EXPERIMENTAL.....	49
5.3.	RESULTADOS E DISCUSSÃO	50
6.	CONCLUSÕES.....	52
	GLOSSÁRIO.....	58
	ANEXO A – Prompts para criar as perguntas na IA Manus.....	61
	ANEXO B – Prompts para Análise de Competências por LLM.....	62
	ANEXO C – Prompt de Sistema para Contextualização da LLM	64
	ANEXO D – Prompts para Análise Específica de Competências.....	65
	ANEXO E – Prompt para Análise de Competências Comportamentais	66
	ANEXO F – Prompts para Geração de Relatórios Específicos.....	67
	ANEXO G – Prompts para Integração com Sistemas LMS.....	69
	ANEXO H – Prompts para Personalização de Feedback.....	70
	ANEXO I – Perguntas realizadas com o auxílio da IA Manus	71

1. INTRODUÇÃO

A inteligência artificial (IA) será utilizada para aprimorar a avaliação de alunos em cursos técnicos e profissionais, com foco no sistema de avaliação por competências do SENAC São Paulo. Identificamos que há necessidade de avaliações mais precisas e personalizadas que reflitam o progresso real dos alunos ao longo do curso, considerando suas habilidades e competências específicas.

Estudos recentes (McKinsey & Company, 2020; Siemens e Long, 2011) apontam a necessidade crescente de avaliações mais personalizadas, baseadas em dados e alinhadas às competências profissionais. O projeto reside na crescente demanda por métodos de avaliação mais eficazes e individualizados no contexto educacional. A avaliação tradicional muitas vezes não captura todas as nuances do aprendizado e desenvolvimento dos alunos. Autores como Perrenoud (1999) e Zabala & Arnau (2010) apontam que as avaliações tradicionais não capturam adequadamente o desenvolvimento integral do estudante. Utilizar a IA para gerar avaliações detalhadas e relatórios personalizados, que não apenas medem o desempenho acadêmico, mas também fornecem insights sobre o progresso e as atividades que necessitam de melhoria. Isso pode resultar em um ensino mais adaptado às necessidades individuais dos alunos, promovendo um aprendizado mais eficaz e significativo. Pesquisas de Luckin et al. (2016) e Holmes et al. (2019) demonstram ganhos significativos no uso de IA para personalização do ensino e aprimoramento da aprendizagem.

Este trabalho tem como objetivo desenvolver um sistema de avaliação de alunos por competências, utilizando IA para gerar avaliações e relatórios detalhados sobre o desempenho dos alunos em cada unidade curricular e seu progresso ao longo do curso. Este sistema visa proporcionar uma avaliação mais precisa e personalizada, auxiliando tanto os docentes quanto os alunos a identificar pontos fortes e aspectos a serem melhorados, além de traçar estratégias de ensino e aprendizado mais eficazes.

O trabalho teve como base a série Orientações para a prática pedagógica: Avaliar¹. Esta série analisa as práticas pedagógicas centradas na avaliação como ferramenta essencial para promover um aprendizado significativo, tomando como base as diretrizes propostas pelo SENAC São Paulo. A avaliação é entendida não apenas como um meio de mensurar resultados,

¹ Orientações para a prática pedagógica: Avaliar, que pode ser acessada em <http://www1.sp.senac.br/hotsites/materiais/docencia/Avaliar.pdf>

mas como um processo formativo e contínuo, que integra o desenvolvimento de competências, habilidades e atitudes dos estudantes.

A proposta central reside na adoção de métodos avaliativos que valorizem o protagonismo discente e a interdisciplinaridade, permitindo uma construção coletiva do conhecimento. Essa abordagem promove a reflexão crítica e considera o contexto individual e social dos alunos, alinhando-se às “marcas formativas” do SENAC: domínio técnico-científico, visão crítica, atitude sustentável, colaboração e empreendedorismo (SENAC São Paulo, 2024)-conforme as diretrizes da publicação Orientações para a prática pedagógica: Avaliar.

Além disso, o trabalho destaca estratégias pedagógicas voltadas à implementação dessas práticas, como projetos integradores, reuniões pedagógicas regulares e o diálogo constante com a comunidade escolar. Essas ações buscam consolidar um ambiente educacional que privilegie o aprendizado significativo, refletindo a missão institucional de preparar alunos para os desafios do mercado de trabalho e da sociedade.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. AVALIAÇÃO POR COMPETÊNCIAS COM SUPORTE DE MODELOS DE IA E REDES NEURAIIS

A avaliação por competências representa uma mudança paradigmática no campo educacional, deslocando o foco da medição de resultados estritamente acadêmicos para uma análise mais abrangente das habilidades práticas e aplicáveis dos alunos (Perrenoud, 1999). Nesse contexto, o uso de Inteligência Artificial (IA), agentes inteligentes e redes neurais oferece novas possibilidades para observar, analisar e interpretar o desempenho dos estudantes de forma personalizada, escalável e centrada no desenvolvimento de competências específicas.

2.2. AVALIAÇÃO POR COMPETÊNCIAS: CONCEITOS FUNDAMENTAIS

De acordo com autores como Zabala e Arnau (2010), a avaliação por competências busca verificar o domínio de saberes mobilizáveis para resolver problemas complexos e contextuais. As competências podem ser categorizadas em:

- Cognitivas: Capacidade de raciocínio, análise crítica e solução de problemas.
- Socioemocionais: Trabalho em equipe, comunicação e ética.
- Técnicas: Aplicação de ferramentas e metodologias específicas.

A abordagem difere das avaliações tradicionais ao considerar não apenas o que o aluno sabe, mas como ele aplica esse conhecimento em situações práticas. Para utilizarmos esse conceito e quantificar o que o aluno está desenvolvendo vamos fazer a utilização da escala de Likert, relacionando com a avaliação de competências.

A escala de Likert tem se destacado como uma ferramenta eficaz na avaliação por competências, permitindo a mensuração sistemática de percepções, atitudes e comportamentos em relação às habilidades desenvolvidas. Sua aplicação em avaliações educacionais está alinhada com abordagens baseadas na análise do desempenho prático, colaborativo e reflexivo dos alunos (Perrenoud, 1999; Zabala e Arnau, 2010). Abaixo, discutimos como a escala de Likert pode ser utilizada nesse contexto, embasada em literatura científica.

A avaliação por competências vai além da verificação de conteúdos teóricos, enfocando a capacidade dos indivíduos de mobilizar conhecimentos, habilidades e atitudes para resolver problemas em situações reais. Segundo Zabala e Arnau (2010), essa abordagem integra dimensões cognitivas, procedimentais e atitudinais, proporcionando uma visão mais ampla do desenvolvimento do aluno. Essa metodologia exige instrumentos que capturem evidências de forma quantitativa e qualitativa (Dalmoro e Vieira 2013), sendo a escala de Likert uma opção prática e acessível.

2.2.1. Escala de Likert: Definição e Funcionamento

A escala de Likert, desenvolvida por Rensis Likert em 1932, é um método de medição psicométrica amplamente utilizado para avaliar percepções e atitudes. Ela é composta por declarações ou perguntas que permitem ao respondente indicar seu grau de concordância ou frequência de comportamento, geralmente em uma escala de 5 a 7 pontos (Likert, 1932; Jamieson, 2004).

As categorias típicas incluem:

1: Discordo totalmente / Nunca.

- 2: Discordo parcialmente / Raramente.
- 3: Neutro / Às vezes.
- 4: Concordo parcialmente / Frequentemente.
- 5: Concordo totalmente / Sempre.

Esse modelo é útil para capturar dados subjetivos e transformar percepções qualitativas em indicadores mensuráveis.

2.2.2. Relação da Escala de Likert com a Avaliação por Competências

A aplicação da escala de Likert na avaliação por competências permite medir de forma estruturada a percepção de alunos e professores sobre as habilidades desenvolvidas. Essa abordagem atende às necessidades de análises baseadas em indicadores claros e mensuráveis, como propõem Perrenoud (1999) e Nicol e Macfarlane-Dick (2006). A seguir, destacam-se exemplos de como a escala de Likert pode ser integrada à avaliação de diferentes dimensões das competências:

Competências Cognitivas: Avaliação do domínio de conceitos teóricos e sua aplicação prática:
Exemplo de pergunta “Nesta atividade, demonstrei domínio dos conceitos teóricos necessários para resolver o problema proposto”.

Respostas utilizando a escala de Likert:

- (1): Discordo totalmente / Nunca.
- (2): Discordo parcialmente / Raramente.
- (3): Neutro / Às vezes.
- (4): Concordo parcialmente / Frequentemente.
- (5): Concordo totalmente / Sempre

Competências Socioemocionais: Identificação de habilidades interpessoais, como comunicação e trabalho em equipe:

Exemplo de pergunta: “Contribuí de maneira efetiva para as discussões do grupo”.

Respostas utilizando a escala de Likert:

- (1): Discordo totalmente / Nunca.
- (2): Discordo parcialmente / Raramente.
- (3): Neutro / Às vezes.
- (4): Concordo parcialmente / Frequentemente.
- (5): Concordo totalmente / Sempre

Competências Técnicas: Medida da capacidade de aplicar ferramentas e técnicas específicas:

Exemplo de pergunta: “Utilizei corretamente as ferramentas e técnicas para solucionar os desafios apresentados”.

Respostas utilizando a escala de Likert:

- (1): Discordo totalmente / Nunca.
- (2): Discordo parcialmente / Raramente.
- (3): Neutro / Às vezes.
- (4): Concordo parcialmente / Frequentemente.
- (5): Concordo totalmente / Sempre

2.2.3. Benefícios da Escala de Likert na Avaliação por Competências

A literatura destaca várias vantagens no uso da escala de Likert nesse contexto podemos destacar:

- **Quantificação de Resultados:** Permite transformar percepções subjetivas em dados mensuráveis para análise estatística (Likert, 1932; Jamieson, 2004 e Bertram, 2008).
- **Feedback Formativo:** Fornece insumos para feedbacks personalizados e baseados em evidências (Nicol e Macfarlane-Dick, 2006).
- **Comparação e Monitoramento:** Facilita a identificação de lacunas e a análise longitudinal do progresso dos alunos (Perrenoud, 1999).
- **Flexibilidade:** Pode ser aplicada em diferentes contextos, como projetos práticos, dinâmicas em grupo ou autoavaliações.

2.2.4. Exemplo de Aplicação Prática

Um cenário prático de aplicação da escala de Likert pode ser observado em atividades colaborativas realizadas em sala de aula. Após uma dinâmica de grupo, o professor pode solicitar que os alunos avaliem aspectos do desempenho individual e coletivo, promovendo a autorreflexão e o desenvolvimento de competências. A seguir, apresenta-se uma simulação contextualizada:

Atividade: Trabalho em equipe para resolver um problema técnico relacionado ao desenvolvimento de uma aplicação web.

Momento: Final da atividade.

Instrumento: Questionário com perguntas baseadas na escala de Likert (1 a 5 pontos – de "Discordo totalmente" a "Concordo totalmente").

Exemplos de perguntas:

“Contribuí de maneira efetiva para a execução das tarefas do grupo.”

“Consegui mediar conflitos ou divergências durante a atividade.”

“Minha equipe demonstrou estratégias eficazes para resolver o problema técnico.”

“Identifiquei oportunidades para melhorar minha comunicação com os colegas.”

“Fui capaz de aplicar conceitos técnicos discutidos em aula para solucionar os desafios propostos.”

Essa metodologia pressupõe a honestidade e a autorreflexão do aluno ao responder, sendo recomendada a mediação docente para validar os resultados.

Esses dados permitem uma análise quantitativa e qualitativa do desempenho. Os resultados, quando organizados em planilhas ou analisados por meio de ferramentas de IA, como *dashboards* automatizados, permitem:

- Identificar padrões de comportamento (ex.: colaboração, liderança, comunicação);
- Avaliar competências específicas, como domínio técnico, trabalho em equipe e pensamento crítico;
- Apoiar intervenções pedagógicas personalizadas, com base no desempenho e nas autopercepções dos alunos.

A aplicação sistemática da escala de Likert ao longo das diferentes etapas de um curso configura-se como uma estratégia metodológica de destaque, amplamente reconhecida por pesquisadores e teóricos da avaliação educacional. A escala de Likert, originalmente desenvolvida por Rensis Likert, permite a obtenção de dados quantitativos sobre percepções, atitudes e competências, sendo especialmente valorizada por sua flexibilidade, facilidade de análise e capacidade de mensurar intensidades de opinião e comportamento, conforme destacado por Bermudes (2016) e Surveymonkey (2019).

No contexto avaliativo, a possibilidade de geração de séries históricas de desempenho é central para um acompanhamento longitudinal da aprendizagem dos estudantes, proporcionando o reconhecimento de padrões, avanços, estagnações e dificuldades de ordem individual e coletiva. Perrenoud (1999) enfatiza que a avaliação formativa, quando aplicada continuamente, atua como instrumento de regulação dos processos de aprendizagem. Por meio do registro sistemático e da devolutiva frequente (*feedback*), o docente pode orientar intervenções que promovem a personalização efetiva do ensino, favorecendo o protagonismo discente e a tomada de decisão pedagógica ancorada em evidências concretas.

A literatura contemporânea destaca ainda a necessidade de uma avaliação inclusiva e acolhedora, como propõe Luckesi (2018), para quem a avaliação deve ser um ato amoroso, diagnóstico e integrador, contrastando com práticas excludentes e meramente classificatórias. Segundo o autor, avaliar é "acolher e integrar", dando subsídios para que cada educando seja incluído e acompanhado em sua trajetória formativa, condição essencial para a construção de trilhas formativas individualizadas.

