

**UNIVERSIDADE FEDERAL DO RIO DE JANEIRO  
CENTRO DE CIÊNCIAS DA MATEMÁTICA E DA NATUREZA  
PROGRAMA DE PÓS-GRADUAÇÃO EM HISTÓRIA DAS CIÊNCIAS E DAS  
TÉCNICAS E EPISTEMOLOGIA**

**FRANCISCO ANDRÉ MOREIRA DE LIMA**

**MODELO FUZZY DE TOMADA DE DECISÃO BASEADO EM  
ESPECIFICIDADES FUNCIONAIS: ANÁLISE DE DADOS DE  
PESSOAS COM DEFICIÊNCIA**

**RIO DE JANEIRO**

**2024**

FRANCISCO ANDRÉ MOREIRA DE LIMA

**MODELO FUZZY DE TOMADA DE DECISÃO BASEADO EM  
ESPECIFICIDADES FUNCIONAIS: ANÁLISE DE DADOS DE  
PESSOAS COM DEFICIÊNCIA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em História das Ciências e das Técnicas e Epistemologia, Universidade Federal do Rio de Janeiro, como requisito parcial à obtenção do título de Mestre em História das Ciências e das Técnicas e Epistemologia.

Orientador:

Prof. Dr. Alfredo Nazareno Pereira Boente

RIO DE JANEIRO

2024

## CIP - Catalogação na Publicação

L819m LIMA, FRANCISCO ANDRÉ MOREIRA DE  
MODELO FUZZY DE TOMADA DE DECISÃO BASEADO EM  
ESPECIFICIDADES FUNCIONAIS: ANÁLISE DE DADOS DE  
PESSOAS COM DEFICIÊNCIA / FRANCISCO ANDRÉ MOREIRA DE  
LIMA. -- Rio de Janeiro, 2024.  
65 f.

Orientador: ALFREDO NAZARENO PEREIRA BOENTE.  
Dissertação (mestrado) - Universidade Federal do  
Rio de Janeiro, Decania do Centro de Ciências  
Matemáticas e da Natureza, Programa de Pós-Graduação  
em História das Ciências e das Técnicas e  
Epistemologia, 2024.

1. Tomada de decisão multicritério. 2. Avaliação  
funcional. 3. Lógica fuzzy. 4. Redes neurais  
artificiais. 5. LangChain. I. BOENTE, ALFREDO  
NAZARENO PEREIRA, orient. II. Título.

Elaborado pelo Sistema de Geração Automática da UFRJ com os dados fornecidos pelo(a) autor(a), sob a responsabilidade de Miguel Romeu Amorim Neto - CRB-7/6283.

FRANCISCO ANDRÉ MOREIRA DE LIMA

**MODELO FUZZY DE TOMADA DE DECISÃO BASEADO EM ESPECIFICIDADES  
FUNCIONAIS: ANÁLISE DE DADOS DE PESSOAS COM DEFICIÊNCIA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em História das Ciências e das Técnicas e Epistemologia, Universidade Federal do Rio de Janeiro, como requisito parcial à obtenção do título de Mestre em História das Ciências e das Técnicas e Epistemologia.

Aprovada em: \_\_ de \_\_\_\_\_ de 2024.

---

**Prof. Dr. Alfredo Nazareno Pereira Boente (Orientador)**  
Universidade Federal do Rio de Janeiro - HCTE

---

**Prof. Dr. José Antonio dos Santos Borges**  
Universidade Federal do Rio de Janeiro - HCTE

---

**Prof. Dr. Evandro Vieira Ouriques**  
Universidade Federal do Rio de Janeiro - HCTE

---

**Prof. Dr. Edison Conde Perez dos Santos**  
Instituto Militar de Engenharia - IME

## AGRADECIMENTOS

Ao concluir este trabalho, é impossível não refletir sobre todas as pessoas que, de diversas maneiras, contribuíram para que eu chegasse até aqui. Primeiramente, quero expressar minha imensa gratidão à minha família. Vocês sempre foram meu porto seguro, oferecendo apoio incondicional, amor e compreensão em todos os momentos. Cada palavra de incentivo e cada gesto de carinho foram fundamentais para que eu superasse os desafios desta jornada. A vocês, minha eterna gratidão por acreditarem em mim e por me derem forças para continuar.

Gostaria de agradecer especialmente aos professores Ricardo Marciano e Vinícius Marques. Durante todo o curso, vocês não foram apenas mestres, mas também verdadeiros amigos. Suas orientações e conselhos foram essenciais para o meu crescimento acadêmico e pessoal. Vocês estiveram ao meu lado nos momentos mais desafiadores, sempre dispostos a compartilhar seu conhecimento e oferecer apoio. A amizade de vocês é um presente valioso, e sou profundamente grato por tê-los em minha vida.

