

ORIENTAÇÃO PROFISSIONAL NA ERA DIGITAL: Desenvolvimento do aplicativo Luminar com base em inteligências múltiplas e IA

Eder Junior Alves Silva
Graduando em Engenharia de Software – Uni-FACEF
ederjuninho2003@gmail.com

Jaqueline Brigladori Pugliesi
Doutora em Ciência da Computação – USP São Carlos
jbpugliesi@gmail.com

Resumo

A transição para a vida adulta e a escolha profissional representam um momento de incertezas para muitos jovens, influenciando diretamente sua trajetória de carreira e satisfação pessoal. Nesse cenário, torna-se essencial oferecer ferramentas inovadoras que auxiliem no processo de autoconhecimento e tomada de decisão. Este artigo apresenta o desenvolvimento da Luminar, um aplicativo móvel para iOS baseado na Teoria das Inteligências Múltiplas de Howard Gardner, com o objetivo de apoiar jovens na identificação de seus perfis e na exploração de carreiras compatíveis. O aplicativo incorpora um questionário interativo, um módulo de análise com Inteligência Artificial e um sistema de recomendações personalizadas. O desenvolvimento seguiu metodologias ágeis, empregando Swift com UIKit no *front-end* nativo para iOS, NestJS no *back-end* e PostgreSQL como banco de dados. A validação foi conduzida com jovens entre 18 e 25 anos, por meio de testes de usabilidade e análise da clareza dos resultados. A contribuição do projeto reside na integração entre uma teoria psicológica consolidada e os recursos tecnológicos contemporâneos, possibilitando uma experiência dinâmica, personalizada e otimizada para dispositivos móveis. Os resultados esperados incluem maior engajamento dos usuários, redução da ansiedade vocacional e suporte efetivo ao planejamento de carreira na era digital.

Palavras-chave: Autoconhecimento; inteligências múltiplas; Inteligência Artificial; orientação profissional; aplicativo móvel.

Abstract

The transition to adulthood and career choice represents a period of uncertainty for many young people, directly influencing their professional trajectory and personal satisfaction. In this context, it becomes essential to provide innovative tools that support the process of self-knowledge and decision-making. This article presents the development of Luminar, a native iOS mobile application based on Howard Gardner's Theory of Multiple Intelligences, aimed at helping young people identify their profiles and explore compatible career paths. The platform incorporates an interactive questionnaire, an Artificial Intelligence analysis module, and a personalized recommendation system. The development followed agile methodologies, employing Swift with UIKit for the native iOS front-end, NestJS for the back-end, and PostgreSQL as the database. Validation will be conducted with young people aged 18 to 25 through usability testing and analysis of the clarity of results. The contribution of this project lies in the integration of a consolidated psychological theory with contemporary technological resources, enabling a Dynamic, personalized, and optimized experience

for mobile devices. Expected outcomes include higher user engagement, reduced vocational anxiety, and effective support for career planning in the digital age.

Keywords: *self-knowledge; multiple intelligence; artificial intelligence; vocational guidance; mobile application.*

1 Introdução

A transição para a vida adulta representa um dos estágios mais decisivos no desenvolvimento de um indivíduo, momento em que a escolha profissional surge como um pilar fundamental para a construção de uma carreira e para a satisfação pessoal. Autores como Super (1990) e Savickas (2002) destacam que este não é um processo linear ou simples. Pelo contrário, é marcado por uma multiplicidade de opções, intensas pressões sociais e, frequentemente, uma carência de autoconhecimento, fatores que culminam em ansiedade e indecisão para os jovens. Diante de um cenário de possibilidades quase ilimitadas e de um mercado de trabalho em constante transformação, um dos maiores desafios contemporâneos é tornar essa jornada de descoberta mais clara, personalizada e menos angustiante. Nesse contexto, torna-se cada vez mais desafiador orientar os jovens utilizando apenas metodologias tradicionais, como testes vocacionais padronizados, que muitas vezes se mostram insuficientes para capturar a complexidade das novas gerações.

Os métodos convencionais de orientação vocacional, frequentemente baseados em questionários estáticos e abordagens genéricas, falham em dialogar com uma juventude imersa em tecnologias digitais e acostumada com o dinamismo e a interatividade. Pesquisas como as de Robbins e Judge (2014) apontam que os indivíduos possuem características, interesses e motivações únicas, o que reforça a ineficácia de soluções "tamanho único". A principal motivação para o desenvolvimento deste projeto nasceu da observação dessa problemática geracional. Em círculos sociais e em relatos de jovens na faixa dos 20 anos, é notável um sentimento comum de "estar perdido", uma dificuldade genuína em identificar as próprias paixões e talentos. Essa angústia indica a necessidade urgente de ferramentas de apoio mais humanas, inteligentes e adaptadas à realidade digital, que transformem o processo de autodescoberta em uma experiência engajadora e assertiva.

Para enfrentar esse desafio, o mercado de trabalho moderno oferece uma pista valiosa: a crescente valorização do capital intelectual e da diversidade de habilidades. A ideia de uma "inteligência única" foi superada pela compreensão de que múltiplas competências são cruciais para a inovação. Neste ponto, a Teoria das Inteligências Múltiplas de Howard Gardner (1995) ganha especial relevância, ao propor que cada indivíduo possui um espectro único de inteligências. Simultaneamente, a ascensão da Inteligência Artificial (IA) abre novas fronteiras. Estudos como os de Baker e Siemens (2014) e Chen et al. (2020) mostram o potencial da IA para analisar grandes volumes de dados e gerar recomendações personalizadas em larga escala, apoiando processos de aprendizagem e desenvolvimento pessoal de forma antes inviável. A integração entre a psicologia e a tecnologia, mediada pela IA, surge, portanto, como uma solução promissora para modernizar a orientação profissional.

É neste cenário de convergência que se insere a proposta deste artigo: o desenvolvimento de um aplicativo móvel para iOS denominado Luminar. A escolha por uma aplicação nativa justifica-se pela busca de uma experiência de usuário

superior, com maior desempenho, fluidez e integração com os recursos do sistema operacional, elementos essenciais para manter o engajamento do público-alvo. O Luminar foi concebido para ir além dos testes vocacionais tradicionais, que muitas vezes entregam um "rótulo" sem fornecer os próximos passos. A aplicação visa traduzir os resultados do perfil do usuário em recomendações concretas, sugerindo carreiras e práticas de desenvolvimento alinhadas às suas inteligências predominantes, transformando o autoconhecimento em um plano de ação tangível.