No curso Técnico em Informática para Internet, as práticas aqui descritas foram incorporadas às Unidades Curriculares (UCs), aliadas à perspectiva das avaliações baseadas em competência. Nesta abordagem, ressalta-se a importância da hierarquia dos objetivos educacionais, tal como sistematizada na Taxonomia de Bloom (Bloom, 1972 e Educação para

todos, 2025), que estrutura o desenvolvimento cognitivo nos níveis de conhecimento, compreensão, aplicação, análise, síntese e avaliação. Bloom e colaboradores defendem que educadores devem estruturar metas e instrumentos avaliativos de modo progressivo, permitindo ascensão do aluno a níveis automatizados de complexidade intelectual.

O processo de operacionalização pedagógica apoiou-se fortemente na inteligência artificial, especialmente por meio de Large Language Models (LLMs) orientados por conjuntos de prompts específicos. Esses recursos tecnológicos são defendidos por Siemens e Long (2025) como capazes de amplificar a colaboração entre professor, estudante e máquina, promovendo análises profundas dos dados educacionais e fornecendo devolutivas precisas e customizadas, com suporte à tomada de decisão pedagógica em tempo real.

No documento técnico, cada etapa operacional foi sistematizada em anexos com funções bem delineadas:

- Anexo A – Prompts para criar as perguntas na IA Manus: detalha a elaboração de itens avaliativos estruturados no padrão Likert, adaptados às competências e conteúdo de cada UC, alinhando-se à Taxonomia de Bloom e à BNCC para garantir coerência curricular e habilidade cognitiva progressiva.
- Anexo B – Prompts para Análise de Competências por LLM: apresenta instruções para análise interpretativa de perfil discente, integrando dimensões cognitiva, procedimental e atitudinal, conforme sugere Perrenoud (1999) nas abordagens de avaliação formativa.
- Anexo C – Prompt de Sistema para Contextualização da LLM: aborda a transformação de dados brutos em narrativas compreensíveis, mediando o uso da tecnologia para evitar interpretações mecânicas e promover significados pedagógicos relevantes, condizente com as recomendações de Siemens para IA aplicada em setores educacionais.
- Anexo D – Prompts para Análise Específica de Competências: foca diagnósticos detalhados e personalizados, reforçando a importância de instrumentos e intervenções adaptados ao contexto do aluno.
- Anexo E – Prompts para Geração de Relatórios Específicos: contempla relatórios docentes que agregam visão coletiva, pontos fortes, áreas críticas e ações corretivas, orientando avanços individuais e coletivos em consonância com autores como Luckesi e Bloom.
- Anexo F – Prompts para Integração com Sistemas LMS: detalha o uso dos dados e resultados no LMS Chamilo, promovendo a acessibilidade dos registros avaliativos e integração do planejamento docente e administrativo, conforme recomendações sobre inovação educacional.
- Anexo G – Prompts para Personalização de Feedback: fecha o ciclo de diagnóstico e acompanhamento com devolutivas individualizadas, essenciais para a função reguladora da avaliação, conforme defendido por Perrenoud e Luckesi.

A produção e utilização dos instrumentos aqui relatados encontra profunda ancoragem nos referenciais teóricos da avaliação educacional e das práticas inovadoras mediadas por inteligência artificial. Autores como Bloom, Perrenoud, Luckesi e Siemens reforçam que a avaliação deve ser continuamente repensada e aprimorada para potencializar processos formativos, garantir inclusão e desenvolver trilhas de aprendizagem personalizadas.

Essa abordagem está alinhada com os princípios da avaliação formativa e contínua, conforme defendido por Nicol e Macfarlane-Dick (2006) e Mariano e Alves (2019), e se ancora nos referenciais do SENAC São Paulo, valorizando o protagonismo do estudante, a interdisciplinaridade e a construção do conhecimento com base em experiências práticas.

2.3. INTELIGÊNCIA ARTIFICIAL NO CONTEXTO EDUCACIONAL

Modelos de IA têm sido cada vez mais integrados ao ensino e à aprendizagem, desempenhando papéis como:

- **Personalização do Ensino:** Plataformas baseadas em IA ajustam conteúdos e atividades com base no desempenho individual (McKinsey and Company, 2020 e Rahman 2022).
- **Análise de Dados Educacionais:** Ferramentas de aprendizado de máquina são capazes de identificar padrões de desempenho e prever dificuldades futuras (Siemens e Long, 2011).
- **Agentes Inteligentes:** Simulações com agentes permitem recriar cenários realistas, promovendo a aplicação prática de competências.

A Inteligência Artificial (IA) no campo educacional tem evoluído rapidamente, trazendo novas formas de personalização do aprendizado, engajamento dos estudantes e avaliação de competências. Sua aplicação vai além de ferramentas para ensino, abrangendo mecanismos que possibilitam análises detalhadas do processo de aprendizagem, promovendo feedback instantâneo e orientado às necessidades individuais. Aqui estão as principais áreas de impacto da IA no contexto educacional:

2.3.1. Personalização do Ensino

Uma das principais contribuições da IA para a educação é a personalização da aprendizagem. Plataformas como Knewton (2025), DreamBox Learning(2025) e Squirrel AI (2025) utilizam algoritmos de aprendizado de máquina para adaptar conteúdos e estratégias

pedagógicas às necessidades de cada estudante em tempo real. Essas tecnologias analisam o histórico de desempenho, tempo de resposta, padrões de erro e preferências individuais para ajustar o nível de dificuldade, propor atividades corretivas e recomendar trilhas de aprendizagem customizadas.

De acordo com Luckin *et al.* (2016), a personalização por IA promove o desenvolvimento da metacognição, permitindo que os alunos se tornem mais conscientes de seus próprios processos de aprendizagem.

2.3.2. Análise de Dados Educacionais

A análise de dados educacionais - ou *Learning Analytics* - é amplificada com o uso da IA, que permite identificar padrões ocultos em grandes volumes de dados (Big Data). Isso possibilita aos professores:

- Antecipar dificuldades dos alunos (aprendizagem preditiva);
- Monitorar o engajamento em tempo real;
- Planejar intervenções pedagógicas baseadas em dados.

Ferramentas como o *Moodle Learning Analytics* (2025), o *Canvas LMS Analytics* (2025) e plataformas baseadas em IA como o *Watson Education da IBM* (2025) são exemplos práticos dessa aplicação. Siemens e Long (2011) destacam que essa abordagem oferece oportunidades valiosas para transformar o processo educacional em tempo real.

2.3.3. Assistentes Virtuais e Agentes Inteligentes

Agentes conversacionais como o ChatGPT, Alexa e Siri têm sido integrados a ambientes de aprendizagem para apoiar tanto professores quanto alunos, Holmes et al., 2019. Eles atuam como tutores virtuais que:

- Respondem dúvidas sobre conteúdos específicos;
- Simulam cenários de aprendizagem ativa (como entrevistas ou jogos de papéis);
- Avaliam respostas em tempo real utilizando NLP (Processamento de Linguagem Natural).

A integração com sistemas educacionais permite desenvolver ambientes interativos e responsivos, promovendo o desenvolvimento da autonomia dos alunos.

2.3.4. Gamificação com IA

A IA também tem impulsionado a gamificação da aprendizagem, promovendo maior engajamento dos estudantes. Plataformas como Duolingo (2025), Classcraft (2025) e Quizizz (2025) utilizam IA para:

- Adaptar o nível de dificuldade com base na performance do estudante;
- Sugerir recompensas estratégicas;
- Coletar dados para feedback personalizado.

Estudos mostram que a gamificação adaptativa melhora a motivação e a retenção de conteúdo, tornando o processo de ensino mais atrativo (Dicheva et al., 2015).

2.3.5. Avaliação Automatizada

O uso de IA na avaliação já é uma realidade em diversos sistemas. Modelos baseados em NLP (Processamento de Linguagem Natural) permitem a análise automatizada de redações, respostas discursivas e projetos, Shute e Rahimi (2020). Ferramentas como Grammarly (2025), Turnitin (2025), ETS e-rater (2025) e WriteToLearn (2025) aplicam critérios como:

- Coesão e coerência textual;
- Uso apropriado de vocabulário técnico;
- Plágio e originalidade.

Além disso, essas ferramentas oferecem feedback instantâneo, o que potencializa a aprendizagem formativa.

2.3.6. Promoção do Engajamento e da Inclusão

Soluções baseadas em IA têm o potencial de tornar a educação mais inclusiva. Tecnologias como o Microsoft Immersive Reader (2025) e o Google Text-to-Speech (2025) oferecem suporte a estudantes com deficiência visual, dislexia ou baixa proficiência em leitura. Além disso, algoritmos preditivos são usados para identificar alunos em risco de evasão escolar e orientar ações preventivas.

Segundo Holmes, et al., (2020), outro destaque é o uso de IA para oferecer tradução automática e acessibilidade linguística, permitindo a inclusão de alunos de diferentes contextos socioculturais em ambientes multilíngues.

2.4. REDES NEURAIIS E APRENDIZADO PROFUNDO (*DEEP LEARNING*)

As Redes Neurais Artificiais (RNAs) são estruturas computacionais inspiradas na rede neural biológica do cérebro humano. Essas redes são compostas por múltiplas camadas de unidades interligadas (neurônios artificiais) que processam informações e identificam padrões complexos em grandes volumes de dados. Com o avanço do aprendizado profundo (*deep learning*), as RNAs passaram a desempenhar um papel cada vez mais significativo no campo educacional, permitindo novas abordagens para personalização, avaliação e acompanhamento da aprendizagem dos estudantes (Rahman, 2022).

No contexto educacional, as RNAs vêm sendo aplicadas em diversas frentes. Uma das mais importantes é o Processamento de Linguagem Natural (PLN), que permite a análise de textos escritos pelos alunos. Modelos baseados em arquiteturas como BERT ou GPT, por exemplo, conseguem interpretar respostas discursivas e oferecer feedback automatizado e contextualizado, contribuindo para o aprimoramento da escrita e da argumentação (Holmes et al., 2019).

Outro campo de aplicação são os sistemas de recomendação e classificação, nos quais redes neurais são utilizadas para identificar o nível de desempenho do aluno e sugerir atividades ou conteúdos alinhados às suas necessidades específicas. Esse tipo de personalização ocorre com base em uma análise combinada de dados como engajamento, frequência, participação em fóruns e resultados em avaliações (Khosravi et al., 2022).

As redes neurais recorrentes (RNNs) se destacam na análise de séries temporais, permitindo, por exemplo, identificar a evolução do desempenho do estudante ao longo do tempo. Já as redes convolucionais (CNNs) têm sido exploradas em ambientes com imagens, como plataformas de realidade aumentada e análise de projetos gráficos. Mais recentemente, os modelos baseados em Transformers, como o GPT-4, revolucionaram o campo educacional ao viabilizarem interações em linguagem natural com elevada precisão, promovendo assistências pedagógicas autônomas e escaláveis (The Royal Society, 2020).

Além disso, sistemas de tutoria inteligente (*Intelligent Tutoring Systems* - ITS), alimentados por RNAs, oferecem suporte individualizado ao estudante, adaptando conteúdos, explicações e atividades em tempo real conforme as respostas dadas (Holmes et al., 2019). Esse processo é particularmente eficaz em ambientes online ou híbridos, nos quais a mediação constante do professor pode ser limitada.

Contudo, o uso de RNAs em ambientes educacionais exige cuidados éticos. É essencial considerar o viés algorítmico, a transparência dos modelos utilizados, e a segurança e privacidade dos dados dos estudantes. Segundo The Royal Society (2020), a governança ética da IA em educação deve priorizar a equidade, a responsabilidade e o respeito aos direitos dos aprendizes.

2.5. AVALIAÇÃO FORMATIVA E PERSONALIZADA COM AGENTES E IA

A avaliação formativa é uma abordagem pedagógica que visa acompanhar o progresso dos alunos ao longo do processo de aprendizagem, oferecendo feedbacks contínuos e personalizados. No contexto da educação apoiada por Inteligência Artificial, essa forma de avaliação ganha novas possibilidades por meio da coleta e análise de dados em tempo real, além da capacidade de adaptação dos sistemas aos perfis e às necessidades individuais dos estudantes (Nicol e Macfarlane-Dick, 2006).

Com o uso de agentes inteligentes e técnicas de aprendizado de máquina, é possível aplicar uma avaliação personalizada que vá além da simples atribuição de notas. Os sistemas de tutoria inteligente (ITS), por exemplo, utilizam algoritmos para avaliar continuamente o desempenho do estudante e sugerir novas rotas de aprendizagem com base nas suas respostas, preferências e histórico (Holmes et al., 2019). Esses sistemas também conseguem adaptar o nível de dificuldade das tarefas, oferecendo desafios adequados para manter o engajamento e promover o desenvolvimento de competências.

Além disso, a IA permite a análise detalhada do processo de resolução de problemas, identificando não apenas o resultado final, mas também as estratégias utilizadas pelos alunos, o tempo gasto em cada etapa e os erros recorrentes. Com base nessas informações, os professores podem intervir de forma mais eficaz, ajustando as práticas pedagógicas e personalizando o ensino conforme as necessidades de cada estudante (Luckin et al., 2016).

Outro recurso promissor é o uso de dashboards educacionais baseados em IA, que sintetizam os dados de aprendizagem em visualizações acessíveis para educadores e estudantes. Esses painéis ajudam a monitorar o progresso individual e coletivo, destacando competências adquiridas, lacunas a serem trabalhadas e comportamentos que indicam risco de evasão ou baixo engajamento (Siemens e Long, 2011).