Aos professores do HCTE, em especial meu orientador professor Alfredo Boente, professora Maira Fróes e professora Priscilla Tamiasso, meus sinceros agradecimentos por todo o conhecimento transmitido ao longo do curso. Cada aula, cada discussão e cada conselho contribuíram significativamente para minha formação. A dedicação de vocês em ensinar e orientar foi inspiradora, e sou muito grato por terem me proporcionado uma experiência acadêmica tão rica e transformadora. O apoio de vocês, muitas vezes silencioso, mas sempre presente, foi um alicerce importante nesta caminhada.

Também quero agradecer aos colegas de curso, com quem compartilhei momentos de aprendizado, desafios e conquistas. A convivência com vocês tornou essa jornada mais leve e significativa. Agradeço por cada troca de ideias, por cada risada e por cada momento de companheirismo.

Por fim, agradeço a todos que, de alguma forma, fizeram parte dessa trajetória. Sejam amigos, colegas, familiares ou professores, cada um de vocês que contribuíram para a realização deste trabalho e para o meu crescimento como pessoa e profissional.

A todos, meu sincero agradecimento.

## RESUMO

LIMA, Francisco André Moreira de. **Modelo *fuzzy* de tomada de decisão baseado em especificidades funcionais: Análise de dados de pessoas com deficiência.** Orientador: Alfredo Nazareno Pereira Boente. Projeto de Pesquisa de Dissertação (Mestrado em História das Ciências, das Técnicas e Epistemologia) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2024.

Esta dissertação explora o desenvolvimento de um modelo inovador de tomada de decisão multicritério para a avaliação funcional de pessoas com deficiência, utilizando uma abordagem integrada de lógica *fuzzy*, redes neurais artificiais e a tecnologia LangChain. O objetivo central é criar um sistema que possa lidar com a incerteza e a subjetividade dos dados, oferecendo uma avaliação mais precisa e personalizada das necessidades específicas desses indivíduos, especialmente no contexto educacional.

O estudo começa com uma revisão teórica abrangente, que abrange conceitos fundamentais de lógica *fuzzy*, redes neurais e métodos de tomada de decisão multicritério. A partir dessa base, desenvolve-se uma metodologia que combina pesquisa bibliográfica e um estudo de caso prático, realizado em uma instituição educacional. A aplicação do modelo proposto permite uma análise detalhada dos dados, facilitando a identificação de necessidades específicas e a adaptação de métodos de ensino e recursos pedagógicos.

Os resultados indicam que a combinação de lógica *fuzzy* e redes neurais, aprimorada pela tecnologia LangChain, melhora significativamente a precisão e a eficácia das avaliações funcionais. Além disso, o modelo mostra-se flexível e adaptável, permitindo sua aplicação em diferentes contextos e populações. A pesquisa destaca a importância de abordagens personalizadas na inclusão educacional e oferece uma ferramenta prática para educadores e profissionais de saúde.

Conclui-se que o modelo proposto não só contribui para uma melhor compreensão das necessidades de pessoas com deficiência, mas também promove uma inclusão mais eficaz e humanizada. Este trabalho abre caminho para futuras pesquisas e desenvolvimentos na área, incentivando a exploração de novas tecnologias e metodologias para aprimorar a qualidade da educação e a inclusão social.

**Palavras-chave:** Tomada de decisão multicritério. Avaliação funcional. Lógica *fuzzy*. Redes neurais artificiais. LangChain.

## ABSTRACT

*LIMA, Francisco André Moreira de. **Fuzzy decision-making model based on functional specificities: Data analysis of people with disabilities.** Advisor: Alfredo Nazareno Pereira Boente. Research Project for Dissertation (Master in History of Sciences, Techniques, and Epistemology) - Federal University of Rio de Janeiro, Rio de Janeiro, 2024.*

*This dissertation explores the development of an innovative multi-criteria decision-making model for the functional evaluation of people with disabilities, utilizing an integrated approach of fuzzy logic, artificial neural networks, and the LangChain technology. The central objective is to create a system capable of handling data uncertainty and subjectivity, offering a more precise and personalized assessment of these individuals' specific needs, especially in the educational context.*

*The study begins with a comprehensive theoretical review, covering fundamental concepts of fuzzy logic, neural networks, and multi-criteria decision-making methods. Based on this foundation, a methodology combining bibliographic research and a practical case study, conducted in an educational institution, is developed. The application of the proposed model enables a detailed analysis of the data, facilitating the identification of specific needs and the adaptation of teaching methods and pedagogical resources.*