O objetivo geral deste trabalho é, portanto, desenvolver e implementar o aplicativo móvel Luminar, uma ferramenta voltada para auxiliar jovens no processo de autoconhecimento e orientação profissional com base na Teoria das Múltiplas Inteligências, oferecendo suporte contínuo ao planejamento de carreira. Para alcançar este propósito, foram traçados os seguintes objetivos específicos: primeiramente, desenvolver o aplicativo nativo para o sistema operacional iOS, garantindo uma ferramenta acessível e de alta performance. Em seguida, elaborar um questionário interativo e dinâmico, fundamentado nos diferentes tipos de inteligências proposto por Howard Gardner. Concomitantemente, implementar um módulo de Inteligência Artificial capaz de analisar as respostas do usuário para gerar um perfil personalizado e detalhado de suas inteligências. Foi desenvolvido também o *back-end* da aplicação, seguindo as melhores práticas de segurança e privacidade de dados. Por fim, a aplicação foi validada com cinco jovens do público-alvo, a fim de coletar *feedbacks* que permitirão ajustes e melhorias no software.

Para apresentar de forma clara e organizada o percurso desta pesquisa, o artigo foi estruturado em cinco seções. A segunda seção, Referencial Teórico, apresenta os conceitos que embasam o trabalho, abordando a Teoria das Múltiplas Inteligências, o autoconhecimento na era digital, a orientação profissional para jovens e a aplicação de Inteligência Artificial em sistemas de recomendação, além de detalhar as tecnologias escolhidas. A terceira seção é dedicada aos aspectos técnicos do projeto, incluindo a análise de requisitos, a arquitetura do sistema, a implementação das funcionalidades e os protótipos de UI/UX. Na quarta seção, Resultados e Discussões, é descrito o processo de validação com os usuários, apresentando a análise dos dados coletados e discutindo a eficácia do aplicativo. Finalmente, a quinta seção, Conclusão, sintetiza os principais resultados do trabalho, avalia o cumprimento dos objetivos, destaca as contribuições do projeto e sugere trabalhos futuros.

2 Referencial Teórico

A presente seção tem como objetivo apresentar a base teórica que fundamenta este estudo. Para isso, são discutidos conceitos fundamentais sobre a Teoria das Inteligências Múltiplas, seus impactos no contexto educacional e profissional, e a aplicação da Inteligência Artificial e *Machine Learning* (ML) para personalização de testes e recomendações.

O conceito de inteligência tem sido amplamente estudado ao longo dos séculos, com diferentes abordagens sobre sua definição e medição (Hunt, 2011). Tradicionalmente, os modelos de inteligência focam no Quociente de Inteligência (QI), um indicador quantitativo do desempenho cognitivo baseado em testes padronizados. Alfred Binet e Theodore Simon foram pioneiros nessa metodologia no início do século XX, desenvolvendo testes para avaliar o desempenho acadêmico e identificar dificuldades de aprendizagem. A própria definição do que é inteligência e como ela

evolui ao longo das gerações é um campo de estudo vasto, popularizado por pesquisadores como Flynn (2007).

Entretanto, diversos estudiosos, incluindo Howard Gardner, questionaram a limitação do modelo do QI, argumentando que ele não captura toda a complexidade da inteligência humana. Outros teóricos, como Sternberg (1985) com sua Teoria Triárquica da Inteligência, também propuseram modelos alternativos que expandem a noção de uma inteligência única. Gardner, em particular, propôs uma abordagem mais ampla, levando em consideração habilidades diversificadas que não podem ser reduzidas a um único número (Gardner, 1995).

2.1 Tipos de Inteligências

A teoria de Gardner, detalhada em sua obra seminal (Gardner, 1995) e amplamente discutida no meio educacional (Nogueira, 2010; Santos, 2012), postula a existência de diferentes faculdades mentais, relativamente independentes umas das outras. A seguir, são descritos os tipos de inteligência propostos, conforme a teoria e suas aplicações práticas (Campbell, 2004):

- Inteligência Linguística: relacionada à sensibilidade para a linguagem, comunicação verbal e escrita. Caracteriza escritores, jornalistas e comunicadores.
- Inteligência Lógico-Matemática: habilidade de raciocínio lógico e resolução de problemas matemáticos. Característica de cientistas e engenheiros.
- Inteligência Espacial: capacidade de visualizar e manipular objetos mentalmente, fundamental para arquitetos, artistas e designers.
- Inteligência Musical: sensibilidade para tons, ritmos e sons, comum entre músicos e compositores.
- Inteligência Corporal-Cinestésica: habilidade de coordenação e controle do próprio corpo, relevante para atletas, dançarinos e cirurgiões.
- Inteligência Interpessoal: capacidade de entender e interagir com outras pessoas, importante para psicólogos, professores e líderes. Esta inteligência se aproxima de conceitos desenvolvidos posteriormente, como a inteligência emocional (Goleman, 1995).
- Inteligência Intrapessoal: autoconhecimento e compreensão dos próprios sentimentos e comportamentos, também um pilar da inteligência emocional (Salovey; Mayer, 1990).
- Inteligência Naturalista: habilidade de identificar padrões na natureza e interagir com o meio ambiente, essencial para biólogos e ecologistas.
- Inteligência Existencial: capacidade de refletir sobre questões filosóficas e transcendentais, característica de teólogos e filósofos (Smith, 2005).

2.2 A Aplicação da Inteligência Artificial na Personalização de Testes e Recomendações

A evolução da Inteligência Artificial e do *Machine Learning* possibilitou a criação de ferramentas mais dinâmicas e personalizadas para avaliação cognitiva (Gonçalves, 2016). A combinação dessas tecnologias com a Teoria das Inteligências

Múltiplas abre novas possibilidades para a construção de sistemas inteligentes voltados ao autoconhecimento e à orientação profissional.

Com o avanço dos algoritmos de Aprendizado de Máquina, tornou-se possível desenvolver testes interativos, nos quais as respostas do usuário são analisadas dinamicamente para fornecer resultados mais precisos (Miyako, 2018). Alguns benefícios do uso de IA nesse contexto, especialmente no âmbito educacional, incluem (Lord, 2019):

- Adaptação personalizada: o sistema ajusta perguntas conforme o padrão de respostas do usuário, tornando a avaliação mais eficiente e precisa.
- Análise preditiva: permite prever áreas de maior potencial profissional com base no comportamento e nas respostas do usuário durante o teste.
- *Feedback* instantâneo: geração de relatórios personalizados e imediatos que podem auxiliar na tomada de decisões de carreira e desenvolvimento pessoal.

Nesse sentido, a aplicação da IA em sistemas de recomendação de carreiras possibilita a criação de aplicativos inovadores que auxiliam indivíduos a encontrar áreas de atuação compatíveis com seu perfil. Utilizando algoritmos que cruzam dados de habilidades, preferências e tendências do mercado, esses sistemas são capazes de oferecer sugestões altamente customizadas, preparando os jovens para o futuro do trabalho (Hardy, 2020; Allen, 2020).