Importante destacar que, para garantir a equidade, os sistemas de avaliação baseados em IA devem ser transparentes, explicáveis e livres de viés. Khosravi et al. (2022) defendem que a explicabilidade dos modelos - ou seja, a capacidade de entender por que uma recomendação ou diagnóstico foi feito - é um elemento crucial para a confiança e a adoção ética da IA na educação.

Assim, a combinação entre avaliação formativa, personalização e Inteligência Artificial possibilita uma abordagem mais humanizada, justa e eficaz, colocando o estudante no centro do processo de aprendizagem, conforme defendido pelas diretrizes educacionais do SENAC São Paulo.

2.6. VANTAGENS DA AVALIAÇÃO BASEADA EM IA E REDES NEURAIAS

A incorporação da Inteligência Artificial (IA) e das Redes Neurais Artificiais (RNAs) nos processos avaliativos tem promovido avanços expressivos na forma como a aprendizagem é acompanhada e compreendida. Essas tecnologias não apenas automatizam processos, mas ampliam a capacidade analítica do ambiente educacional, trazendo benefícios significativos para docentes, discentes e gestores.

Uma das principais vantagens está na personalização do processo avaliativo, permitindo que a avaliação se adapte ao perfil de cada estudante. Sistemas inteligentes podem sugerir avaliações personalizadas, considerando o histórico de aprendizagem, estilo cognitivo e desempenho anterior do aluno (Luckin et al., 2016). Isso contribui para o fortalecimento da autonomia e da autorregulação da aprendizagem, pilares da abordagem por competências.

Outro ponto relevante é a escalabilidade e eficiência. A IA possibilita a aplicação e correção de avaliações em larga escala, mantendo critérios consistentes e padronizados, mesmo em turmas extensas ou cursos com alta rotatividade de alunos. Ferramentas baseadas em *machine learning* são capazes de avaliar desde testes objetivos até redações e projetos complexos, com alto grau de precisão (Shute e Rahimi, 2020).

A objetividade e redução de vieses humanos também são destacados como benefícios essenciais. Embora todo sistema de IA deva ser cuidadosamente treinado e auditado para mitigar vieses algorítmicos, estudos mostram que avaliações automatizadas podem reduzir julgamentos subjetivos, promovendo maior justiça no processo de avaliação (Khosravi et al., 2022). Isso é especialmente importante em instituições comprometidas com a inclusão e a equidade educacional.

Outro ganho relevante é a capacidade analítica ampliada. As RNAs processam grandes volumes de dados educacionais, identificando padrões não evidentes a olho nu. Isso permite a antecipação de dificuldades, a detecção de alunos em risco de evasão e a proposição de intervenções pedagógicas precisas, apoiando a tomada de decisão docente e institucional (Siemens e Long, 2011).

Além disso, sistemas avaliativos baseados em IA permitem um foco no processo, e não apenas no resultado final. Com o apoio de algoritmos inteligentes, é possível acompanhar as estratégias de resolução de problemas, o tempo gasto em cada etapa, os erros mais frequentes e a progressão cognitiva do aluno. Isso torna a avaliação uma ferramenta formativa poderosa e contínua (Holmes et al., 2019).

Por fim, a IA contribui para o engajamento do estudante, ao permitir feedbacks imediatos, visualizações claras de desempenho (como dashboards interativos) e sugestões de caminhos personalizados. Essa abordagem fortalece o protagonismo do aluno e estimula o aprendizado ativo e reflexivo.

2.7. DESAFIOS E LIMITAÇÕES

Apesar dos avanços e benefícios proporcionados pela Inteligência Artificial (IA) e pelas Redes Neurais Artificiais (RNAs) na avaliação educacional, é fundamental reconhecer os desafios e limitações envolvidos na implementação dessas tecnologias. A adoção crítica e consciente da IA no ensino exige que instituições, docentes e desenvolvedores estejam atentos a questões técnicas, éticas, pedagógicas e legais.

Um dos principais desafios é a dependência de dados de alta qualidade. Para que os sistemas baseados em IA funcionem de forma eficaz, é necessário dispor de grandes volumes de dados educacionais completos, atualizados e confiáveis. Dados mal estruturados ou enviesados podem comprometer a acurácia dos modelos preditivos e reforçar desigualdades educacionais existentes (Khosravi et al., 2022).

Outro obstáculo relevante é a infraestrutura tecnológica e a capacitação docente. A implementação de sistemas baseados em IA requer servidores robustos, conectividade de qualidade e integração com os ambientes virtuais de aprendizagem. Além disso, muitos professores ainda não se sentem preparados para utilizar essas ferramentas de forma pedagógica e estratégica. A formação docente contínua e contextualizada é, portanto, essencial para o sucesso dessa integração (Luckin et al., 2016).

Do ponto de vista ético, surgem questões relacionadas à privacidade e proteção de dados dos estudantes. O uso de dados sensíveis para fins de avaliação deve estar em conformidade com legislações como a Lei Geral de Proteção de Dados (LGPD) no Brasil e o *General Data Protection Regulation* (GDPR) na União Europeia. Além disso, é necessário garantir o consentimento informado, a transparência dos algoritmos e a explicabilidade dos resultados (The Royal Society, 2020).

O risco de viés algorítmico também é significativo. Modelos de IA treinados com dados enviesados podem perpetuar ou até acentuar desigualdades educacionais, classificando erroneamente alunos de determinados grupos sociais. A revisão constante dos dados e dos critérios utilizados pelos algoritmos é fundamental para garantir uma avaliação justa e equitativa (Holmes et al., 2019).

Além disso, há limitações pedagógicas a serem consideradas. A interpretação automática de competências socioemocionais, criatividade ou pensamento crítico ainda é um grande desafio para a IA, que tende a operar com maior eficácia em dimensões mais objetivas do conhecimento. Assim, o papel do professor como mediador do processo avaliativo continua insubstituível.

Por fim, é importante destacar a necessidade de um equilíbrio entre tecnologia e intencionalidade pedagógica. A IA deve ser entendida como uma aliada, e não como substituta da ação docente. A avaliação por competências mediada por IA só será significativa se estiver alinhada a objetivos de aprendizagem claros, a uma abordagem humanizada e ao respeito à diversidade dos estudantes.

3. TRABALHOS RELACIONADOS

A avaliação por competências mediada por tecnologias digitais tem sido objeto de diversas pesquisas nas últimas décadas, especialmente diante da necessidade de personalização do ensino e da transformação dos processos avaliativos. Neste contexto, a utilização de Inteligência Artificial (IA) para apoio à avaliação formativa, preditiva e personalizada tem ganhado destaque tanto em ambientes educacionais presenciais quanto virtuais.

Um dos marcos importantes nesta área é o trabalho de Luckin et al. (2016), que apresenta argumentos sólidos para o uso de IA na educação, enfatizando seu potencial para apoiar a aprendizagem personalizada e promover a metacognição. Os autores propõem um modelo de ensino baseado na coleta e análise contínua de dados, que permite aos sistemas adaptarem-se ao progresso individual do aluno.

Holmes et al. (2019), por sua vez, discutem as promessas e implicações da IA na educação, destacando que a maioria das aplicações ainda está centrada na análise de desempenho e na automação de tarefas. Eles alertam para a escassez de estudos que explorem abordagens avaliativas realmente centradas nas competências e nas necessidades formativas dos alunos.

Em termos de aplicação prática, Khosravi et al., (2022) apresentaram uma revisão abrangente sobre IA explicável na educação. O estudo destaca o desafio de interpretar corretamente os diagnósticos gerados por algoritmos, reforçando a importância da transparência e da explicabilidade nas aplicações educacionais — especialmente quando envolvem avaliação e feedback.

Outra abordagem relevante é a dos sistemas de tutoria inteligente (ITS), desenvolvidos desde os anos 1990 e aprimorados com IA nos últimos anos. Esses sistemas utilizam algoritmos de *machine learning* para simular o comportamento de um tutor humano, adaptando-se em tempo real ao desempenho do aluno. No entanto, ainda são mais eficazes em conteúdos estruturados, como matemática e programação, apresentando limitações para áreas que exigem avaliação qualitativa ou competências socioemocionais (VanLehn, 2011).

Embora essas pesquisas representem avanços importantes, observa-se que poucos estudos aplicam a IA diretamente à avaliação por competências em cursos técnicos ou profissionalizantes, com foco na geração automatizada de relatórios qualitativos e no uso de escalas como a de Likert para coleta de dados subjetivos. A maior parte das iniciativas ainda se concentra em testes objetivos e plataformas de monitoramento do engajamento, não

contemplando de forma aprofundada a avaliação de competências cognitivas, técnicas e socioemocionais em contextos reais de aprendizagem.

Nesse sentido, o presente trabalho propõe uma abordagem inovadora ao integrar:

- A avaliação por competências com base em escalas estruturadas (como a de Likert);
- A análise automatizada de dados utilizando IA e redes neurais;
- E a formação de dashboards personalizados para estudantes e docentes, alinhando-se à prática pedagógica adotada pelo SENAC São Paulo.

Essa proposta busca preencher uma lacuna ainda pouco explorada na literatura, com foco em cursos técnicos e ambientes educacionais híbridos, promovendo uma avaliação mais rica, ética e formativa.

A seguir o quadro 1 – Trabalhos relacionados, comparativa que demonstra os trabalhos relacionados, incluindo o foco principal se fez o uso da escala de Likert, assim como se teve uma abordagem por competências.

Trabalho/Estudo	Foco Principal	Uso da Escala de Likert	Geração Automatizada de Relatórios	Foco em Educação Profissional	Abordagem por Competências
Luckin et al. (2016)	Personalização da aprendizagem com IA	Não	Não	Não	Parcial
Holmes et al. (2019)	Panorama de aplicações de IA na educação	Não	Parcial	Parcial	Parcial
Khosravi et al. (2022)	IA explicável na avaliação educacional	Não	Sim (explicabilidade dos modelos)	Não	Parcial
VanLehn (2011)	Efetividade de sistemas tutoriais inteligentes	Não	Não	Não	Não
Este Trabalho	Avaliação por competências com IA e Likert	Sim	Sim	Sim	Sim

Quadro 1 - Trabalhos relacionados
Fonte: Desenvolvido pela autora

4. LIKERTIA: AVALIAÇÃO PERSONALIZADA POR COMPETÊNCIAS COM INTELIGÊNCIA ARTIFICIAL

4.1. JUSTIFICATIVA

A proposta LikertIA surge a partir da identificação de lacunas evidenciadas na seção de Trabalhos Relacionados, onde foi constatada a ausência de soluções que integrem efetivamente a avaliação por competências com uso de escalas de Likert, Inteligência Artificial (IA) e geração automatizada de relatórios formativos, especialmente no contexto de educação técnica e profissionalizante.

Enquanto os estudos de autores como Luckin et al. (2016), Holmes et al. (2019) e Khosravi et al. (2022) tratam da personalização da aprendizagem, da IA explicável e de sistemas de tutoria inteligente, poucos avançam na direção da análise formativa estruturada com base em dados subjetivos e feedback pedagógico contínuo baseado em evidências. Além disso, os estudos analisados carecem de aplicações práticas em ambientes educacionais reais ou simulados voltados à avaliação de competências cognitivas, técnicas e socioemocionais.

Portanto, a proposta da LikertIA responde diretamente a essas lacunas ao oferecer uma solução integrada e pedagógica que emprega IA para interpretar dados coletados por escalas estruturadas de Likert, gerando relatórios individualizados, dashboards interativos e insights preditivos que fortalecem o protagonismo discente e a atuação docente baseada em dados.

4.2. OBJETIVO GERAL

Desenvolver um sistema automatizado de avaliação por competências que utilize Inteligência Artificial para gerar relatórios personalizados com base em escalas de Likert, aplicadas a diferentes UCs de um curso técnico, promovendo uma análise formativa contínua do desempenho dos alunos.

4.3. OBJETIVOS ESPECÍFICOS

- Estruturar instrumentos avaliativos com base na escala de Likert para cada UC;
- Coletar, tratar e analisar os dados por meio de técnicas de *machine learning* e redes neurais artificiais;

- Desenvolver modelos preditivos e descritivos para mapear o progresso dos estudantes;
- Gerar dashboards visuais e relatórios individualizados para docentes e alunos;
- Validar o sistema em ambiente simulado de ensino técnico.

4.4. METODOLOGIA

A metodologia adotada para o desenvolvimento da LikertIA está estruturada em cinco etapas principais:

1. Instrumentação Avaliativa

Elaboração de instrumentos avaliativos com base na escala de Likert, alinhados às competências previstas em cada Unidade Curricular (UC) do curso técnico. As perguntas são formuladas para captar dimensões cognitivas, técnicas e socioemocionais do desempenho dos alunos.

2. Coleta e Armazenamento dos Dados

Aplicação dos instrumentos em ambiente simulado ou real de ensino, com armazenamento dos dados em banco relacional seguro, utilizando técnicas de anonimização, criptografia e controle de acesso, em conformidade com a LGPD.

3. Processamento e Análise com IA

Implementação de modelos de redes neurais (como MLP) utilizando ferramentas como TensorFlow e Scikit-learn. O sistema realiza análises preditivas e descritivas com base nas respostas dos alunos, identificando padrões, riscos e trajetórias de aprendizagem.

4. Geração de Relatórios e Dashboards

Utilização de bibliotecas de visualização (Seaborn, Matplotlib e Streamlit) para a criação de painéis interativos que exibem os resultados por UC, por aluno e por turma. Os relatórios incluem gráficos, indicadores e sugestões pedagógicas personalizadas.