*The results indicate that the combination of fuzzy logic and neural networks, enhanced by the LangChain technology, significantly improves the precision and effectiveness of functional evaluations. Moreover, the model proves to be flexible and adaptable, allowing its application in different contexts and populations. The research highlights the importance of personalized approaches in educational inclusion and offers a practical tool for educators and healthcare professionals.*

*It is concluded that the proposed model not only contributes to a better understanding of the needs of people with disabilities but also promotes more effective and humane inclusion. This work paves the way for future research and developments in the area, encouraging the exploration of new technologies and methodologies to enhance the quality of education and social inclusion.*

**Keywords:** Multi-criteria decision-making. Functional evaluation. Fuzzy logic. Artificial neural networks. LangChain.

## **LISTA DE SIGLAS**

ANN - Artificial Neural Network (Rede Neural Artificial)

BNDES - Banco Nacional de Desenvolvimento Econômico e Social

DI - Deficiência Intelectual

ETE - Empretec Training Workshop

FIP - Fuzzy Inference Process (Processo de Inferência Fuzzy)

HCTE - História das Ciências e das Técnicas e Epistemologia

IBGE - Instituto Brasileiro de Geografia e Estatística

INEP - Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira

LSTM - Long Short-Term Memory (Memória de Longo e Curto Prazo)

MPE - Micro e Pequenas Empresas

NLP - Natural Language Processing (Processamento de Linguagem Natural)

PNUD - Programa das Nações Unidas para o Desenvolvimento

RNN - Recurrent Neural Network (Rede Neural Recorrente)

SEBRAE - Serviço Brasileiro de Apoio às Micro e Pequenas Empresas

## LISTA DE ILUSTRAÇÕES E TABELAS

Figura 1	Controle de Temperatura com Lógica Fuzzy	24
Figura 2	Arquitetura de rede neural artificial (ANN ih 1-h 2-h no)	27
Figura 3	Exemplo de Redes Neurais Convolucionais	32
Figura 4	Processamento em Linguagem Natural	34
Figura 5	Rede Neural Long Short-Term Memory (LSTM)	38
Figura 6	Diagrama de Integração de Dados com LangChain	41
Figura 7	Definição das Funções de Pertinência	49
Figura 8	Visualização das Funções de Pertinências	50
Figura 9	Representação Gráfica das Funções de Pertinência	51
Figura 10	Conjunto Fuzzy Aplicado para Qualidade de Vida	52
Tabela 1	Variável Linguística: Grau de Deficiência	44
Tabela 2	Variável Linguística: Necessidade de Suporte	45
Tabela 3	Variável Linguística: Qualidade de Vida	45

# Sumário

<b>AGRADECIMENTOS</b>	5
<b>RESUMO</b>	6
<b>ABSTRACT</b>	7
<b>LISTA DE SIGLAS</b>	8
<b>LISTA DE ILUSTRAÇÕES E TABELAS</b>	9
<b>1. INTRODUÇÃO</b>	13
1.1. RELEVÂNCIA DO TEMA	14
1.2. PROBLEMA DE PESQUISA	15
1.3. HIPÓTESE(S)	15
1.4. JUSTIFICATIVA	15
1.5. OBJETIVOS	16
1.5.1. Objetivo Geral	16
1.5.2. Objetivos Específicos	17
<b>2. REFERENCIAL TEÓRICO</b>	18
2.1. DEFICIÊNCIA INTELECTUAL	18
2.1.1. Deficiência Intelectual e Inclusão Social	18
2.1.2. Avaliação Funcional de Pessoas com Deficiência	19
2.2. INTELIGÊNCIA ARTIFICIAL	20
2.3. LÓGICA FUZZY	22
2.3.1. Aplicações da Lógica Fuzzy	22
2.3.2. Lógica Fuzzy na Educação Inclusiva	24
2.3.3. Benefícios e Desafios da Lógica Fuzzy	24
2.4. REDES NEURAIS ARTIFICIAIS	24
2.4.1. Camada de Entrada	26
2.4.2. Camada Oculta	28