2.3 Biografia de Howard Gardner

Howard Gardner (nascido em Scranton, Pensilvânia, 1943) é um psicólogo cognitivo e educacional cujo trabalho revolucionou a forma como a inteligência é compreendida. Formado pela Universidade de Harvard, onde se tornou professor e pesquisador, Gardner se tornou uma das referências mundiais no estudo do potencial humano.

Ele iniciou seus estudos sobre as múltiplas inteligências a partir de pesquisas com populações diversas, incluindo indivíduos com talentos específicos, como músicos prodígios, e pacientes que, após sofrerem danos cerebrais, perdiam certas habilidades enquanto mantinham outras intactas. Essa dissociação de capacidades serviu como evidência para a sua teoria. Seu trabalho resultou na publicação do livro *Frames of Mind: The Theory of Multiple Intelligences* (1983), no qual propôs inicialmente sete inteligências distintas.

Apesar de sua ampla aceitação no campo educacional, a teoria gerou debates e críticas no meio psicométrico mais tradicional, que questionava a falta de testes padronizados para medir tais inteligências. Ao longo dos anos, Gardner expandiu sua teoria, adicionando as inteligências Naturalista e Existencial. Há décadas, ele também atua como diretor sênior do Harvard Project Zero, um grupo de pesquisa focado em aprimorar a educação por meio da compreensão da cognição, do pensamento crítico e da criatividade. Hoje, seu legado continua a influenciar não apenas a psicologia, mas principalmente o desenvolvimento de métodos de ensino inovadores e mais inclusivos em todo o mundo.

3 Materiais e Métodos

A presente pesquisa caracteriza-se como aplicada, uma vez que tem como propósito o desenvolvimento de uma solução prática para um problema real: apoiar jovens em fase de escolha profissional por meio de um aplicativo móvel para iOS interativo. Quanto aos objetivos, trata-se de uma pesquisa exploratória e descritiva. É exploratória porque busca compreender como a integração entre a Teoria das Inteligências Múltiplas e a Inteligência Artificial pode ser aplicada em um contexto de orientação profissional. É também descritiva, pois apresenta o processo de desenvolvimento do aplicativo Luminar, descrevendo suas funcionalidades e arquitetura tecnológica.

No que se refere à abordagem, a pesquisa é mista, combinando aspectos quantitativos e qualitativos. Do ponto de vista quantitativo, os dados coletados pelo questionário de inteligências múltiplas permitem a análise estatística das respostas dos usuários. Para a elaboração do questionário, foi realizada uma análise de instrumentos de avaliação das Inteligências Múltiplas já existentes e amplamente difundidos na literatura e em plataformas digitais. O questionário do aplicativo Luminar foi, então, sintetizado e adaptado a partir desses modelos, buscando manter a fidelidade aos construtos definidos por Howard Gardner, ao mesmo tempo em que se garantia uma linguagem acessível e uma experiência interativa para o público-alvo. Já do ponto de vista qualitativo, os *feedbacks* coletados durante os testes de usabilidade, detalhados mais adiante, fornecem informações subjetivas sobre clareza, engajamento e relevância da ferramenta.

Como procedimento técnico, segue-se um estudo de caso com jovens de 18 a 25 anos, público-alvo do aplicativo. O estudo consiste na aplicação piloto da ferramenta para avaliação preliminar de sua eficácia e usabilidade, com base em um grupo de usuários voluntários.

Para o treinamento do módulo de Inteligência Artificial, foi elaborado um formulário baseado na Teoria das Inteligências Múltiplas de Howard Gardner, aplicado a profissionais atuantes em diferentes áreas. Esses profissionais responderam ao questionário, permitindo a coleta de dados reais que relacionam inteligências predominantes a trajetórias profissionais.

Com os dados coletados a Inteligência Artificial usou esses dados para realizar o treinamento, sendo o núcleo do sistema de recomendação é uma rede neural desenvolvida com a biblioteca TensorFlow.js. A Figura 1 ilustra a definição da arquitetura do modelo, que consiste em camadas densas projetadas para aprender os padrões nos dados.

Os resultados coletados dos profissionais foram utilizados como conjunto de treinamento. A IA foi treinada para correlacionar perfis de inteligências com profissões específicas, conforme mostra o código na Figura 2, que apresenta o processo de compilação e treinamento (fit) do modelo.

Figura 1 - Definição do Modelo de Rede Neural com TensorFlow.

```
const model = tf.sequential();  
model.add(tf.layers.dense({ units: 32, activation: 'relu', inputShape: [8] }));  
model.add(tf.layers.dense({ units: 16, activation: 'relu' }));  
model.add(tf.layers.dense({ units: professions.length, activation: 'softmax' }));
```

Fonte: Autoria Própria.

Figura 2 - Processo de Treinamento (fit) do Modelo de IA.

```
model.compile({ optimizer: 'adam', loss: 'categoricalCrossentropy', metrics: ['accuracy'] });  
  
await model.fit(xs, ys, {  
  epochs: 50,  
  batchSize: 16,  
  verbose: 1  
});
```

Fonte: Autoria Própria.

3.1 Metodologia de Desenvolvimento

O desenvolvimento da aplicação seguiu metodologias ágeis, que valorizam a flexibilidade e a entrega contínua de valor. Em especial, foi adotado o método Kanban para o gerenciamento visual das tarefas, apoiado pela ferramenta Trello para a organização das atividades.

O Kanban é uma metodologia que surgiu no contexto da manufatura industrial na Toyota, no Japão, e foi adaptada com grande sucesso para o desenvolvimento de software. A metodologia baseia-se em três princípios fundamentais: visualizar o trabalho, limitar o trabalho em progresso (Work in Progress - WIP) e focar no fluxo contínuo. Por meio do uso de quadros, colunas e cartões, a equipe consegue acompanhar visualmente o status de cada tarefa, desde o início ("A Fazer") até a conclusão ("Feito"), facilitando a identificação de gargalos e a implementação de melhorias (Anderson, 2010).

O uso de ferramentas digitais como o Trello revelou-se fundamental para a aplicação prática desses princípios, permitindo a organização e o acompanhamento sistemático das atividades. O aplicativo possibilita a visualização clara do andamento das tarefas e o registro do histórico completo da evolução do trabalho, favorecendo a gestão eficiente do projeto (Stellman; Greene, 2014).