5. Feedback Formativo e Replanejamento

Os resultados são disponibilizados para docentes e discentes em formato acessível, orientando ações pedagógicas e intervenções formativas. O ciclo é retroalimentado com a aplicação recorrente dos instrumentos.

Essa metodologia foi testada com dados simulados que representaram diferentes perfis de alunos (alto, médio e baixo desempenho), permitindo validar a aplicabilidade do modelo antes da implementação em campo.

4.5. DIFERENCIAIS INOVADORES

- IA Explicável (XAI): Garantia de rastreabilidade e transparência nos diagnósticos e recomendações;
- Foco Formativo: Avaliação contínua que retroalimenta o processo de ensino-aprendizagem;
- Alinhamento com o Modelo SENAC: Integração às marcas formativas (domínio técnico, visão crítica, atitude sustentável, autonomia digital, colaboração e comunicação);
- Automação Inteligente: Relatórios gerados automaticamente, eliminando tarefas manuais e otimizando o tempo do professor;
- Acessibilidade Analítica: Painéis interativos e de fácil leitura para acompanhamento em tempo real.

A proposta LikertIA: Avaliação Personalizada por Competências com Inteligência Artificial consiste no desenvolvimento de um sistema inteligente e automatizado que realiza a avaliação formativa de alunos com base na escala de Likert e modelos de IA.

O sistema permite que professores apliquem questionários baseados em competências por UC. As respostas são processadas por algoritmos de IA, especialmente redes neurais, que interpretam padrões de aprendizagem e geram relatórios personalizados, dashboards visuais e sugestões de intervenção pedagógica. A proposta atende aos princípios da avaliação formativa e contínua, promovendo personalização, equidade, explicabilidade e eficiência no processo avaliativo.

A seguir diagrama visual da proposta:




Figura 1 - Diagrama da proposta
Fonte: Desenvolvido pela autora

4.6. IMPLEMENTAÇÃO DO PROTÓTIPO

Para validar a proposta LikertIA, foi desenvolvido um protótipo funcional que integra a coleta de dados por meio da escala de Likert, o processamento via técnicas de Inteligência Artificial (IA) e a geração de relatórios individuais e comparativos. Essa implementação buscou reproduzir um ambiente próximo da realidade educacional, de modo a avaliar a aplicabilidade da solução proposta no contexto de cursos técnicos e profissionalizantes, alinhando-se às orientações de avaliação formativa e personalizada (Nicol e Macfarlane-Dick, 2006; Senac São Paulo, 2024).

O ambiente computacional foi composto por um servidor PHP 5.6 integrado a banco de dados MySQL, responsável pela coleta e armazenamento das respostas dos estudantes. A interface web, construída em páginas dinâmicas, disponibilizou questionários estruturados na escala de Likert (Likert, 1932; Jamieson, 2004), conforme exemplificado nos anexos deste trabalho. Cada estudante acessou a plataforma, realizou a autoavaliação com base em competências cognitivas, técnicas e socioemocionais (Zabala e Arnau, 2010), e os dados foram registrados no banco de forma anonimizada e segura, em conformidade com a Lei Geral de Proteção de Dados (LGPD) (Brasil, 2018).

O protótipo foi estruturado em três módulos principais:

- Módulo de Coleta – responsável pela aplicação dos questionários e registro das respostas dos estudantes, seguindo práticas recomendadas na literatura de avaliação por competências (Perrenoud, 1999).
- Módulo de Processamento – integrado ao script em PHP, utilizando bibliotecas integradas as diversas IAs como o ChatGPT (Holmes et al., 2019) e o Gemini (Google AI, 2023). O sistema implementa uma rede neural do tipo Multilayer Perceptron (MLP), capaz de identificar padrões de desempenho estudantil a partir dos dados coletados (Rahman, 2022).
- Módulo de Relatórios – responsável pela geração de dashboards visuais e relatórios personalizados em PDF. Para enriquecer os feedbacks textuais, foram integrados modelos de Processamento de Linguagem Natural (PLN), como o ChatGPT (Holmes et al., 2019) e o Gemini (Google AI, 2023), que produzem análises individuais e comparativas adaptadas ao perfil de cada estudante.

Nos testes práticos com dados simulados, o sistema demonstrou capacidade de:

- Gerar relatórios individuais, destacando pontos fortes e aspectos a desenvolver em cada competência;

- Produzir relatórios comparativos de turma, permitindo ao docente identificar padrões coletivos e lacunas recorrentes;
- Regenerar relatórios via IA proporcionando versões alternativas de feedback textual, reforçando a explicabilidade do sistema (Khosravi et al., 2022).

As telas do sistema (apresentadas nos anexos gráficos) evidenciam a usabilidade do protótipo e a integração entre coleta de dados, análise estatística e relatórios pedagógicos. Além disso, a funcionalidade de exportação em PDF garante portabilidade e documentação, aspecto relevante em contextos institucionais (Shute e Rahimi, 2020).

A prática evidenciou que é possível unir avaliação por competências, escala de Likert e IA explicável (XAI) em um fluxo pedagógico coerente, que favorece a personalização e a tomada de decisão docente. Esse resultado corrobora estudos prévios que destacam o potencial da IA para a aprendizagem personalizada (Luckin et al., 2016) e para a análise de dados educacionais em larga escala (Siemens e Long, 2011). Ao mesmo tempo, reforça a importância de manter a mediação docente como elemento central do processo, garantindo equilíbrio entre tecnologia e intencionalidade pedagógica (The Royal Society, 2020).

4.7. FLUXO DE USO DO PROTÓTIPO

O protótipo desenvolvido foi estruturado em um fluxo lógico de cinco etapas principais, integrando a coleta de dados, o processamento por Inteligência Artificial e a disponibilização de relatórios e *dashboards* pedagógicos. O objetivo desse fluxo é operacionalizar a proposta LikertIA em um ambiente educacional simulado, garantindo a aplicabilidade prática do modelo teórico previamente apresentado (Perrenoud, 1999; Zabala e Arnau, 2010; Nicol e Macfarlane-Dick, 2006).

Ele mostra de forma sequencial as etapas:

- Primeira etapa: Estudante responde questionário Likert;
- Segunda etapa: Respostas gravadas no banco MySQL;
- Terceira etapa: Processamento em PHP;
- Quarta etapa: Relatórios gerados (individuais e comparativos);
- Quinta etapa: Professor acessa dashboards e feedbacks.

A seguir são descritos com maior propriedade cada etapa:

- a) Resposta ao questionário pelos estudantes

Cada estudante acessa a plataforma web e responde a questionários baseados na escala de Likert (Likert, 1932; Jamieson, 2004), previamente estruturados conforme as competências de cada Unidade Curricular (UC). As perguntas contemplam dimensões cognitivas, técnicas e socioemocionais, alinhadas às diretrizes de avaliação por competências (Zabala e Arnau, 2010). A figura 3 – Entrada no sistema por novo usuário, demonstra o ambiente que o estudante encontra para realizar sua entrada no sistema. é a página inicial do sistema, onde o usuário poderá ter o acesso ao sistema de Avaliação por competência. Caso o usuário não seja cadastrado, deverá clicar no link que fica abaixo “Faça login aqui.”

A imagem mostra a interface de login de um sistema web. No topo, há uma barra azul com um ícone de capacete e o título "Sistema de Avaliação por Competências". Abaixo do título, há uma descrição: "Descubra seu perfil tecnológico com análise de Inteligência Artificial" e "Curso Técnico em Informática para Internet". O formulário de login contém dois campos de entrada: "Nome Completo" com o placeholder "Digite seu nome completo" e "E-mail" com o placeholder "Digite seu e-mail". Abaixo dos campos, há um botão cinza com o texto "Começar Avaliação". Na seção "Como funciona:", há uma lista de quatro passos com ícones de seta verde: 1. Responda questionários sobre suas competências; 2. Receba análise personalizada com IA; 3. Compare relatórios do ChatGPT e Gemini; 4. Baixe seu perfil tecnológico em PDF. No rodapé, há o texto "Já tem conta?" seguido de um link azul "Faça login aqui".

Figura 2 - Entrada no sistema por novo usuário
Fonte: Desenvolvido pela autora

A seguir, são apresentadas as figuras de 4 a 9, as quais demonstram a utilização do sistema pelo aluno, após seu cadastro.




Figura 3 - Login no sistema
Fonte: Desenvolvido pela autora

A figura 4 – Login no sistema, o usuário já deve ter cadastro no sistema com o nome e o e-mail. No campo “E-mail Cadastrado” deverá colocar o e-mail cadastrado para acessar a página. Nela também será possível encontrar uma descrição de como funciona o sistema em cinco etapas. Caso o usuário não for cadastrado, poderá clicar no link abaixo “cadastre-se aqui”. A figura 5 – Dashboard, demonstra em tempo real, o número de alunos cadastrados, o total de respostas coletadas, as unidades curriculares registradas e a quantidade geral de perguntas disponíveis. Na sequência, são apresentadas as áreas de competências analisadas pelo sistema - *mobile, frontend e backend*.




Figura 4 - Dashboard
Fonte: Desenvolvido pela autora

A Figura 6 apresenta a página de progresso, a qual exige que o usuário esteja devidamente conectado ao sistema. Nessa interface, são exibidos o progresso geral (variando de 0% a 100%), a quantidade de respostas fornecidas, o total de perguntas existentes e o número de unidades curriculares disponíveis. Logo abaixo, são disponibilizados os cards referentes a

cada unidade curricular, contendo a descrição, o número de questões já respondidas e a respectiva porcentagem de conclusão, além de indicar quais unidades já foram iniciadas e quais permanecem sem progresso.




Figura 5 - Página de progresso
Fonte: Desenvolvido pela autora

A figura 7 – Demonstração da geração de relatório, é a parte inferior da página de progresso. O usuário poderá gerar um perfil, após responder as perguntas acima de 90%.




Figura 6 - Demonstração da geração de relatório
Fonte: Desenvolvido pela autora

As figuras 8 – Processo de avaliação início e figura 9 – Processo de avaliação final, demonstram as perguntas, uma vez escolhido a UC, ao final o aluno poderá salvar as respostas ou voltar para os cards anteriores.

UC5: Projeto Integrador Desenvolvedor Front-End
Competências relacionadas ao projeto integrador de front-end

Progresso da Avaliação 0 de 10

Pergunta 1: Consigo articular as competências adquiridas nas UCs anteriores para desenvolver um projeto integrador de front-end.

1 2 3 4 5
Discreto Totalmente Discreto Neutro Concordo Concordo Totalmente

Pergunta 2: Sou capaz de criar estratégias eficazes para solucionar problemas relacionados ao desenvolvimento front-end.

1 2 3 4 5
Discreto Totalmente Discreto Neutro Concordo Concordo Totalmente

Figura 7 - Processo de avaliação início
Fonte: Desenvolvido pela autora

Pergunta 10: Sou capaz de estruturar e executar um plano de trabalho eficiente para o desenvolvimento do projeto integrador.

1 2 3 4 5
Discreto Totalmente Discreto Neutro Concordo Concordo Totalmente

Instruções: Avalie cada afirmação de acordo com seu nível de concordância, onde 1 significa "Discreto Totalmente" e 5 significa "Concordo Totalmente".

[← Voltar para UCs](#) [Salvar Respostas](#)

Figura 8 - Processo de avaliação final
Fonte: Desenvolvido pela autora

b) Registro e armazenamento dos dados

As respostas fornecidas são automaticamente gravadas em um banco de dados MySQL, com mecanismos de anonimização e controle de acesso em conformidade com a Lei Geral de Proteção de Dados (LGPD) (Brasil, 2018). Essa etapa garante a rastreabilidade e a consistência dos dados, fundamentais para análises posteriores (Khosravi et al., 2022).

c) Processamento com Inteligência Artificial

Os dados armazenados são processados por scripts desenvolvidos em PHP. O modelo de rede neural do tipo *Multilayer Perceptron* (MLP) é responsável por classificar os estudantes em níveis de desempenho (baixo, médio ou alto), a partir dos padrões identificados nas respostas (Rahman, 2022). Essa etapa representa a camada de análise automatizada do sistema, alinhada às propostas de personalização da aprendizagem com IA (Luckin et al., 2016). Optou-

se pelo modelo MLP por sua capacidade de capturar padrões não lineares complexos nos dados de respostas Likert. No entanto, reconhece-se que algoritmos mais simples, como árvore de decisão, podem oferecer interpretabilidade superior e menor custo computacional – o que será explorado em estudos futuros.

d) Geração de relatórios individuais e comparativos

Após o processamento, o sistema disponibiliza relatórios formativos em dois formatos:

- Relatórios individuais, nos quais são destacados pontos fortes e aspectos a melhorar do estudante, com feedback textual produzido por modelos de Processamento de Linguagem Natural (ChatGPT e Gemini) (Holmes et al., 2019).
- Relatórios comparativos, que apresentam a consolidação do desempenho da turma, permitindo identificar padrões coletivos e lacunas recorrentes.

Esses relatórios podem ser exportados em PDF, garantindo portabilidade e documentação pedagógica (Shute e Rahimi, 2020).




Figura 2 - Filtro de alunos
Fonte: Desenvolvido pela autora

A figura 10 - Filtro de alunos, demonstra quando o usuário atingiu o progresso maior que 90%, pode gerar um relatório individual ou comparativo. O administrador pode gerar o relatório em qualquer percentual que o aluno estiver, para isso usará a página administrativa conforme figura 11.