2.4.3. Camada de Saída	29
2.4.4. Exemplos Práticos de Aplicações	30
2.5. TECNOLOGIA <i>LANGCHAIN</i>	39
2.5.1. Aplicações na Educação Inclusiva	39
2.5.2. Vantagens e Desafios do LangChain	41
2.6. MÉTODOS DE TOMADA DE DECISÃO MULTICRITÉRIO	41
2.7. APLICAÇÃO DO ESTUDO	42
<b>3. APLICAÇÃO DO ESTUDO</b>	<b>43</b>
3.1. Contexto Educacional	44
3.2. Inclusão Educacional	45
3.3. Tomada de Decisão Multicritério	45
3.4. Expansão para Outras Áreas	45
3.5. Futuras Implementações e Melhorias	46
3.6. Objeto do estudo	46
<b>4. ANÁLISE DE RESULTADOS E DISCUSSÕES</b>	<b>55</b>
5.2. Integração e Automação de Dados com <i>LangChain</i>	55
5.3. Comparação com Métodos Tradicionais	56
5.4. Discussão das Implicações Educacionais	56
5.5. Limitações do Estudo	56
5.6. Recomendações para Pesquisas Futuras	57
<b>5. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS</b>	<b>58</b>
5.1. CONSIDERAÇÕES FINAIS	58
5.2. TRABALHOS FUTUROS	59
6.2.1. Validação do Modelo em Diferentes Contextos Educacionais	59
6.2.2. Integração com Outras Tecnologias Emergentes	60
6.2.3. Desenvolvimento de Ferramentas de Apoio para Educadores	60
6.2.4. Expansão para Outras Áreas de Aplicação	60

6.2.5. Estudo do Impacto a Longo Prazo	60
6.2.6. Exploração de Aspectos Éticos e Sociais	61
<b>REFERÊNCIAS</b>	62
<b>APÊNDICE A</b>	65
<b>APÊNDICE B</b>	67

## 1. INTRODUÇÃO

Nas últimas décadas, a sociedade tem experimentado uma crescente conscientização sobre a importância da inclusão de pessoas com deficiência em todos os aspectos da vida social, educacional e profissional (Mazzotta e D'Antino, 2011). Este movimento inclusivo reflete um avanço significativo nas práticas e políticas que buscam garantir a igualdade de oportunidades e a valorização da diversidade (Schalock et al., 2007). Dentro desse contexto, a avaliação funcional de pessoas com deficiência emerge como uma ferramenta essencial para identificar e atender às necessidades específicas desses indivíduos, promovendo sua plena participação e autonomia (Aranha, 2001).

A presente dissertação se insere nesse cenário ao explorar o desenvolvimento de um modelo de tomada de decisão multicritério, utilizando uma abordagem integrada de lógica *fuzzy*, redes neurais artificiais e a tecnologia *LangChain*. O objetivo central é criar um sistema que possa lidar com a incerteza e a subjetividade dos dados, oferecendo uma avaliação mais precisa e personalizada das necessidades funcionais de pessoas com deficiência, especialmente no contexto educacional.

A relevância deste estudo está diretamente ligada ao impacto positivo que modelos de avaliação mais sofisticados podem ter na qualidade de vida das pessoas com deficiência. Ao permitir uma compreensão mais profunda e detalhada de suas necessidades, essas ferramentas podem orientar a criação de ambientes mais acessíveis e inclusivos, tanto nas escolas quanto em outras esferas sociais.

Nesta dissertação, além de apresentar uma revisão teórica abrangente sobre lógica *fuzzy*, redes neurais e métodos de tomada de decisão multicritério, desenvolve-se uma metodologia que combina pesquisa bibliográfica e um estudo de caso prático. O estudo é realizado em uma instituição educacional, onde o modelo proposto é testado e avaliado, permitindo uma análise detalhada dos dados coletados.

Os resultados alcançados apontam para a eficácia da combinação de lógica *fuzzy* e redes neurais, aprimorada pela tecnologia *LangChain*, na melhoria da precisão e da eficácia das avaliações funcionais. Além disso, o modelo se mostra flexível e adaptável, podendo ser aplicado em diferentes contextos e populações. A pesquisa enfatiza a importância de abordagens personalizadas para a inclusão educacional e oferece uma ferramenta prática para educadores e profissionais de saúde.

Por fim, este trabalho não apenas contribui para uma melhor compreensão das necessidades das pessoas com deficiência, mas também promove uma inclusão mais eficaz e humanizada. Espera-se que os resultados deste estudo possam inspirar futuras pesquisas e desenvolvimentos na área, incentivando a exploração de novas tecnologias e metodologias para aprimorar a qualidade da educação e da inclusão social.

## 1.1. RELEVÂNCIA DO TEMA

A importância da inclusão social e educacional de pessoas com deficiência é um tema amplamente reconhecido e discutido na sociedade contemporânea. Com a crescente consciência sobre os direitos humanos e a igualdade de oportunidades, há uma demanda crescente por práticas que garantam a participação plena de todos os indivíduos, independentemente de suas limitações físicas, sensoriais ou cognitivas (MAZZOTTA e D'ANTINO, 2011).