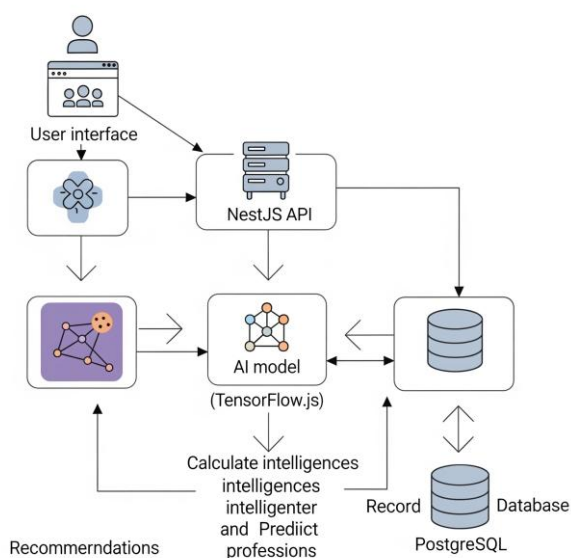
3.2 Análise e Projeto do Sistema

O processo de análise e projeto do aplicativo Luminar buscou traduzir os objetivos definidos para o sistema em soluções técnicas e funcionais. A etapa envolveu o levantamento de requisitos e a modelagem conceitual do sistema.

O levantamento de requisitos foi realizado com base em estudos da literatura sobre orientação vocacional e em observações de demandas recorrentes entre jovens de 18 a 25 anos. Como requisitos funcionais, destacam-se: a disponibilização de um questionário fundamentado na Teoria das Inteligências Múltiplas, a geração de um relatório de perfil personalizado e a recomendação de carreiras. Como requisitos não funcionais, definiu-se que o aplicativo deveria ser responsivo, escalável e seguro.

Para a modelagem do sistema, foram elaborados um diagrama funcional, para representar o fluxo do usuário no aplicativo, e um diagrama entidade-relacionamento, para modelar a estrutura do banco de dados. O relacionamento entre as entidades foi modelado de forma a permitir a escalabilidade do sistema. Usuários e profissionais têm seus dados de inteligência armazenados em tabelas separadas, mas com estrutura idêntica, o que facilita o uso conjunto para fins de análise e comparação.

Figura 3 – Fluxo do usuário no aplicativo.



Fonte: Autoria Própria.

3.3 Tecnologias Utilizadas

O desenvolvimento do Luminar foi estruturado a partir de uma arquitetura moderna, que combina múltiplas ferramentas e linguagens para garantir desempenho, escalabilidade e segurança. Neste capítulo, cada tecnologia utilizada será descrita em detalhe, com foco em seu papel dentro do sistema e nas razões que justificaram sua adoção.

- **Front-end (iOS Nativo):** a aplicação foi construída com Swift, a linguagem moderna e segura da Apple. A interface gráfica foi desenvolvida com UIKit, garantindo componentes nativos e uma experiência familiar ao usuário de iOS. A organização do código seguiu a arquitetura MVVC (Model-View-ViewModel-Coordinator), que promove

um alto desacoplamento das responsabilidades, separando a lógica de navegação (Coordinator) da lógica de apresentação (ViewModel) e da visualização (View).

- *Linguagem Swift:* A linguagem Swift foi lançada pela Apple em 2014 como substituta do Objective-C, amplamente utilizado desde a década de 1980. Diferentemente de sua antecessora, o Swift foi projetado para ser moderno, seguro e de fácil aprendizado, incorporando mecanismos automáticos capazes de prevenir erros de memória e falhas de segurança comuns em linguagens mais antigas. No desenvolvimento do aplicativo Luminar, a adoção do Swift trouxe vantagens significativas. Entre elas, destaca-se a segurança, já que a linguagem permite a detecção de erros antes mesmo da execução, reduzindo a probabilidade de falhas em produção. A performance também se mostrou um diferencial, pois, embora apresente simplicidade na escrita do código, o Swift alcança níveis de desempenho comparáveis a linguagens de baixo nível, como C++. Além disso, sua integração nativa ao ecossistema Apple assegura compatibilidade total com as atualizações do iOS, oferecendo suporte contínuo ao longo do ciclo de vida do aplicativo. Ainda que alternativas híbridas, como React Native ou Flutter, estivessem disponíveis, a escolha pelo Swift revelou-se a mais adequada para garantir alto desempenho e uma experiência de uso consistente, sem as limitações impostas por soluções de terceiros.
- *Framework UIKit:* O UIKit constitui o principal framework gráfico do iOS, sendo responsável por disponibilizar componentes de interface como botões, tabelas, menus, barras de navegação e animações. Criado em 2007, juntamente com as primeiras versões do iPhone, o UIKit permanece amplamente utilizado em aplicativos que priorizam estabilidade. No desenvolvimento do aplicativo Luminar, a escolha por esse framework se justificou por diferentes razões. Em primeiro lugar, a consistência visual, uma vez que o UIKit garante a aderência aos padrões estabelecidos pela Apple, oferecendo maior familiaridade ao usuário. Em segundo lugar, a estabilidade, característica de uma tecnologia consolidada, que reduz o risco de problemas inesperados em atualizações do sistema. Por fim, a flexibilidade, aspecto que se mostrou decisivo, já que, embora o SwiftUI represente uma alternativa mais recente, o UIKit possibilita maior controle sobre os detalhes da interface, o que foi essencial para o nível de personalização exigido pelo projeto. Dessa forma, o uso do UIKit representou um equilíbrio entre inovação e confiabilidade, elementos indispensáveis para a robustez necessária ao Luminar.
- *Arquitetura MVVM (Model-View-ViewModel):* A arquitetura MVVM foi adotada como padrão de organização do aplicativo. Criado em 2005 pela Microsoft, esse modelo surgiu como uma evolução do tradicional MVC (Model-View-Controller) e tem como objetivo principal a separação clara de responsabilidades, o que contribui para a maior manutenibilidade do sistema. Nesse contexto, o Model representa os dados e estruturas fundamentais, enquanto a View corresponde à interface visual, composta por botões, listas e demais elementos acessados pelo usuário. Já o ViewModel atua como intermediário entre

o Model e a View, sendo responsável por encapsular a lógica de apresentação. No caso do aplicativo Luminar, a adoção da MVVM trouxe benefícios diretos. A organização do código foi aprimorada, uma vez que cada camada passou a ter uma responsabilidade única, o que reduziu a complexidade geral. Além disso, a testabilidade foi favorecida, pois a lógica concentrada no ViewModel possibilitou a validação simplificada de comportamentos por meio de testes automatizados. A escalabilidade também se destacou como uma vantagem, permitindo a adição de novas funcionalidades sem comprometer aquelas já existentes. Embora arquiteturas alternativas, como MVP ou VIPER, também fossem viáveis, a MVVM demonstrou o melhor equilíbrio entre simplicidade e clareza, sobretudo no contexto de aplicações modernas desenvolvidas para iOS.