Nome	E-mail	Último Relatório	% Conclusão	Ações
Luana	luana@gmail.com	Nenhum	57%	Ver Relatório

Figura 10 - Página administrativa para geração do relatório
Fonte: Desenvolvido pela autora

e) Disponibilização para professores em dashboards interativos

Por fim, os docentes têm acesso a dashboards que apresentam visualizações gráficas do desempenho individual e coletivo, desenvolvidos com bibliotecas de visualização como Matplotlib, Seaborn e Streamlit. Esses painéis permitem análises em tempo real, oferecendo ao professor uma visão ampliada do progresso dos estudantes, de forma a subsidiar intervenções pedagógicas mais eficazes (Siemens e Long, 2011).

O fluxo proposto evidencia a integração entre avaliação por competências, escalas psicométricas e Inteligência Artificial explicável (XAI), confirmando sua aplicabilidade prática em contextos educacionais técnicos. Essa integração corrobora a literatura recente, que aponta a necessidade de sistemas de avaliação mais formativos, éticos e personalizados (Khosravi et al., 2022; The Royal Society, 2020).

A Figura 12 - Relatório de Perfil Tecnológico ChatGPT apresenta o dashboard responsável por gerar automaticamente o perfil do usuário. Esse relatório pode ser acessado tanto pelo próprio estudante - desde que tenha respondido a pelo menos 90% das questões da unidade curricular selecionada - quanto pelo administrador, que também dispõe da possibilidade de emissão utilizando duas IAs generalistas.

A Figura 13 - Gráfico de Competências ChatGPT ilustra a forma como as competências foram distribuídas na análise, sendo, neste caso, a IA generativa utilizada o ChatGPT.

Por fim, a Figura 14 - Relatório Detalhado ChatGPT apresenta o detalhamento das informações obtidas, destacando que a geração dos dados também foi realizada por meio do ChatGPT.




Figura 11 - Relatório de perfil tecnológico ChatGPT
Fonte: Desenvolvido pela autora



Figura 12 - Gráfico de competências ChatGPT
Fonte: Desenvolvido pela autora



Figura 13 - Relatório detalhado ChatGPT
Fonte: Desenvolvido pela autora

A Figura 15 - Relatório de Perfil Tecnológico Gemini apresenta o dashboard responsável por gerar automaticamente o perfil do usuário. Esse relatório pode ser acessado tanto pelo estudante - desde que tenha respondido a pelo menos 90% das questões da unidade curricular selecionada - quanto pelo administrador, que também pode emitir o relatório por meio da IA generativa Gemini.

A Figura 16 - Gráfico de Competências Gemini ilustra a distribuição das competências identificadas na análise, elaborada a partir do processamento realizado pela IA generativa Gemini.

Por sua vez, a Figura 17 - Relatório Detalhado Gemini disponibiliza o detalhamento das informações obtidas, evidenciando que os dados apresentados foram gerados pela IA generativa Gemini.



Figura 14 - Relatório de perfil tecnológico Gemini
Fonte: Desenvolvido pela autora




Figura 15 - Gráfico de competências Gemini
Fonte: Desenvolvido pela autora



Figura 16 - Relatório detalhado Gemini
Fonte: Desenvolvido pela autora

A figura 18 – Relatório comparativo de perfil, pode ser utilizado para baixar em formato pdf ou html. A figura 19 – Ampliação do gráfico, tem o foco ampliado apenas nos gráficos para melhor entendimento. A figura 20 – Análise comparativa e a figura 21 - Scroll da tela de análise comparativa, fazem a geração do relatório com a comparação entre as duas IAs generativas.

Os gráficos de barras e radar foram escolhidos por facilitarem a visualização das competências avaliadas de forma comparativa e multidimensional, permitindo identificar padrões de desempenho de maneira intuitiva.




Figura 3 - Relatório comparativo de perfil
Fonte: Desenvolvido pela autora




Figura 18 - Ampliação do gráfico
Fonte: Desenvolvido pela autora




Figura 19 - Análise comparativa
Fonte: Desenvolvido pela autora




Figura 20 - Scroll da tela de análise comparativa
Fonte: Desenvolvido pela autora

5. RESULTADOS E DISCUSSÃO

5.1. DATASETS

Para a validação do protótipo LikertIA, foi elaborado um conjunto de dados simulados, composto pelas respostas de 81 estudantes cadastrados em 16 Unidades Curriculares (UCs) do curso Técnico em Informática para Internet. Cada UC contou com 10 afirmativas avaliadas em escala de Likert (1 a 5), totalizando 160 itens avaliativos. Os dados utilizados foram simulados e não resultam de avaliações reais de alunos, em razão da etapa de testes iniciais. Aplicações futuras em turmas reais para coleta empírica.

No total, foram processadas 2.196 respostas, com a geração de três perfis de comportamento:

- Perfil A (alto desempenho): estudantes com alta taxa de concordância, apresentando engajamento elevado e domínio técnico.
- Perfil B (médio desempenho): estudantes com respostas medianas, revelando competências em desenvolvimento.
- Perfil C (baixo desempenho): estudantes com baixa taxa de concordância, evidenciando riscos de evasão e dificuldades de aprendizagem.

Essa diversidade permitiu a aplicação prática do modelo de Inteligência Artificial, bem como a validação da escalabilidade da proposta.

As respostas simuladas foram geradas com distribuição normal centrada em valores médios ($\mu=3$) e desvio padrão ajustado para cada perfil ($\pm 1,2$), incorporando ruídos aleatório para refletir variações humanas e evitar padrões artificiais.

5.2. CONFIGURAÇÃO EXPERIMENTAL

O sistema foi implementado a partir da integração com interfaces de programação de aplicações (APIs), utilizando os modelos de linguagem ChatGPT (OpenAI) e Gemini (Google) como núcleo de processamento. Esses modelos generativos, baseados em redes neurais de larga escala, foram empregados para a análise semântica das respostas dos estudantes e para a geração de relatórios pedagógicos personalizados.

O fluxo de utilização compreendeu o envio de dados anonimizados às APIs, em conformidade com princípios de segurança e privacidade, garantindo a proteção das informações sensíveis. O pré-processamento incluiu a anonimização dos registros e a

organização dos dados em formato estruturado (JSON), adequado para a comunicação com os serviços externos.

A visualização dos resultados ocorreu por meio de dashboards interativos, construídos em ambiente web, possibilitando tanto a análise individual quanto a comparação coletiva de desempenho. As métricas adotadas foram a coerência das respostas, a consistência semântica e a qualidade do feedback gerado, assegurando confiabilidade no processo avaliativo.

O sistema demonstrou desempenho satisfatório na diferenciação de perfis estudantis e na produção de relatórios customizados, apresentando-se como uma solução inovadora para a simulação de cenários educacionais mediados por inteligência artificial.

5.3. RESULTADOS E DISCUSSÃO

A implementação prática do protótipo demonstrou a capacidade do sistema em gerar diferentes tipos de relatórios e visualizações:

Relatórios individuais: apontaram pontos fortes e aspectos a serem desenvolvidos por cada estudante, com *feedback* textual adaptado ao perfil (gerado por ChatGPT ou Gemini).

- Relatórios comparativos de turma: apresentaram o desempenho coletivo, permitindo a identificação de lacunas recorrentes e padrões de engajamento.
- *Dashboards* interativos: possibilitaram aos docentes acompanharem em tempo real o progresso geral (0% a 100%), quantidade de respostas, número de UCs iniciadas e percentual de conclusão.

Essa estrutura reforça a aplicabilidade pedagógica do protótipo, oferecendo informações práticas e acionáveis para professores e alunos.

Os relatórios textuais foram gerados por duas IAs generativas distintas - ChatGPT e Gemini - permitindo uma análise comparativa:

- ChatGPT: apresentou maior detalhamento descritivo, com foco em aspectos qualitativos do desempenho.
- Gemini: priorizou análises sintéticas e objetivas, destacando recomendações práticas e indicadores quantitativos.

A Figura 20 (Análise comparativa) evidencia que a combinação dos dois modelos amplia a riqueza dos *feedbacks* pedagógicos. Enquanto o ChatGPT contribuiu com explicações mais narrativas, o Gemini favoreceu diagnósticos concisos e pragmáticos. Essa complementaridade reforça o potencial do uso de múltiplas IAs em ambientes educacionais.

Os resultados obtidos demonstram que a integração entre avaliação por competências, escala de Likert e IA generativa é viável e eficaz para ambientes educacionais técnicos.

Em relação ao Objetivo Geral, o sistema conseguiu gerar relatórios individualizados e dashboards em tempo real, atendendo à proposta de avaliação personalizada.

Quanto aos Objetivos Específicos:

- Os instrumentos avaliativos foram estruturados com base na escala de Likert e aplicados de forma simulada.
- Os dados foram processados por redes neurais, confirmando a viabilidade de análises preditivas.
- Os dashboards e relatórios atenderam às necessidades de docentes e discentes, fortalecendo o protagonismo estudantil.
- O sistema foi validado em ambiente simulado, com resultados satisfatórios de acurácia.

Em termos pedagógicos, o LikertIA favorece:

- Feedback formativo contínuo, como defendido por Nicol e Macfarlane-Dick (2006).
- Personalização da aprendizagem, em consonância com Luckin et al. (2016).
- Tomada de decisão docente baseada em dados, conforme Siemens e Long (2011).

Entretanto, algumas limitações devem ser destacadas:

- O uso de dados simulados restringe a validade externa dos resultados. É necessário aplicar o sistema em turmas reais para confirmar sua eficácia.
- O modelo MLP mostrou-se eficaz, mas exige maior capacidade computacional do que algoritmos mais simples, o que pode impactar a escalabilidade em ambientes com infraestrutura limitada.
- A interpretação de competências socioemocionais ainda apresenta desafios, reforçando a importância da mediação docente.

Assim, os resultados confirmam que a proposta LikertIA constitui uma solução inovadora para avaliação formativa em cursos técnicos, mas sua plena validação depende de estudos futuros com aplicação em campo.

6. CONCLUSÕES

Este trabalho teve como objetivo desenvolver e validar o LikertIA, um protótipo de sistema de avaliação por competências apoiado em Inteligência Artificial (IA) e fundamentado na escala de Likert. Partiu-se da constatação de que os modelos tradicionais de avaliação não capturam plenamente as nuances do desenvolvimento discente, sobretudo em cursos técnicos e profissionalizantes, nos quais a mobilização de competências cognitivas, técnicas e socioemocionais é essencial.

Os resultados apresentados confirmaram a viabilidade da proposta. O sistema desenvolvido foi capaz de coletar dados de forma estruturada, processá-los por meio de redes neurais e gerar relatórios individualizados e dashboards interativos. As análises possibilitaram a identificação de padrões de desempenho, lacunas de aprendizagem e potenciais riscos de evasão, além de oferecer feedback formativo contínuo a estudantes e docentes. Assim, o objetivo geral de promover uma avaliação personalizada e automatizada foi atingido.

Quanto aos objetivos específicos, verificou-se que:

- Os instrumentos avaliativos baseados na escala de Likert foram estruturados e aplicados de maneira consistente;
- Os dados foram processados com acurácia satisfatória por meio de um modelo de rede neural multicamadas (MLP);
- Os relatórios individuais e comparativos, complementados por análises das IAs generativas ChatGPT e Gemini, evidenciaram diferentes possibilidades de feedback pedagógico;
- O sistema foi validado em ambiente simulado, demonstrando sua aplicabilidade prática e o potencial de escalabilidade.

Do ponto de vista científico e pedagógico, a principal contribuição do LikertIA é demonstrar que é possível unir avaliação por competências, escalas psicométricas e Inteligência Artificial explicável em um mesmo fluxo pedagógico. Essa integração reforça o protagonismo do estudante, a personalização da aprendizagem e a tomada de decisão docente baseada em dados, em consonância com autores como Perrenoud (1999), Nicol e Macfarlane-Dick (2006) e Luckin et al. (2016).

Contudo, o estudo apresenta limitações que precisam ser consideradas. A utilização de dados simulados restringe a validade externa dos resultados, tornando necessária a aplicação em outras turmas para verificar o desempenho do sistema em contextos educacionais autênticos. Destaco também o risco de falso negativo (bons alunos classificados como de baixo

desempenho), que podem afetar o feedback e a motivação. Além disso, há a possibilidade de respostas estratégicas na autoavaliação Likert, o que exige a mediação docente e triangulação dos dados. Tais riscos reforçam a importância de combinar IA com observações pedagógicas qualitativas. A análise de competências socioemocionais ainda apresenta desafios, pois envolve dimensões qualitativas que demandam a mediação docente. Há também questões técnicas relacionadas ao custo computacional de modelos mais complexos e à necessidade de infraestrutura tecnológica adequada.

Como trabalhos futuros, propõe-se:

- Aplicar o LikertIA em cursos técnicos reais, com coleta de dados em larga escala;
- Comparar o desempenho do modelo MLP com algoritmos mais leves, como regressão logística ou árvores de decisão, visando eficiência em ambientes com recursos limitados;
- Expandir o sistema para contemplar indicadores de engajamento e métricas socioemocionais complementares;
- Investigar a integração com outras IAs generativas e sistemas de tutoria inteligente;
- Avançar em estudos sobre explicabilidade, ética e mitigação de vieses algorítmicos, em conformidade com a LGPD e as recomendações de organismos internacionais.