Neste contexto, a avaliação funcional de pessoas com deficiência surge como uma ferramenta crucial para identificar suas necessidades específicas e adaptar ambientes e serviços para melhor atendê-las. A precisão e a personalização dessas avaliações podem fazer uma diferença significativa na qualidade de vida desses indivíduos, proporcionando-lhes maior autonomia e participação ativa na sociedade.

O desenvolvimento do modelo proposto nesta dissertação, que utilizam lógica *fuzzy* e redes neurais artificiais, representa um avanço significativo no campo da avaliação funcional. Esses modelos não apenas lidam de maneira eficaz com a incerteza e a subjetividade dos dados, mas também oferecem uma análise mais detalhada e personalizada das necessidades de cada pessoa. A introdução de tecnologias como o *LangChain* potencializa ainda mais esses processos, proporcionando resultados mais precisos e relevantes.

A relevância deste estudo está, portanto, em sua contribuição para o avanço das práticas inclusivas, especialmente no âmbito educacional. Ao oferecer uma ferramenta prática para a avaliação funcional, o trabalho promove uma compreensão mais profunda das necessidades dos estudantes com deficiência, permitindo a criação de ambientes de aprendizado mais inclusivos e adaptados. Isso, por sua vez, pode levar a melhores resultados educacionais e sociais, fortalecendo o compromisso com uma sociedade mais justa e equitativa.

Portanto, a relevância do tema consiste na sua capacidade de influenciar positivamente a vida de pessoas com deficiência, oferecendo-lhes as ferramentas e o suporte necessários para

alcançar seu potencial. Além disso, a pesquisa contribuiu para o desenvolvimento acadêmico e científico, abrindo caminhos para futuras investigações e inovações tecnológicas que possam continuar aprimorando as práticas de inclusão.

## 1.2. PROBLEMA DE PESQUISA

Como desenvolver um algoritmo *fuzzy* eficaz, utilizando métodos matemáticos e computacionais, que pudesse ser emulado em uma rede neural artificial e combinado com a técnica de *stack LangChain*, para atuar na tomada de decisão multicritério em cenários complexos?

## 1.3. HIPÓTESE(S)

Há hipóteses que a aplicação de algoritmos *fuzzy*, combinados com a emulação de redes neurais, baseada pela tecnologia *LangChain*, resulta em uma melhoria significativa na precisão da tomada de decisão multicritério, especialmente para a avaliação de especificidades funcionais de pessoas com deficiência.

## 1.4. JUSTIFICATIVA

A relevância desta pesquisa é multifacetada e abrange diversos aspectos importantes. Para a organização, o desenvolvimento de um modelo de tomada de decisão representa um avanço significativo na inclusão educacional de pessoas com deficiência, permitindo uma avaliação mais precisa de suas necessidades funcionais, o que justificou o desenvolvimento dessa dissertação.

Neste contexto, o modelo pode transformar a forma como as instituições educacionais e os profissionais de saúde abordam a inclusão, garantindo que os métodos de ensino e os recursos pedagógicos sejam adequados às necessidades individuais dos alunos.

Como pesquisador, esta dissertação tornou-se uma oportunidade valiosa para aprofundar meus conhecimentos em algoritmos avançados de tomada de decisão, redes neurais e explorar o potencial da *stack LangChain*. A aplicação prática dessas tecnologias em um contexto tão relevante é um desafio estimulante, que contribui para meu crescimento acadêmico e profissional.

Do ponto de vista da comunidade acadêmica, esta dissertação apresenta uma metodologia para a aplicação de lógica *fuzzy* e redes neurais, a problemas complexos, incentivando futuras pesquisas e desenvolvimentos nessa área. O uso da *stack LangChain* é especialmente relevante, pois oferece a capacidade de integrar diversas fontes de dados e automatizar processos complexos, tornando a análise de dados mais eficiente e precisa. Além disso, *LangChain* facilita a criação de interfaces intuitivas, melhorando a experiência dos usuários e promovendo uma interação mais eficaz com o sistema.

A combinação dessas tecnologias, lógica *fuzzy*, redes neurais e *LangChain*, promete fornecer uma solução abrangente e robusta para a avaliação funcional de pessoas com deficiência. Isso promove uma inclusão mais eficaz e personalizada, ajudando a adaptar métodos de ensino e recursos pedagógicos às necessidades específicas de cada aluno. Este modelo tem o potencial de ser uma ferramenta valiosa para instituições educacionais e profissionais de saúde, proporcionando uma abordagem mais individualizada e equitativa.