- **Comunicação com a API:** Um dos papéis centrais do frontend é a comunicação com o backend. No Luminar, essa comunicação é feita por meio de requisições HTTP que acessam os serviços da API REST. Para gerenciar a autenticação, foi criado um componente chamado TokenManager, responsável por armazenar e atualizar os tokens de acesso (JWT). Esses tokens funcionam como uma espécie de “chave digital”, que autoriza temporariamente as ações do usuário dentro do aplicativo. A segurança desse processo foi garantida pelo uso do Keychain, sistema de armazenamento seguro do iOS. O Keychain funciona como um cofre criptografado interno, criado pela Apple para guardar informações confidenciais, como senhas e credenciais bancárias. Ao utilizar esse recurso, o Luminar assegura que os dados de autenticação dos usuários permaneçam protegidos, mesmo em caso de comprometimento do dispositivo.
- **Experiência do Usuário (UX):** Outro ponto importante foi a preocupação com a experiência do usuário (UX). O desenvolvimento nativo possibilitou que o aplicativo explorasse recursos específicos do iOS, como notificações push, animações mais fluidas e integração com serviços do sistema operacional, a exemplo da câmera, do GPS e do Keychain. Essa integração direta trouxe benefícios significativos, pois aumentou a velocidade e a fluidez do sistema, reduzindo o tempo de carregamento e tornando as interações mais naturais. Além disso, contribuiu para maior confiabilidade, já que evitou falhas comuns em frameworks híbridos, e garantiu familiaridade ao manter os padrões de design da Apple, o que facilitou a curva de aprendizado do usuário.
- **Back-end e Banco de Dados:** a interface de programação de aplicações foi desenvolvida em TypeScript com o framework NestJS, garantindo um código fortemente tipado e organizado. Para o banco de dados, o PostgreSQL foi escolhido por sua confiabilidade e robustez no gerenciamento de dados relacionais.
- **Node.js:** O Node.js surgiu em 2009, criado por Ryan Dahl, com o objetivo de expandir os limites da linguagem JavaScript. Antes dessa tecnologia, o JavaScript era restrito ao navegador, atuando apenas na manipulação da interface gráfica. Com o Node.js, tornou-se possível executar JavaScript em servidores, permitindo que a mesma linguagem seja usada tanto no backend quanto no frontend. A base do Node.js é o motor V8, desenvolvido pelo Google para o navegador Chrome. Esse motor

compila o JavaScript diretamente em código de máquina, o que garante alta velocidade na execução. Graças a essa característica, o Node.js é amplamente adotado em sistemas que exigem respostas rápidas e capazes de lidar com milhares de usuários simultaneamente. No Luminar, o uso do Node.js foi fundamental para a construção de um servidor escalável. Essa escolha reduziu custos de desenvolvimento, já que a equipe pôde concentrar-se em uma única linguagem para ambas as camadas do sistema, facilitando a integração entre backend e frontend. Outras alternativas, como Java (Spring Boot) ou Python (Django/Flask), foram avaliadas, mas o Node.js se destacou pela compatibilidade direta com bibliotecas de inteligência artificial utilizadas no projeto.

- *TypeScript*: O TypeScript é uma evolução do JavaScript, criada pela Microsoft em 2012. Sua principal característica é a adição de tipagem estática, ou seja, a possibilidade de definir com antecedência quais tipos de dados cada variável deve conter. Isso evita erros comuns em projetos grandes, como tentar somar um número a um texto, e permite que o próprio editor de código identifique falhas durante o desenvolvimento. No Luminar, o uso de TypeScript aumentou a segurança e a clareza do código. Para a equipe, isso significou menos tempo corrigindo erros inesperados e mais confiança na manutenção futura. Em comparação ao JavaScript puro, o TypeScript oferece maior robustez em projetos de médio e grande porte, o que o torna uma escolha natural em sistemas que precisam ser sustentados por vários anos.
- *NestJS*: O NestJS é um framework progressivo para Node.js, inspirado em boas práticas de desenvolvimento de software, como a arquitetura modular. Ele organiza o sistema em módulos, controladores e serviços, o que promove clareza e facilita a manutenção. No contexto do Luminar, o NestJS possibilitou a construção de um backend mais organizado e escalável. Isso significa que novas funcionalidades podem ser adicionadas sem comprometer o funcionamento já existente. Embora outros frameworks, como o Express.js, sejam populares, o NestJS foi preferido por oferecer uma estrutura mais rígida, que incentiva boas práticas e reduz a possibilidade de erros arquiteturais.
- *PostgreSQL e TypeORM*: O PostgreSQL é um dos bancos de dados relacionais mais respeitados no mundo, com origem na Universidade da Califórnia, em 1986. Ele é conhecido por sua robustez, confiabilidade e suporte a transações complexas. Trata-se de uma tecnologia que garante integridade e segurança no armazenamento de dados. Para interagir com esse banco de dados, o Luminar utilizou o TypeORM, que funciona como um tradutor entre o código em TypeScript e as tabelas do PostgreSQL. Essa abordagem simplifica operações comuns — como cadastrar, consultar ou atualizar informações — sem que o desenvolvedor precise escrever comandos SQL diretamente. A escolha do PostgreSQL se deve à sua estabilidade e às suas funcionalidades avançadas. Alternativas como MySQL e SQLite foram consideradas, mas o PostgreSQL mostrou-se mais adequado por oferecer melhor suporte a operações complexas e por ser amplamente utilizado em ambientes de produção.