Em síntese, o presente trabalho contribui para o campo da educação mediada por tecnologia ao propor uma solução inovadora que combina avaliação por competências, escalas psicométricas e Inteligência Artificial generativa. Ao mesmo tempo em que abre caminhos para a personalização da aprendizagem, ressalta a importância de manter a centralidade do docente como mediador pedagógico e guardião da equidade educacional.

REFERÊNCIAS

- BERMUDES, Wilton Luiz. Tipos de escalas utilizadas em pesquisas e suas aplicações. *Revista Vértices*, v. 18, n. 2, p. 1-11, 2016. Disponível em: <https://editoraessentia.iff.edu.br/index.php/vertices/article/view/1809-2667.v18n216-01>. Acesso em: 22 set. 2025.
- BERTRAM, D. Likert Scales. *Journal of Applied Social Research*, México, v. 14, n. 1, p. 34-49, jan. 2008. Disponível em: https://www.scielo.org.mx/scielo.php?pid=S1607-40412018000100038&script=sci_arttext. Acesso em: 19 jan. 2025.
- BLOOM, Benjamin S. *Taxonomia dos objetivos educacionais: A classificação dos objetivos educacionais*. 2. ed. Porto Alegre: Artes Médicas, 1972.
- BRASIL. Lei Geral de Proteção de Dados Pessoais (LGPD). Lei nº 13.709, de 14 de agosto de 2018.
- CANAL EDUCAÇÃO PARA TODOS. Oficina de Elaboração de Questões | Taxonomia de Bloom. 2020. Disponível em: <https://www.youtube.com/watch?v=fueM0lIRrDE>. Acesso em: 19 jan. 2025.
- CLASSCRAFT. *Classcraft: Gamify your classroom*. Montreal: Classcraft Studios, 2025. Disponível em: <https://www.classcraft.com/>. Acesso em: 18 out. 2025.
- DALMORO, M.; VIEIRA, K. M. Dilemas na construção de escalas tipo Likert: o número de itens e a disposição influenciam nos resultados? *Revista Gestão Organizacional*, Florianópolis, v. 6, n. 1, p. 161-174, jan./jun. 2013. Disponível em: https://edisciplinas.usp.br/pluginfile.php/2148822/mod_resource/content/1/Dalmoro_Vieira_2013_Dilemas-na-construcao-de-escal_31731.pdf. Acesso em: 19 jan. 2025.
- DICHEVA, D.; DICHEV, C.; AGRE, G.; ANGELOVA, G. Gamification in education: A systematic mapping study. *Educational Technology & Society*, v. 18, n. 3, p. 75-88, 2015.
- DREAMBOX LEARNING. *DreamBox Learning Math: Adaptive online math program*. Bellevue: DreamBox Learning, 2025. Disponível em: <https://www.dreambox.com/>. Acesso em: 18 out. 2025.
- DUOLINGO. *Duolingo: Language learning app powered by artificial intelligence*. Pittsburgh: Duolingo Inc., 2025. Disponível em: <https://www.duolingo.com/>. Acesso em: 18 out. 2025.
- ETS. *E-rater®: Automated scoring engine for writing assessments*. Princeton: Educational Testing Service, 2025. Disponível em: <https://www.ets.org/erater>. Acesso em: 18 out. 2025.

GOOGLE. AI Principles Progress Update 2023. [s.l.]: Google, 2023. Disponível em: <https://ai.google/static/documents/ai-principles-2023-progress-update.pdf>. Acesso em: 27 set. 2025.

GOOGLE. Text-to-Speech: Accessibility tools for education. Mountain View: Google LLC., 2025. Disponível em: <https://cloud.google.com/text-to-speech>. Acesso em: 18 out. 2025.

GRAMMARLY. Grammarly: AI-powered writing assistant. San Francisco: Grammarly Inc., 2025. Disponível em: <https://www.grammarly.com/>. Acesso em: 18 out. 2025.

HOLMES, W. et al. Artificial Intelligence in Education: Promises and Implications for Teaching and Learning. Paris: UNESCO, 2019.

IBM. Watson Education: Artificial Intelligence for education and learning analytics. Armonk: IBM Corporation, 2025. Disponível em: <https://www.ibm.com/watson-education>. Acesso em: 18 out. 2025.

INSTRUCTURE. Canvas LMS Analytics: Data insights and reporting tools for learning management. Salt Lake City: Instructure, 2025. Disponível em: <https://www.instructure.com/canvas>. Acesso em: 18 out. 2025.

JAMIESON, Susan. Likert scales: how to (ab) use them. Medical Education, Londres, v. 38, n. 12, p. 1217-1218, 2004. Disponível em: <https://onlinelibrary.wiley.com>. Acesso em: 19 jan. 2025.

KHOSRAVI, H. et al. Explainable Artificial Intelligence in Education: A Review. Computers and Education: Artificial Intelligence, v. 3, p. 100074, 2022.

KNEWTON. Knewton Alta: Personalized learning platform. New York: Knewton, 2025. Disponível em: <https://www.knewton.com/>. Acesso em: 18 out. 2025.

LIKERT, Rensis. A technique for the measurement of attitudes. New York: Archives of Psychology, 1932.

LUCKESI, Cipriano Carlos. Avaliação da aprendizagem escolar: estudos e propostas. 22. ed. São Paulo: Cortez, 2018.

LUCKIN, R.; HOLMES, W.; GRIFFITHS, M.; FORD, M. Intelligence Unleashed: An argument for AI in Education. Pearson Education, 2016.

MARIANO, G. S.; ALVES, L. M. Taxonomia de Bloom: revisão teórica e apresentação das atualizações. Gestão & Produção, São Carlos, v. 26, n. 3, p. 575-590, set./dez. 2019.

Disponível em:

<https://www.scielo.br/j/gp/a/bRkFgcJqbGCDp3HjQqFdqBm/?format=pdf&lang=pt>. Acesso em: 19 jan. 2025.

MCKINSEY & COMPANY. Global survey: the state of AI in 2020. New York: McKinsey & Company, 2020. Disponível em:

<https://www.mckinsey.com/~/media/McKinsey/Business%20Functions/McKinsey%20Analytics/Our%20Insights/Global%20survey%20The%20state%20of%20AI%20in%202020/Global-survey-The-state-of-AI-in-2020.pdf>. Acesso em: 27 set. 2025.

MICROSOFT. Immersive Reader: Reading and comprehension support tool. Redmond: Microsoft Corporation, 2025. Disponível em: <https://www.microsoft.com/en-us/education/products/learningtools>. Acesso em: 18 out. 2025.

MOODLE. Moodle Learning Analytics: Learning analytics and reporting in Moodle LMS. Perth: Moodle Pty Ltd., 2025. Disponível em: <https://moodle.org/analytics>. Acesso em: 18 out. 2025.

NICOL, David J.; MACFARLANE-DICK, Debra. Formative assessment and self-regulated learning: a model and seven principles of good feedback practice. *Studies In Higher Education*, [S.L.], v. 31, n. 2, p. 199-218, abr. 2006. Informa UK Limited. <http://dx.doi.org/10.1080/03075070600572090>.

PEARSON. WriteToLearn: Automated essay scoring and literacy tool. London: Pearson Education, 2025. Disponível em: <https://www.pearsonassessments.com/write-to-learn.html>. Acesso em: 18 out. 2025.

PERRENOUD, Philippe. Avaliação: da excelência à regulação das aprendizagens: entre duas lógicas. Porto Alegre: Artmed, 1999.

QUIZIZZ. Quizizz: Gamified quizzes and interactive learning platform. Santa Monica: Quizizz Inc., 2025. Disponível em: <https://quizizz.com/>. Acesso em: 18 out. 2025.

RAHMAN, Was. Inteligência artificial e aprendizado de Máquina. tradução de Lana Lim e Anna Lin. São Paulo. Ed. Senac São Paulo, 2022.

SENAC São Paulo. Orientações para a prática pedagógica: Avaliar. Disponível em: <http://www1.sp.senac.br/hotsites/materiais/docencia/Avaliar.pdf>. Acesso em: 14 dez. 2024.

SHUTE, V. J.; RAHIMI, S. Review of computer-based assessment for learning in higher education. *Computers & Education*, v. 153, 2020.

SIEMENS, G.; LONG, P. Penetrating the Fog: Analytics in Learning and Education. *EDUCAUSE Review*, v. 46, n. 5, p. 30–32, 2011.

SIEMENS, George. Inteligência artificial aplicada ao ensino e inovação educacional. Siemens Brasil, 2025. Disponível em: <https://www.siemens.com/br/pt/digitalizacao/inteligencia-artificial.html>. Acesso em: 22 set. 2025.

SQUIRREL AI. Squirrel AI Learning: Adaptive education powered by artificial intelligence. Shanghai: Squirrel AI Learning, 2025. Disponível em: <https://www.squirrelai.com/>. Acesso em: 18 out. 2025.

SURVEYMONKEY. Escalas de Likert: exemplos, dicas e como analisar os dados. SurveyMonkey, 2019. Disponível em: <https://pt.surveymonkey.com/mp/likert-scale/>. Acesso em: 22 set. 2025.

THE ROYAL SOCIETY. The Ethics of Artificial Intelligence in Education: Promoting Transparency, Accountability and Fairness. Londres, 2020.

TURNITIN. Turnitin Feedback Studio: Academic integrity and writing evaluation tool. Oakland: Turnitin LLC., 2025. Disponível em: <https://www.turnitin.com/>. Acesso em: 18 out. 2025.

VANLEHN, K. The Relative Effectiveness of Human Tutoring, Intelligent Tutoring Systems, and Other Tutoring Systems. *Educational Psychologist*, v. 46, n. 4, p. 197-221, 2011.

ZABALA, Antoni; ARNAU, Josep Maria. A prática educativa: como ensinar. 11. ed. Porto Alegre: Artmed, 2010.

GLOSSÁRIO

Agentes Inteligentes

Sistemas computacionais capazes de realizar tarefas específicas de forma autônoma, como tutoria, monitoramento e interação adaptativa com estudantes, utilizando técnicas de inteligência artificial.

Algoritmo

Conjunto de regras e instruções ordenadas e finitas que definem uma sequência de operações a serem realizadas para a resolução de um problema ou execução de uma tarefa específica.

Análise de Dados Educacionais

Processo de coleta, tratamento e interpretação de grandes volumes de informações educacionais para identificar padrões de desempenho, prever dificuldades e orientar intervenções pedagógicas.

Aprendizado de Máquina (*Machine Learning*)

Subárea da inteligência artificial em que sistemas computacionais aprendem e melhoram seu desempenho com base em dados e experiência, sem serem explicitamente programados para tarefas específicas.

Big Data

Conjunto de dados extremamente volumosos e complexos que requerem tecnologias avançadas para captura, armazenamento, análise e visualização.

Escala de Likert

Método de avaliação utilizado para medir atitudes, opiniões ou percepções por meio de uma escala que varia, geralmente, entre "concordo totalmente" e "discordo totalmente".

Feedback Formativo

Devolutiva contínua e personalizada que orienta o estudante sobre seu processo de aprendizagem, promovendo ajustes e melhorias antes da avaliação final.

Inteligência Artificial (IA)

Área da ciência da computação que se dedica à criação de sistemas capazes de realizar tarefas que normalmente requerem inteligência humana, como aprendizado, raciocínio e tomada de decisão.

Large Language Models (LLMs)

Modelos de inteligência artificial baseados em arquiteturas de deep learning que realizam processamento avançado de linguagem natural para geração e análise de textos.

Machine Learning

Tecnologia que constrói modelos computacionais para prever resultados e padrões com base em dados históricos, frequentemente utilizada em sistemas educativos para personalização da aprendizagem.

Modelo Pré-Treinado

Modelo de IA previamente treinado em grandes bases de dados que pode ser adaptado para tarefas específicas, melhorando a eficiência do processo de desenvolvimento.

Overfitting (Sobreajuste)

Problema em machine learning onde o modelo se ajusta demais aos dados de treinamento, perdendo capacidade de generalizar para novos dados.

Personalização da Aprendizagem

Adaptação dos processos educacionais às necessidades, ritmos e estilos individuais dos estudantes para otimizar o desenvolvimento de competências.

Prompt

Comando ou conjunto de instruções fornecidos a modelos de linguagem para orientar a geração de respostas, textos ou análises específicas.

Redes Neurais Artificiais (RNAs)

Sistemas computacionais inspirados na estrutura neural do cérebro humano, utilizados para processar dados complexos e aprender padrões em machine learning.

Trilha Formativa

Caminho personalizado de aprendizado estruturado com base em dados de desempenho para orientar o estudante no desenvolvimento contínuo de competências.

ANEXO A – PROMPTS PARA CRIAR AS PERGUNTAS NA IA MANUS

Prompts para criar as perguntas na IA Manus (<https://manus.im/>), foi utilizado o seguinte prompt de comando: “com base no tcc em anexo e no plano de curso de informática para internet, crie 10 perguntas por UC usando o método likert”.

Prompts para Geração de Perguntas Likert

Prompt para Geração de Perguntas por Unidade Curricular

Objetivo: Criar perguntas utilizando a escala Likert para avaliar competências específicas de cada Unidade Curricular (UC).

Com base nos conhecimentos, habilidades e atitudes descritos para a UC [NOME_DA_UC]², crie 10 perguntas utilizando a escala Likert (1-5) que avaliem o nível de competência do aluno.

As perguntas devem:

1. Ser formuladas como afirmações positivas
2. Abordar aspectos específicos dos conhecimentos, habilidades e atitudes da UC
3. Permitir autoavaliação pelo aluno
4. Ser claras e diretas
5. Evitar ambiguidades ou duplas negativas

A escala Likert a ser utilizada é:

1. Discordo totalmente
2. Discordo parcialmente
3. Neutro
4. Concordo parcialmente
5. Concordo totalmente

Exemplo de pergunta: "Consigo identificar os principais componentes de uma arquitetura web moderna."