Adicionalmente, o projeto está alinhado com os princípios do Estatuto da Pessoa com Deficiência, estabelecido pela Lei nº 13.146, de 6 de julho de 2015 (BRASIL, 2015). Esta legislação é um marco importante na garantia dos direitos das pessoas com deficiência no Brasil, promovendo sua inclusão social e cidadania plena. A lei assegura direitos fundamentais em diversas áreas, como educação, saúde, trabalho e acessibilidade, buscando eliminar barreiras e promover a igualdade de oportunidades. O Estatuto reforça a importância da acessibilidade, não apenas em termos de infraestrutura física, mas também na comunicação e nos serviços, assegurando que as pessoas com deficiência possam participar plenamente da sociedade.

O compromisso com a efetiva implementação da Lei nº 13.146/2015 envolve desafios significativos, incluindo a adaptação de infraestruturas e a formação de profissionais capacitados. A conscientização da sociedade sobre os direitos das pessoas com deficiência é igualmente crucial para promover uma cultura de inclusão.

## 1.5. OBJETIVOS

### 1.5.1. Objetivo Geral

Desenvolver um modelo *fuzzy* que integre a emulação de redes neurais e a tecnologia *LangChain* para a tomada de decisão multicritério na avaliação de especificidades funcionais de pessoas com deficiência.

### 1.5.2. Objetivos Específicos

- Identificar e compreender as diversas particularidades dos alunos com deficiência, para que possam ser consideradas na avaliação funcional e na elaboração de estratégias de inclusão.
- Desenvolver um sistema capaz de processar informações que não são absolutamente verdadeiras ou falsas, mas que possuem graus de verdade, permitindo uma análise mais detalhada e realista das condições dos indivíduos.
- Utilizar algoritmos de redes neurais artificiais para aprimorar a capacidade do modelo de identificar padrões e relações complexas nos dados, aumentando a precisão das avaliações.
- Utilizar a *stack LangChain* para facilitar a integração de diversas fontes de dados e automatizar processos, melhorando a eficiência e a precisão da análise de dados.
- Aplicar o modelo proposto em um ambiente real para avaliar sua eficácia e adequação às necessidades de avaliação funcional de pessoas com deficiência.
- Avaliar a performance do novo modelo em comparação com as metodologias tradicionais, para determinar sua superioridade ou identificar áreas para melhorias.

## 2. REFERENCIAL TEÓRICO

### 2.1. DEFICIÊNCIA INTELECTUAL

A Deficiência Intelectual (DI) é uma condição complexa que resulta em dificuldades prolongadas para os indivíduos afetados. Essas dificuldades, quando interagem com várias barreiras sociais e ambientais, podem impedir a plena e efetiva participação dessas pessoas na sociedade, em igualdade de condições com outras. Esta definição está alinhada com a Convenção Internacional sobre os Direitos das Pessoas com Deficiência, da qual o Brasil é signatário (ONU, 2006).

Na Classificação Internacional de Doenças e Problemas Relacionados à Saúde, o termo "deficiência intelectual" é equivalente a "retardo mental". Conforme a nova Classificação Internacional de Doenças, a DI é classificada entre os distúrbios do neurodesenvolvimento, particularmente no desenvolvimento intelectual, abrangendo uma ampla gama de condições com causas específicas. Sua definição envolve múltiplos aspectos relacionados ao conceito de inteligência e deve ser sempre considerada como parte de uma avaliação global do indivíduo.

#### 2.1.1. Deficiência Intelectual e Inclusão Social

A DI é caracterizada por uma redução significativa das funções intelectuais, acompanhada por déficits no comportamento adaptativo, incluindo limitações em habilidades sociais e práticas cotidianas, manifestando-se antes dos 18 anos (OMS, 1993).

A história da deficiência intelectual é marcada por significativas mudanças na maneira como a sociedade percebe e interage com as pessoas que possuem essa condição. O desenvolvimento de definições e abordagens em relação à deficiência intelectual reflete uma evolução nas percepções sociais, políticas e científicas ao longo do tempo. A *American Association on Mental Retardation* (AAMR), atualmente conhecida como *American Association on Intellectual and Developmental Disabilities* (AAIDD), desempenhou um papel crucial na definição e classificação da deficiência intelectual. Em sua 10ª edição de "Retardo mental: definição, classificação e sistemas de apoio", a deficiência intelectual é definida como uma condição caracterizada por limitações tanto no funcionamento intelectual quanto no comportamento adaptativo, manifestando-se em habilidades conceituais, sociais e práticas (AAIDD, 2006). Essa definição enfatiza a importância de sistemas de apoio individualizados para melhorar a qualidade de vida das pessoas com deficiência intelectual.