- *TensorFlow.js*: O TensorFlow.js é uma biblioteca de aprendizado de máquina desenvolvida pelo Google, voltada para a execução de modelos de inteligência artificial em JavaScript. Diferente de outras bibliotecas que exigem servidores externos, o TensorFlow.js pode ser executado diretamente no ambiente Node.js. No Luminar, essa biblioteca foi utilizada para treinar e executar modelos de machine learning responsáveis pelas funcionalidades de recomendação. Essa integração direta simplificou a arquitetura, evitando a dependência de serviços externos e aumentando a velocidade de resposta. Alternativas como Scikit-learn ou TensorFlow (Python) poderiam ser utilizadas, mas exigiriam a integração de linguagens diferentes. O TensorFlow.js, por sua vez, manteve todo o ecossistema em JavaScript/TypeScript, reduzindo a complexidade.
- *Autenticação e segurança*: A segurança foi uma prioridade no Luminar. Para autenticar usuários, foi adotado o JSON Web Token (JWT), que funciona como um crachá digital temporário. Esse token permite que cada requisição seja validada de forma rápida, sem necessidade de verificar constantemente informações no banco de dados. As senhas foram protegidas com a biblioteca Bcrypt, que aplica um processo de criptografia irreversível. Dessa forma, mesmo que o banco de dados seja comprometido, as senhas não poderão ser lidas em texto simples.
- *Validação de Dados e Documentação*: Para garantir a integridade das informações recebidas, foram utilizadas bibliotecas como class-validator, que verificam automaticamente se os dados estão no formato esperado (por exemplo, se um campo de e-mail contém "@"). A documentação da API foi criada com o Swagger (OpenAPI), permitindo que outros desenvolvedores entendam e testem as funcionalidades do sistema por meio de uma interface gráfica interativa.
- *Inteligência Artificial e Processamento de Dados*: O presente estudo empregou técnicas de inteligência artificial apoiadas na biblioteca TensorFlow.js, a qual possibilitou o treinamento e a execução de modelos de *machine learning* diretamente no ambiente Node.js. Essa abordagem permitiu integrar algoritmos de aprendizado de máquina ao sistema de forma eficiente, sem a necessidade de infraestrutura externa adicional, assegurando desempenho adequado e maior controle sobre o processo de análise dos dados.
- *SheetJS(xlsx)*: Para viabilizar a etapa de importação e tratamento dos dados, utilizou-se a biblioteca SheetJS (xlsx). Essa ferramenta foi responsável por processar planilhas em formato Excel e transformá-las em estruturas manipuláveis pelo ambiente de desenvolvimento. A utilização do SheetJS foi fundamental para automatizar a leitura dos dados brutos e prepará-los para posterior uso pelo modelo de inteligência artificial.
- *JSON*: A conversão dos dados de planilhas para o formato JSON (JavaScript Object Notation) representou um ponto central na preparação da base de treinamento. Esse formato de intercâmbio de dados, amplamente adotado por sua simplicidade e legibilidade, facilitou a integração entre diferentes módulos da aplicação. Além disso, garantiu

que as informações fossem organizadas de maneira padronizada, permitindo maior eficiência no fluxo de processamento e na comunicação entre sistemas.

3.4 Procedimentos de Validação

A etapa de validação do aplicativo Luminar foi conduzida por meio de um estudo de caso qualitativo com um grupo-piloto. Devido ao escopo acadêmico do projeto e às restrições inerentes à distribuição de aplicativos fora da loja oficial da Apple (App Store), optou-se por uma abordagem de teste controlado.

O teste foi realizado com 5 jovens, conforme o público-alvo definido, em ambiente controlado. A instalação do aplicativo foi feita diretamente em um dispositivo iOS disponível para o teste. Cada participante foi orientado a utilizar todas as funcionalidades principais do Luminar, desde a realização do questionário até a análise do relatório de perfil e das recomendações de carreira. Ao final da interação, foi aplicado um questionário semiestruturado para a coleta de *feedbacks* qualitativos sobre usabilidade, clareza e relevância da ferramenta.

4 Resultados e Discussão

Após o desenvolvimento do aplicativo Luminar, foi conduzida a etapa de validação com o público-alvo, conforme previsto na metodologia. Esta seção apresenta a aplicação final, os resultados coletados a partir dos testes com o grupo-piloto de usuários e discute as implicações dessas descobertas para a solução proposta.

4.1 Apresentação da Aplicação Final

A versão final do aplicativo Luminar para iOS implementa o fluxo completo da jornada do usuário, desde a apresentação inicial até a entrega das recomendações de carreira personalizadas. As telas apresentadas nesta seção ilustram as principais etapas da experiência.

A jornada principal do usuário no aplicativo, desde o contato inicial até a entrega do perfil personalizado, é ilustrada na sequência apresentada pelas Figura 4. Primeiramente, o usuário é recebido pela tela de boas-vindas (Figura 4a), que estabelece a identidade visual do aplicativo com a mascote "Lume" e o propósito de "iluminar" a jornada vocacional. Em seguida, ele é guiado para a etapa central de coleta de dados por meio do questionário interativo (Figura 4b), cuja interface foi projetada para ser fluida e engajadora. Ao finalizar o teste, o aplicativo apresenta um relatório detalhado com o perfil de Inteligências Múltiplas do usuário (Figura 4c), exibindo os resultados de forma visual para facilitar a compreensão do seu potencial.

Figura 4 - Telas iniciais do aplicativo Luminar.