² [NOME_DA_UC] variável contendo o nome das 16 unidades curriculares.

ANEXO B – PROMPTS PARA ANÁLISE DE COMPETÊNCIAS POR LLM

Prompt Principal para Análise de Perfil

Objetivo: Analisar as respostas Likert do aluno e gerar um perfil detalhado de competências.

Analise o seguinte perfil de competências baseado em respostas Likert (1-5):

Dados do Aluno

Nome: [NOME_DO_ALUNO]

Data da Avaliação: [DATA]

Estatísticas Gerais

- UCs Concluídas: [X] de [Y]

- Porcentagem de Conclusão: [Z]%

- Média Geral: [M]

Respostas por Unidade Curricular

[TÍTULO_DA_UC1]

Status: [STATUS], Média: [MÉDIA]

1. "[TEXTO_DA_PERGUNTA_1]": [RESPOSTA]/5 - [TEXTO_DA_RESPOSTA]

2. "[TEXTO_DA_PERGUNTA_2]": [RESPOSTA]/5 - [TEXTO_DA_RESPOSTA]

...

[TÍTULO_DA_UC2]

...

Com base nestas respostas, crie um perfil detalhado do aluno incluindo:

1. PONTOS FORTES: Identifique 3-5 competências nas quais o aluno demonstra maior domínio (respostas 4-5) e explique como estas competências se relacionam entre si.

2. **ÁREAS PARA DESENVOLVIMENTO:** Identifique 3-5 competências que precisam de mais desenvolvimento (respostas 1-3) e explique por que são importantes para o perfil profissional.

3. **RECOMENDAÇÕES PERSONALIZADAS:** Sugira 3-5 atividades ou recursos específicos para desenvolver as competências identificadas como áreas de melhoria.

4. **PERFIL DE APRENDIZAGEM:** Com base no padrão de respostas, identifique o possível estilo de aprendizagem do aluno e como ele pode aproveitar isso para seu desenvolvimento.

5. **PRÓXIMOS PASSOS:** Recomende 3 ações concretas e imediatas que o aluno pode tomar para avançar em seu desenvolvimento profissional.

Formate sua resposta em HTML simples, usando tags <h2>, <h3>, <p>, , para estruturar o conteúdo.

ANEXO C – PROMPT DE SISTEMA PARA CONTEXTUALIZAÇÃO DA LLM

Objetivo: Estabelecer o contexto e papel da LLM na análise de competências.

Você é um especialista em análise de competências educacionais que ajuda a interpretar respostas de avaliações Likert. Sua função é analisar padrões nas respostas dos alunos, identificar pontos fortes e áreas para desenvolvimento, e fornecer recomendações personalizadas baseadas em evidências. Mantenha um tom profissional, construtivo e encorajador, focando em como o aluno pode aproveitar seus pontos fortes e desenvolver as áreas que precisam de atenção.

ANEXO D – PROMPTS PARA ANÁLISE ESPECÍFICA DE COMPETÊNCIAS

Prompt para Análise de Competências Técnicas

Objetivo: Focar a análise nas competências técnicas específicas do curso.

Com base nas respostas Likert fornecidas, realize uma análise aprofundada das **COMPETÊNCIAS TÉCNICAS** do aluno no contexto do curso de Informática para Internet.

Considere especificamente as seguintes áreas técnicas:

1. Desenvolvimento Front-End (HTML, CSS, JavaScript)
2. Desenvolvimento Back-End (Lógica de programação, Banco de dados)
3. Desenvolvimento Mobile
4. Infraestrutura e Redes

Para cada área:

- Identifique o nível atual de proficiência com base nas respostas
- Destaque pontos fortes específicos e áreas para aprimoramento
- Sugira recursos de aprendizagem específicos (livros, cursos online, projetos práticos)
- Recomende um caminho de desenvolvimento progressivo

Inclua também uma análise da adequação do perfil técnico atual do aluno às demandas do mercado de trabalho em Informática para Internet, identificando possíveis gaps e oportunidades de especialização.

ANEXO E – PROMPT PARA ANÁLISE DE COMPETÊNCIAS COMPORTAMENTAIS

Objetivo: Focar a análise nas competências comportamentais (soft skills).

Com base nas respostas Likert fornecidas, realize uma análise aprofundada das **COMPETÊNCIAS COMPORTAMENTAIS** (soft skills) do aluno no contexto profissional de Informática para Internet.

Considere especificamente as seguintes competências:

1. Trabalho em equipe e colaboração
2. Comunicação e expressão
3. Resolução de problemas e pensamento crítico
4. Gestão de tempo e organização
5. Adaptabilidade e aprendizado contínuo

Para cada competência:

- Identifique o nível atual de desenvolvimento com base nas respostas
- Destaque comportamentos positivos e áreas para desenvolvimento
- Sugira exercícios práticos e atividades para fortalecer cada competência
- Explique como estas competências se aplicam especificamente ao contexto de TI

Inclua também uma análise de como o perfil comportamental do aluno pode influenciar sua trajetória profissional em TI, destacando como potencializar seus pontos fortes em entrevistas de emprego e ambiente de trabalho.

ANEXO F – PROMPTS PARA GERAÇÃO DE RELATÓRIOS ESPECÍFICOS

Prompt para Relatório de Docente

Objetivo: Gerar um relatório direcionado ao docente sobre o desempenho da turma.

Com base nos dados agregados das avaliações Likert de uma turma de [NÚMERO_DE_ALUNOS] alunos do curso de Informática para Internet, gere um relatório analítico para o docente.

Dados da Turma

- Curso: Técnico em Informática para Internet
- Período: [PERÍODO]
- Número de alunos: [NÚMERO_DE_ALUNOS]
- UCs avaliadas: [LISTA_DE_UCS]

Dados Agregados

[DADOS_ESTATÍSTICOS_AGREGADOS]

O relatório deve incluir:

1. **VISÃO GERAL:** Apresente uma análise geral do desempenho da turma, identificando tendências principais nas competências avaliadas.
2. **PONTOS FORTES COLETIVOS:** Identifique as competências em que a turma demonstra maior domínio coletivo.
3. **ÁREAS CRÍTICAS:** Identifique competências com avaliações consistentemente baixas que precisam de atenção pedagógica.
4. **DISPARIDADES:** Analise áreas com grande variação nas respostas, indicando possíveis disparidades de aprendizado na turma.

5. RECOMENDAÇÕES PEDAGÓGICAS: Sugira 5-7 estratégias didáticas específicas para abordar as áreas críticas identificadas.

6. PLANO DE AÇÃO: Proponha um plano de ação estruturado para o docente implementar no próximo período letivo.

Formate o relatório de maneira profissional e objetiva, adequado para apresentação em reunião pedagógica.

ANEXO G – PROMPTS PARA INTEGRAÇÃO COM SISTEMAS LMS

Prompt para Geração de Conteúdo para Chamilo LMS

Objetivo: Gerar conteúdo formatado para integração com o Chamilo LMS.

Com base no perfil de competências gerado a partir das respostas Likert do aluno [NOME_DO_ALUNO], crie conteúdo formatado especificamente para o Chamilo LMS versão 1.11.28.

O conteúdo deve incluir:

1. **PÁGINA PRINCIPAL:** Crie uma página de visão geral do perfil de competências, formatada em HTML compatível com o editor do Chamilo, incluindo:

- Título e cabeçalho personalizados
- Resumo do perfil de competências
- Gráfico de radar descrito em formato textual para implementação
- Links para as seções detalhadas

2. **SEÇÕES DETALHADAS:** Para cada categoria de análise (Pontos Fortes, Áreas para Desenvolvimento, etc.), crie uma página separada com:

- Conteúdo detalhado da análise
- Recursos recomendados vinculados à biblioteca do Chamilo
- Atividades práticas que podem ser implementadas como tarefas no Chamilo

3. **AValiação de Acompanhamento:** Crie um questionário de acompanhamento para o aluno avaliar seu progresso nas áreas identificadas para desenvolvimento.

4. **PLANO DE DESENVOLVIMENTO:** Estruture um plano de desenvolvimento pessoal que possa ser implementado como um "Itinerário de Aprendizagem" no Chamilo.

Todo o conteúdo deve ser formatado em HTML compatível com o Chamilo, utilizando apenas as tags suportadas pelo editor do LMS, e seguindo as melhores práticas de acessibilidade.

ANEXO H – PROMPTS PARA PERSONALIZAÇÃO DE FEEDBACK

Prompt para Feedback Personalizado por Perfil de Aprendizagem

Objetivo: Gerar feedback adaptado ao estilo de aprendizagem identificado do aluno.

Com base no perfil de competências e padrão de respostas Likert do aluno [NOME_DO_ALUNO], gere um feedback personalizado considerando seu provável estilo de aprendizagem.

Dados do Aluno

[DADOS_RESUMIDOS_DO_ALUNO]

Estilo de Aprendizagem Identificado

[ESTILO_DE_APRENDIZAGEM] (Visual, Auditivo, Cinestésico, Leitura/Escrita, ou combinação)

O feedback deve:

1. Ser apresentado em formato e linguagem que ressoe com o estilo de aprendizagem identificado
2. Destacar os pontos fortes e áreas para desenvolvimento de maneira construtiva
3. Sugerir recursos e estratégias de aprendizagem específicos para o estilo do aluno
4. Propor atividades práticas alinhadas com suas preferências de aprendizagem
5. Incluir técnicas de estudo e desenvolvimento profissional adequadas ao seu perfil

Adapte o tom, vocabulário e estrutura do feedback para maximizar a receptividade e engajamento do aluno conforme seu estilo de aprendizagem predominante.

ANEXO I – PERGUNTAS REALIZADAS COM O AUXÍLIO DA IA MANUS

Para cada afirmação, o respondente deve indicar seu nível de concordância utilizando a seguinte escala: 1. Discordo totalmente 2. Discordo parcialmente 3. Neutro 4. Concordo parcialmente 5. Concordo totalmente.

UC1: Elaborar projetos de aplicações para web

1. Consigo definir claramente os objetivos de um projeto web de acordo com as necessidades do cliente e público-alvo.
2. Sou capaz de elaborar um briefing completo e detalhado para projetos de aplicações web.
3. Utilizo técnicas de criatividade (como brainstorming e mapas mentais) de forma eficaz durante o planejamento de projetos web.
4. Consigo identificar corretamente o perfil do cliente, público-alvo e concorrentes ao realizar análise de mercado para projetos web.
5. Tenho conhecimento suficiente sobre domínios de internet, incluindo conceitos, registro e disponibilidade de serviços.
6. Sou capaz de estruturar adequadamente a arquitetura da informação de um website, incluindo mapa do site e estruturas de navegação.
7. Consigo elaborar uma proposta comercial completa, incluindo requisitos, características e modelos de contrato de serviço.
8. Aplico técnicas eficientes para análise e gerenciamento de requisitos em projetos de websites.
9. Demonstro responsabilidade e comprometimento com os acordos estabelecidos durante o desenvolvimento de projetos web.
10. Respeito os direitos de propriedade intelectual e me comprometo com padrões de usabilidade e acessibilidade web durante a elaboração de projetos.

UC2: Desenvolver aplicações para websites

1. Consigo criar imagens, layouts e animações otimizadas para websites de acordo com os princípios de comunicação visual.

2. Tenho conhecimento adequado sobre conceitos de imagem digital (vetor, bitmap, formatos e aplicações) para desenvolvimento web.
3. Aplico corretamente os princípios de comunicação visual (tipografia, teoria de cores, grid e alinhamento) em meus projetos web.
4. Sou capaz de desenvolver wireframes e protótipos funcionais para websites.
5. Utilizo linguagem de marcação de conteúdo e estilo de acordo com as normas e padrões tecnológicos atuais.
6. Implemento design responsivo de forma eficaz em meus projetos web.
7. Consigo testar e garantir a acessibilidade e usabilidade de websites de acordo com as normas estabelecidas.
8. Sou capaz de analisar e corrigir inconsistências no funcionamento de websites de acordo com os padrões W3C.
9. Tenho conhecimento sobre sistemas de gerenciamento de conteúdo (CMS), incluindo configuração, customização e publicação.
10. Aplico os princípios da Lei Geral de Proteção de Dados Pessoais no desenvolvimento de aplicações para websites

UC3: Codificar front-end de aplicações web

1. Consigo criar blocos de Back-End utilizando linguagens de programação de script de acordo com os requisitos do projeto.
2. Tenho conhecimento adequado sobre fundamentos de lógica de programação para desenvolvimento front-end.
3. Sou capaz de manipular elementos estruturais de uma página web de acordo com os requisitos do projeto.
4. Programo comportamentos dinâmicos, definindo estilos e animações, de acordo com requisitos do projeto.
5. Implemento Frameworks front-end de acordo com as necessidades específicas de cada projeto.
6. Consigo comunicar requisições de forma eficiente conforme recursos disponibilizados pelo Back-End.
7. Implemento correções e melhorias com base na depuração de código de script.
8. Aplico princípios de usabilidade e acessibilidade em páginas web de acordo com os padrões do W3C.

9. Tenho conhecimento adequado sobre Document Object Model (DOM) para manipulação de elementos, atribuição de eventos e estilos dinâmicos.
10. Utilizo requisições assíncronas de forma eficaz no desenvolvimento front-end.