No contexto brasileiro, Marcia Silva de Freitas Aranha tem contribuído significativamente para o entendimento da deficiência intelectual. Em suas análises conceituais e metodológicas sobre a integração social de pessoas com deficiência, discute como a sociedade evoluiu de um paradigma de segregação para um de integração e, mais recentemente, para inclusão. Em outro trabalho, ela aborda os diferentes paradigmas da relação da sociedade com pessoas com deficiência, destacando a necessidade de um modelo que reconheça a igualdade de direitos e a plena participação dessas pessoas na vida social (Aranha, 1995; Aranha, 2001).

A inclusão de alunos com deficiência intelectual em escolas regulares também tem sido um tema de intenso debate e desenvolvimento. Bueno (2001) argumenta que a inclusão desses alunos em classes comuns do ensino regular representa um desafio que requer uma transformação significativa na abordagem pedagógica e na estrutura escolar. De acordo com Beyer (2005), o projeto político-pedagógico da educação inclusiva, refletindo sobre a gestão educacional e suas implicações para a educação especial. Ele enfatiza que a inclusão efetiva de alunos com deficiência intelectual nas escolas regulares exige uma gestão educacional que promova a capacitação de professores e o desenvolvimento de práticas pedagógicas inclusivas.

A pesquisa de Capellini (2004) sobre o ensino colaborativo no processo de inclusão escolar de alunos com deficiência mental destaca a importância da colaboração entre educadores para criar um ambiente de aprendizagem mais inclusivo e eficaz. Em sua tese de doutorado na Universidade Federal de São Carlos, Capellini explora as possibilidades e desafios do ensino colaborativo, oferecendo insights valiosos para a prática educacional.

Em síntese, a história da deficiência intelectual revela uma trajetória de crescente reconhecimento e valorização dos direitos das pessoas com deficiência. Desde as primeiras definições e classificações até os esforços contemporâneos de inclusão, observa-se uma evolução contínua na busca por uma sociedade mais justa e inclusiva.

### 2.1.2. **Avaliação Funcional de Pessoas com Deficiência**

A avaliação das especificidades funcionais de pessoas com deficiência é um campo multidisciplinar que abrange aspectos educacionais, sociais e tecnológicos. O objetivo dessa avaliação é identificar as necessidades individuais de cada pessoa, fornecendo o suporte adequado para promover sua inclusão e participação plena na sociedade.

No contexto educacional, essa avaliação é crucial para adaptar métodos de ensino e recursos pedagógicos de acordo com as necessidades específicas dos alunos, garantindo que todos tenham acesso a uma educação de qualidade.

Estudos realizados por Schalock et al. (2007) e Wehmeyer et al. (2008) ressaltam a importância de abordagens personalizadas e baseadas em evidências na avaliação funcional. Essas pesquisas destacam a necessidade de desenvolver modelos que possam integrar múltiplos critérios e lidar com a variabilidade dos dados coletados, o que é fundamental para obter uma avaliação precisa e abrangente. Essas abordagens são particularmente relevantes para capturar a diversidade das necessidades e capacidades dos indivíduos, permitindo uma compreensão mais holística de suas situações.

Além disso, a literatura enfatiza o papel das tecnologias avançadas na melhoria dos processos de avaliação funcional. Tecnologias como redes neurais e lógica *fuzzy* têm se mostrado eficazes na análise de dados complexos e na formulação de avaliações mais precisas. Essas ferramentas não apenas facilitam a coleta e interpretação de dados, mas também promovem uma educação mais inclusiva, ao permitir que as avaliações sejam feitas de forma mais dinâmica e adaptável às mudanças nas condições dos alunos.

## 2.2. INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é uma das áreas mais dinâmicas e influentes da ciência da computação, dedicada à criação de sistemas e tecnologias que simulam a inteligência humana, pois a IA envolve o desenvolvimento de algoritmos e modelos que permitem que as máquinas realizem tarefas que tradicionalmente exigiriam intervenção humana, como reconhecimento de padrões, processamento de linguagem natural, aprendizado e tomada de decisões complexas.

Desde sua concepção, a IA passou por diversas fases de evolução, começando com os primeiros algoritmos baseados em regras até chegar às sofisticadas redes neurais e sistemas de aprendizado profundo (*deep learning*) que conhecemos hoje (Russell e Norvig, 2010).