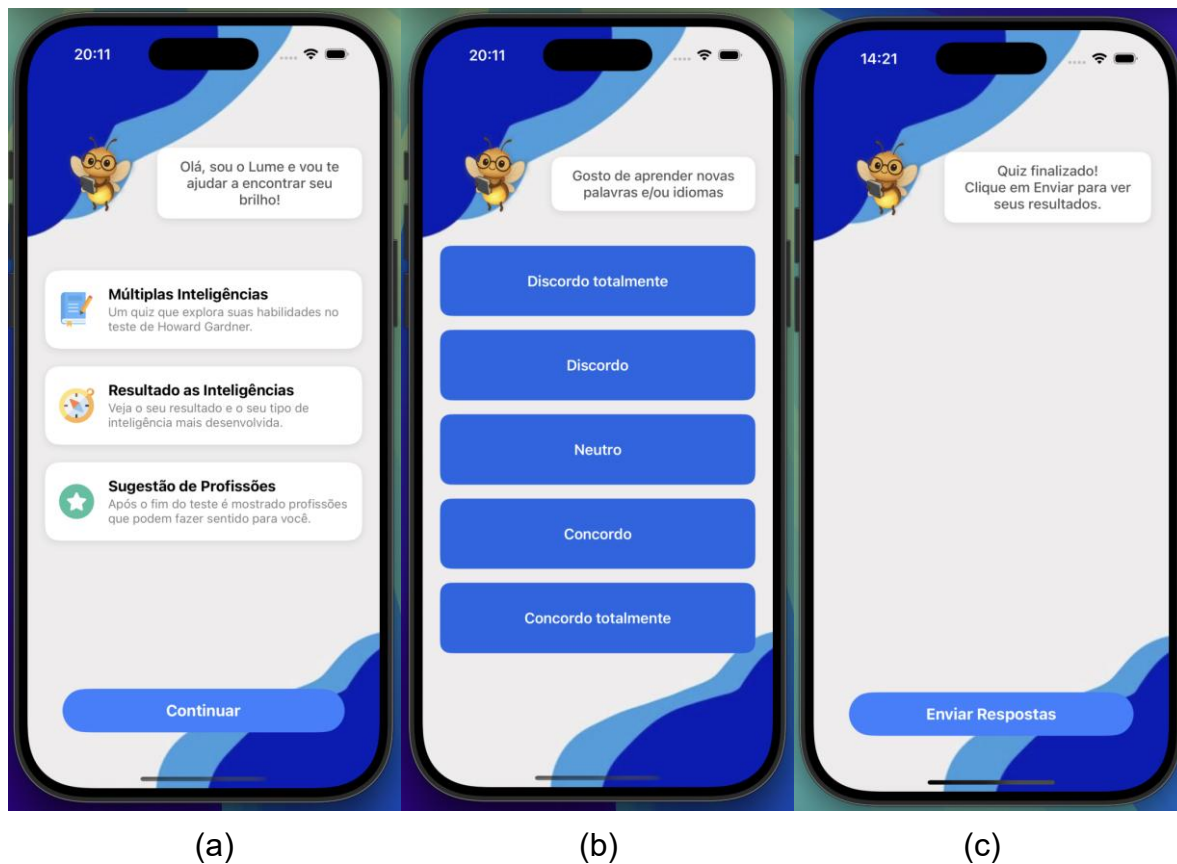


Fonte: Autoria Própria.

Após a autenticação no aplicativo, o usuário é introduzido ao fluxo de avaliação do aplicativo, um processo composto por três etapas principais. Primeiramente, a tela de *onboarding* (Figura 5a) apresenta uma visão geral da jornada de autoconhecimento, detalhando em cartões informativos como o teste, a análise de resultados e as recomendações da IA irão funcionar. Em seguida, o usuário inicia a etapa central de avaliação na tela do questionário (Figura 5b), onde responde a 45 afirmativas com base em uma escala de concordância de cinco pontos. Ao concluir o preenchimento de todas as questões, uma tela de finalização (Figura 5c) exibe uma mensagem de confirmação e disponibiliza o botão para que o usuário possa avançar para a visualização de seu perfil de inteligências.

Ao concluir o questionário, o usuário avança para as etapas finais da jornada, onde os dados de autoavaliação são transformados em *insights* práticos. Primeiramente, o aplicativo exibe a tela de resultados (Figura 6a), que apresenta o perfil de Inteligências Múltiplas de forma detalhada. Cada inteligência é exibida em um cartão (*card*) individual, acompanhada de uma breve descrição e da respectiva pontuação percentual, permitindo que o usuário compreenda suas aptidões predominantes. Por fim, na tela de recomendações (Figura 6b), o sistema de Inteligência Artificial sugere áreas de atuação e profissões alinhadas ao perfil do usuário, oferecendo um direcionamento concreto para a exploração de carreira. Esta tela também contém a funcionalidade para encerrar a sessão no aplicativo.

Figura 5 - Telas de apresentação, explicação e questionário.



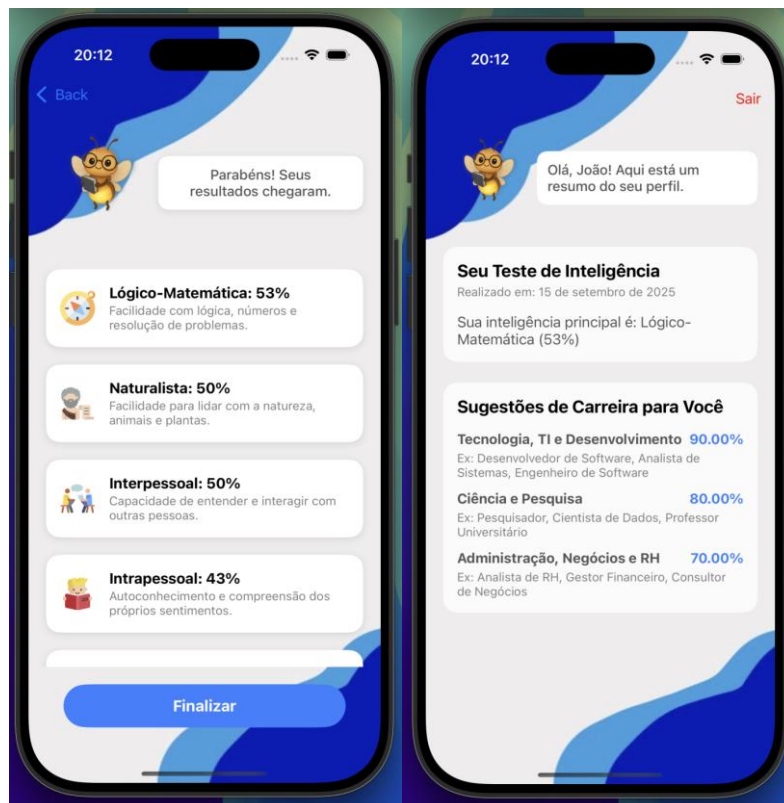
(a)

(b)

(c)

Fonte: Autoria Própria.

Figura 6 - Telas de resultados e recomendações.



(a)

(b)

Fonte: Autoria Própria.

4.2 Análise da Validação com Usuários

A validação foi realizada por meio de um teste de usabilidade com um grupo de cinco jovens voluntários (três do gênero feminino e dois do masculino, com idades entre 19 e 24 anos), todos estudantes universitários de áreas distintas (Engenharia de Software, Psicologia, Design Gráfico, Jornalismo e Administração). Ao final da interação, um questionário semiestruturado coletou suas percepções, que foram agrupadas em três categorias principais.

Em relação a Usabilidade e Experiência do Usuário, de forma unânime, a usabilidade do aplicativo foi avaliada muito positivamente. Todos os participantes classificaram a interface como "intuitiva" e "agradável". O Participante A (estudante de Design Gráfico) comentou que "o design é limpo e as perguntas aparecendo uma por uma deixam o processo menos cansativo". A alta aceitação da interface sugere que os objetivos de criar uma experiência de usuário engajadora foram atingidos.

Quanto à clareza e relevância do Relatório, a apresentação dos resultados foi considerada clara e de fácil compreensão. Quatro dos cinco participantes afirmaram se identificar com o perfil de inteligências gerado. A Participante D (estudante de Psicologia) destacou que "o relatório ajudou a colocar em palavras algumas habilidades que eu sentia que tinha, mas não sabia nomear", indicando a aderência da ferramenta ao seu propósito de promover o autoconhecimento.

Já em relação a Percepção sobre as Recomendações da IA, as recomendações de carreira foram o aspecto de maior interesse. Todos consideraram as sugestões "pertinentes" e "um bom ponto de partida". O Participante E (estudante de Administração) relatou que duas das três profissões sugeridas já eram de seu interesse e que a terceira "foi uma surpresa positiva". Como crítica construtiva, três participantes sugeriram a inclusão de mais informações sobre as carreiras recomendadas, para que pudessem explorá-las diretamente no aplicativo.