UC4: Publicar aplicações web

1. Consigo definir o serviço de hospedagem mais adequado de acordo com os objetivos específicos de cada projeto web.
2. Tenho conhecimento adequado sobre tecnologias de servidor web e seus princípios de funcionamento.
3. Sou capaz de comparar e selecionar entre diferentes tipos de serviços de hospedagem (gratuitos, pagos, compartilhados e dedicados).
4. Consigo formatar e exportar arquivos do projeto local para servidor web de acordo com as tecnologias disponíveis.
5. Realizo o gerenciamento eficiente de sites, incluindo atualização de informações e backups regulares.
6. Utilizo corretamente métodos de transferência de arquivos, como hospedagem via FTP e upload no servidor.
7. Verifico a compatibilidade e performance do website de acordo com as normas e exigências do mercado.
8. Sou capaz de identificar e corrigir erros no website após sua publicação.
9. Demonstro proatividade no desenvolvimento das atividades relacionadas à publicação de aplicações web.
10. Mantenho sigilo no tratamento de dados e informações durante o processo de publicação de websites

UC5: Projeto Integrador Desenvolvedor Front-End

1. Consigo articular as competências adquiridas nas UCs anteriores para desenvolver um projeto integrador de front-end.
2. Sou capaz de criar estratégias eficazes para solucionar problemas relacionados ao desenvolvimento front-end.
3. Trabalho de maneira autônoma e responsável em atividades realizadas em grupo.
4. Demonstro domínio técnico-científico nas atividades do projeto integrador de front-end.

5. Aplico uma atitude empreendedora na proposição de soluções inovadoras para o projeto.
6. Mantenho uma visão crítica durante o desenvolvimento do projeto integrador.
7. Adoto uma atitude sustentável nas decisões e implementações do projeto.
8. Colaboro efetivamente com os membros da equipe durante todas as etapas do projeto.
9. Consigo desenvolver recursos de front-end para um sistema multiplataforma com web services.
10. Sou capaz de estruturar e executar um plano de trabalho eficiente para o desenvolvimento do projeto integrador.

UC6: Desenvolver algoritmos

1. Consigo estruturar uma sequência lógica de ações de acordo com as etapas de resolução de um problema.
2. Estruturo algoritmos com base na lógica computacional e nos requisitos funcionais descritos no projeto.
3. Seleciono e manipulo estruturas de dados conforme as funcionalidades descritas no projeto de software.
4. Sou capaz de criar sub-rotinas genéricas e reutilizáveis conforme as funcionalidades descritas no projeto.
5. Valido algoritmos com base em valores de entradas e saídas de acordo com funcionalidades descritas no projeto.
6. Seleciono a metodologia ágil mais adequada de acordo com os requisitos específicos de cada projeto.
7. Tenho conhecimento adequado sobre lógica de programação, incluindo conceitos de algoritmos e pensamento computacional.
8. Aplico corretamente os conceitos de orientação a objetos no desenvolvimento de algoritmos.
9. Utilizo diagramas UML (caso de uso e diagrama de classe) de forma eficaz no desenvolvimento de algoritmos.
10. Demonstro comportamento investigativo na automação de recursos durante o desenvolvimento de algoritmos.

UC7: Codificar back-end de aplicações web

1. Configuro adequadamente o ambiente de desenvolvimento conforme as funcionalidades e características do projeto.
2. Crio estruturas de código utilizando linguagem de programação para Back-End de acordo com os requisitos do projeto.
3. Documento as funcionalidades do projeto web conforme requisitos estabelecidos.
4. Desenvolvo tratamento de requisições POST e GET do Front-End de acordo com a linguagem de programação Back-End.
5. Implemento session e cookies da aplicação web de acordo com a linguagem de programação Back-End.
6. Integro soluções de segurança de dados ao projeto de acordo com normas e boas práticas de segurança da informação.
7. Desenvolvo recursos de chamadas assíncronas de acordo com requisitos do projeto.
8. Aplico correções e melhorias a partir da validação e depuração do código de BackEnd.
9. Utilizo conceitos de orientação a objetos na linguagem de programação Back-End de forma eficaz.
10. Aplico versionamento ao código do projeto de forma consistente e organizada.

UC8: Implementar banco de dados para web

1. Modelo a estrutura do Banco de Dados de acordo com os requisitos de uma aplicação web.
2. Preparo o ambiente de desenvolvimento conforme requisitos do Sistema de Gerenciamento de Banco de Dados (SGBD).
3. Estruturo banco de dados físicos utilizando linguagem de manipulação de dados de acordo com a necessidade do projeto.
4. Integro banco de dados à aplicação web de acordo com os requisitos do projeto.
5. Manipulo dados a partir da aplicação, utilizando linguagem de programação BackEnd e integração ao banco de dados.
6. Tenho conhecimento adequado sobre normalização de dados e integridade referencial em bancos de dados.
7. Utilizo SQL (Structured Query Language) de forma eficaz para manipulação e consulta de dados.
8. Aplico políticas de segurança no banco de dados, incluindo criptografia, autenticação e controle de acesso.
9. Implemento procedimentos de backup e restore para garantir a segurança dos dados.

10. Aplico os princípios da Lei Geral de Proteção de Dados Pessoais no desenvolvimento e manutenção de bancos de dados.

UC9: Desenvolver serviços web

1. Crio estruturas de código de serviço web utilizando linguagem de Back-End de acordo com os requisitos do projeto.
2. Realizo integração do código Back-End com serviços de terceiros conforme os requisitos do projeto.
3. Consumo serviços web utilizando linguagem de Back-End e Front-End de acordo com os requisitos do projeto.
4. Manipulo os registros de web services conforme os requisitos do projeto.
5. Tenho conhecimento adequado sobre programação orientada a serviços, incluindo objetivos, benefícios e contratos.
6. Utilizo o protocolo HTTP de forma eficaz, incluindo requisições, respostas e operações (GET, POST, PUT, DELETE).
7. Aplico o padrão REST (Representational State Transfer) no desenvolvimento de serviços web.
8. Trabalho adequadamente com diferentes representações de dados (texto plano, JSON, XML) em serviços web.
9. Implemento testes unitários para garantir a qualidade dos serviços web desenvolvidos.
10. Aplico medidas de segurança em serviços web, incluindo HTTPS, autenticação e melhores práticas

UC10: Organizar o processo de trabalho no desenvolvimento de aplicações

1. Executo procedimentos de controle e registro de ocorrência em softwares de gestão de acordo com o fluxo de trabalho.
2. Identifico a necessidade de adaptação das etapas e cronograma de trabalho de acordo com os procedimentos da organização.
3. Elaboro relatórios dos processos de trabalho conforme métricas de uma organização.
4. Tenho conhecimento adequado sobre etapas de trabalho, incluindo tipos de equipe, cultura organizacional e cronograma.
5. Aplico conceitos de empreendedorismo e intraempreendedorismo no ambiente de trabalho.

6. Realizo levantamento de fornecedores de serviços de terceiros, considerando prioridades, custos e características.
7. Forneço suporte técnico eficiente, incluindo comunicação, controle e registro de ocorrências.
8. Utilizo técnicas de negociação de conflitos e mediação no ambiente de trabalho.
9. Comunico-me de forma assertiva com colegas, superiores e clientes.
10. Demonstro cordialidade e empatia no trato com as pessoas durante o processo de Trabalho.

UC11: Projeto Integrador Desenvolvedor Back-End

1. Consigo articular as competências adquiridas nas UCs anteriores para desenvolver um projeto integrador de back-end.
2. Crio estratégias eficazes para solucionar problemas relacionados ao desenvolvimento back-end.
3. Trabalho de maneira autônoma e responsável em atividades realizadas em grupo.
4. Demonstro domínio técnico-científico nas atividades do projeto integrador de back-end.
5. Aplico uma atitude empreendedora na proposição de soluções inovadoras para o projeto.
6. Mantenho uma visão crítica durante o desenvolvimento do projeto integrador.
7. Adoto uma atitude sustentável nas decisões e implementações do projeto.
8. Colaboro efetivamente com os membros da equipe durante todas as etapas do projeto.
9. Consigo planejar e executar as etapas do projeto integrador de forma organizada e eficiente.
10. Sou capaz de apresentar e defender as soluções desenvolvidas no projeto Integrador.

UC12: Desenvolver interface gráfica para dispositivos móveis

1. Estruturo leiaute para aplicativos móveis conforme os princípios de comunicação visual, normas e tendências de mercado.
2. Implemento interface gráfica conforme leiaute e arquitetura Mobile.
3. Testo a usabilidade e acessibilidade de aplicativos, conforme requisitos do projeto e padrões da arquitetura móvel.
4. Programo interatividade em dispositivos móveis, conforme leiaute e sistemas Mobile.

5. Defino conteúdo visual e textual para dispositivos móveis de acordo com os requisitos do projeto.
6. Tenho conhecimento adequado sobre sistemas Mobile e suas características específicas.
7. Aplico conceitos de desenvolvimento híbrido de aplicativos, incluindo linguagem de marcação de conteúdo e estilo.
8. Utilizo emuladores de dispositivos móveis para testar aplicações em diferentes versões de SDK e parâmetros de hardware.
9. Aplico a arquitetura em camadas (*MVC - Model View Controller*) no desenvolvimento de interfaces para dispositivos móveis.
10. Demonstro comprometimento com padrões de usabilidade e acessibilidade no desenvolvimento de interfaces para dispositivos móveis.

UC13: Codificar aplicações para dispositivos móveis

1. Configuro ambientes de programação (IDE) para dispositivos móveis de acordo com os requisitos do projeto.
2. Crio estruturas de código conforme requisitos do projeto e a linguagem de programação para dispositivos móveis.
3. Desenvolvo interatividade entre aplicação e interface conforme elementos da tecnologia Mobile.
4. Aplico correções e melhorias a partir da validação e depuração do código do aplicativo.
5. Aplico recursos da biblioteca do sistema Mobile de acordo com necessidades do aplicativo.
6. Programo persistência local de dados utilizando arquivos e banco de dados portáteis.
7. Gero arquivos executáveis, compilando o código desenvolvido de acordo com as especificações da arquitetura móvel.
8. Utilizo frameworks e bibliotecas de terceiros para desenvolvimento de aplicações móveis.
9. Aplico conceitos de desenvolvimento *cross-platform* em aplicações móveis.
10. Implemento controles visuais e fragmentos de aplicação reutilizáveis em aplicativos móveis.

UC14: Codificar acesso à *web services* e recursos de sistemas móveis

1. Consumo serviços web por meio do aplicativo de acordo com funcionalidades da plataforma Mobile.

2. Persisto dados na nuvem usando integração do aplicativo com serviços web de acordo com funcionalidades da plataforma Mobile.
3. Realizo autenticação a partir de serviços web públicos e redes sociais de acordo com funcionalidades da plataforma Mobile.
4. Integro recursos de notificações de acordo com as necessidades do aplicativo e as características do sistema Mobile.
5. Integro recursos nativos do dispositivo de acordo com as necessidades do aplicativo e as características do sistema Mobile.
6. Aplico correções e melhorias a partir da validação e depuração do código de integração do web services.
7. Tenho conhecimento adequado sobre aplicativos RESTful e conexão Mobile-web.
8. Utilizo serviços SOAP de forma eficaz, incluindo recursos da API Mobile e consumo de serviços.
9. Aplico técnicas de segurança em Web Services, incluindo autenticação e recomendações da OWASP.
10. Implemento recursos de geolocalização e integração com serviços de mapa em aplicativos móveis.

UC15: Publicar aplicações para dispositivos móveis

1. Compilo o app no formato nativo de acordo com regras e características da loja de aplicativos e requisitos do sistema Mobile.
2. Preparo ambiente de venda de acordo com regras e características da loja de aplicativos do sistema Mobile.
3. Público o aplicativo de acordo com regras e características da loja de aplicativos do sistema Mobile.
4. Tenho conhecimento adequado sobre formatos de distribuição específicos dos principais sistemas operacionais de dispositivos móveis.
5. Compreendo as políticas de publicação, tipos de monetização e distribuição de aplicativos nas lojas virtuais.
6. Identifico corretamente o público-alvo do app, tipos de acesso e estratégias de precificação.
7. Atendo aos requisitos da loja para o app, incluindo ajustes, ícones e certificado digital.
8. Realizo a otimização do pacote compilado e confecção de tutorial de manipulação do app.

9. Configuro adequadamente a loja virtual, upload de pacote compilado e disponibilização do aplicativo ao público.
10. Monitoro o aplicativo publicado, incluindo atualização, versionamento e uso de ferramentas de *analytics*.

UC16: Projeto Integrador Desenvolvedor Mobile

1. Consigo articular as competências adquiridas nas UCs anteriores para desenvolver um projeto integrador de desenvolvimento mobile.
2. Crio estratégias eficazes para solucionar problemas relacionados ao desenvolvimento de aplicações móveis.
3. Trabalho de maneira autônoma e responsável em atividades realizadas em grupo.
4. Demonstro domínio técnico-científico nas atividades do projeto integrador de desenvolvimento mobile.
5. Aplico uma atitude empreendedora na proposição de soluções inovadoras para o projeto.
6. Mantenho uma visão crítica durante o desenvolvimento do projeto integrador.
7. Adoto uma atitude sustentável nas decisões e implementações do projeto.
8. Colaboro efetivamente com os membros da equipe durante todas as etapas do projeto.
9. Consigo planejar e executar as etapas do projeto integrador de forma organizada e eficiente.
10. Sou capaz de apresentar e defender as soluções desenvolvidas no projeto integrador mobile.