Os resultados da validação preliminar são promissores. O *feedback* positivo indica que o aplicativo Luminar é tecnicamente funcional e bem aceita pelo público-alvo, cumprindo seu objetivo de oferecer uma ferramenta moderna para orientação profissional. A forte identificação dos usuários com os relatórios e a alta relevância percebida nas recomendações da IA validam a abordagem central do projeto, que é a utilização de dados reais de profissionais para treinar o algoritmo.

As críticas, como a sugestão de aprofundar o conteúdo sobre as carreiras, são valiosas e apontam caminhos claros para a evolução do aplicativo. Conclui-se que o Luminar tem potencial para se tornar uma ferramenta de apoio eficaz na jornada de autoconhecimento e planejamento de carreira dos jovens.

5 Conclusão

O desenvolvimento do Luminar possibilitou verificar a viabilidade de integrar fundamentos da Teoria das Inteligências Múltiplas com tecnologias de desenvolvimento móvel e Inteligência Artificial. A solução mostrou ser eficaz em

oferecer um processo de orientação vocacional mais dinâmico e personalizado, contribuindo para que jovens reflitam de forma estruturada sobre suas aptidões.

Os resultados do projeto evidenciaram a coerência entre os requisitos levantados e a arquitetura adotada, garantindo escalabilidade e usabilidade. O *feedback* do grupo-piloto reforçou a relevância da proposta, apontando pontos fortes como a personalização do relatório e a aplicabilidade das recomendações. O principal diferencial do aplicativo é o uso de dados reais de profissionais para treinar o modelo de IA, permitindo que as recomendações sejam fundamentadas em padrões observados no mercado, e não apenas em interpretações teóricas.

Contudo, o projeto possui limitações. A validação foi realizada com uma amostra qualitativa restrita, adequada para uma avaliação inicial, mas que não permite generalizações estatísticas. Essa abordagem decorreu da necessidade de uma distribuição controlada do aplicativo. Adicionalmente, aponta-se a necessidade de expandir a base de profissões disponíveis.

Para a continuidade e evolução do projeto, são propostas as seguintes frentes de trabalho: (i) Evolução do Aplicativo e Base de Dados: publicar o aplicativo na Apple App Store para permitir o acesso em larga escala. Concomitantemente, ampliar continuamente a base de dados de treinamento com profissionais das mais diferentes áreas, além de expandir o catálogo de profissões disponíveis no sistema para refletir melhor as dinâmicas do mercado. (ii) Validação e Aprimoramento do Modelo de IA: com o aplicativo publicado, conduzir estudos quantitativos com uma amostra estatisticamente significativa para validar a eficácia do modelo. Além disso, incorporar algoritmos de Inteligência Artificial mais avançados para aumentar a precisão das recomendações. (iii) Pesquisa de Impacto e Integrações: investigar o impacto longitudinal da ferramenta nas escolhas profissionais dos jovens e ampliar os testes de usabilidade com diferentes perfis de usuários. Futuramente, integrar o sistema com plataformas educacionais e de mercado de trabalho, favorecendo uma transição mais assertiva entre estudo e carreira.

Dessa forma, conclui-se que o Luminar cumpre o papel de aliar fundamentos da psicologia educacional a soluções tecnológicas inovadoras, configurando-se como uma contribuição significativa para o campo da orientação vocacional na era digital.

Referências

ALLEN, Jack L. Artificial Intelligence and the Modern Workforce. Chicago: The University of Chicago Press, 2020.

ANDERSON, David J. Kanban: Mudança Evolucionária de Sucesso para seu Negócio de Tecnologia. Seattle: Blue Hole Press, 2010.

BAKER, R. S. J. d.; SIEMENS, G. Educational data mining and learning analytics. In: SAWYER, R. K. (Ed.). The Cambridge handbook of the learning sciences. 2. ed. Cambridge: Cambridge University Press, 2014.

CAMPBELL, Linda. Multiple Intelligences and How to Teach Them. New York: Pearson, 2004.

CHEN, L. et al. Artificial intelligence in education: A review. IEEE Access, v. 8, p. 75264-75278, 2020.

FLYNN, James R. What is Intelligence? Beyond the Flynn Effect. Cambridge: Cambridge University Press, 2007.

GARDNER, Howard. Inteligências múltiplas: a teoria na prática. Porto Alegre: Artmed, 1995.

GOLEMAN, Daniel. Emotional Intelligence: Why It Can Matter More Than IQ. New York: Bantam Books, 1995.

GONÇALVES, Andreia G. Inteligência Artificial e a Revolução Tecnológica. São Paulo: Atlas, 2016.

HARDY, Adrian. Artificial Intelligence and the Future of Work. New York: Palgrave Macmillan, 2020.

HUNT, Earl B. Human Intelligence. Cambridge: Cambridge University Press, 2011.

LORD, Tim. AI and Its Role in Education: A Review of Theories and Practices. Computers in Education Journal, 2019.

MIYAKO, Haruki. Inteligência Artificial: História, Evolução e Perspectivas Futuras. Campinas: Unicamp, 2018.

NOGUEIRA, Célia. A teoria das inteligências múltiplas e sua aplicação no contexto educacional. Porto Alegre: Artmed, 2010.

ROBBINS, Stephen P.; JUDGE, Timothy A. Comportamento Organizacional. 15. ed. São Paulo: Pearson Prentice Hall, 2014.

SALOVEY, Peter; MAYER, John D. Emotional Intelligence. Imagination, Cognition, and Personality, v. 9, n. 3, p. 185-211, 1990.

SANTOS, Bruna. Psicologia da Educação e as Inteligências Múltiplas de Gardner. Revista Brasileira de Educação, v. 17, p. 41-60, 2012.

SAVICKAS, M. L. Career construction: A developmental theory of vocational behavior. In: BROWN, D. (Ed.). Career choice and development. 4. ed. San Francisco: Jossey-Bass, 2002.

SMITH, M. K. Howard Gardner and Multiple Intelligences. The Encyclopedia of Informal Education, 2005.

STERNBERG, Robert. The Triarchic Mind: A New Theory of Human Intelligence. New York: Penguin Books, 1985.

SUPER, D. E. A life-span, life-space approach to career development. In: BROWN, D.; BROOKS, L. (Eds.). Career choice and development. 2. ed. San Francisco: Jossey-Bass, 1990.

STELLMAN, Andrew; GREENE, Jennifer. Aprendendo a Programar em Equipes Ágeis. São Paulo: Novatec Editora, 2014.