O aprendizado de máquina, um subcampo da IA, desempenha um papel central nesse desenvolvimento, permitindo que os sistemas extraiam padrões e insights de grandes volumes de dados, aprendendo e melhorando sem a necessidade de programação explícita para cada tarefa.

De acordo com Ferreira (2022, p. 18):

A Inteligência Artificial está fundamentada em simular o comportamento e a capacidade humana de solucionar e decidir situações complexas, visto que sua grande vantagem está na capacidade de alto desempenho de processamento que é exponencialmente superior ao do ser humano.

No contexto educacional, a IA tem se mostrado particularmente promissora, pois as aplicações de IA voltadas para a educação incluem desde sistemas tutores inteligentes, que oferecem instrução personalizada, até ferramentas avançadas de análise de dados que ajudam os educadores a identificarem tendências e necessidades dos discentes. Por exemplo, plataformas de *e-learning* podem usar IA para adaptar automaticamente o conteúdo ao ritmo de aprendizado de cada aluno, garantindo que aqueles que necessitam de mais apoio recebam intervenções adequadas em tempo hábil.

Outrossim, a IA facilita a inclusão educacional de alunos com deficiência, visto que podem ser usadas para criar materiais didáticos acessíveis, como leitores de tela para alunos com deficiência visual ou tradutores automáticos de linguagem de sinais. Ferramentas de IA também possibilitam monitorar o progresso de alunos com deficiência em tempo real, ajustando as estratégias de ensino para atender melhor às suas necessidades específicas, o que colabora consideravelmente para a melhora do desempenho acadêmico desses alunos, promovendo sua participação mais ativa no ambiente escolar.

Outra aplicabilidade relevante da IA no contexto educacional é a análise preditiva que possui potencial promissor, utilizando-se de algoritmos de aprendizado de máquina para examinar grandes volumes de dados educacionais, identificar padrões e prever comportamentos ou resultados futuros. De acordo com Baker e Siemens (2014), com a capacidade de processar e analisar grandes volumes de dados históricos e em tempo real, a IA pode prever quais alunos estão em risco de baixo desempenho ou evasão escolar, permitindo que educadores e administradores intervenham de forma preventiva. Essas previsões são baseadas em uma análise complexa de múltiplos fatores, incluindo frequência escolar, participação em atividades extracurriculares, e desempenho acadêmico anterior.

Em termos de ética e impacto social, o uso de IA na educação também levanta importantes questões, visto que é crucial garantir que os sistemas de IA sejam projetados e implementados de forma a respeitar a privacidade dos alunos e a evitar vieses que possam prejudicar grupos

específicos. Isso exige uma abordagem cuidadosa e equilibrada, onde os benefícios da IA sejam maximizados sem comprometer os princípios éticos fundamentais.

De fato, a integração da IA na educação não se limita à personalização do aprendizado e à inclusão, sendo também utilizada para otimizar a gestão escolar, automatizando tarefas administrativas e fornecendo insights sobre a eficiência dos processos educacionais, visto que possibilita a liberação de tempo e recursos, permitindo que educadores e administradores se concentrem mais na qualidade do ensino e na experiência de aprendizado dos alunos.

Em suma, a inteligência artificial tem o potencial de transformar profundamente o campo da educação, oferecendo ferramentas poderosas para personalização, inclusão e gestão. No entanto, a implementação eficaz da IA requer uma compreensão aprofundada de suas capacidades e limitações, bem como um compromisso contínuo com a ética e a equidade.

### 2.3. LÓGICA FUZZY

A lógica *fuzzy*, introduzida por Lotfi Zadeh em 1965, representa um marco na evolução da lógica matemática ao permitir o trabalho com conceitos de verdade parcial, diferentemente da lógica booleana tradicional, que opera com valores binários (verdadeiro ou falso), a lógica *fuzzy* lida com graus de verdade que variam entre 0 e 1, proporcionando uma maneira mais realista de modelar situações em que a precisão absoluta não é possível ou prática (ZADEH, 1965).

Conforme afirmam Luz e Boente (2024, p. 11), diferente da lógica binária que referencia os valores 0 e 1, a lógica *fuzzy* opera com valores contínuos no intervalo entre 0 e 1, inclusive, permitindo uma modelagem mais realista de situações do mundo real e é representada pelas seguintes características principais: Graus de verdade, Funções de pertinência, operações *fuzzy*, regras *fuzzy* e regras de inferência.

Estas regras ajudam no processo de tomada de decisão em sistemas complexos, que apresentam subjetividade e incertezas e que, por essa razão, a aplicação da lógica *fuzzy*.

#### 2.3.1. Aplicações da Lógica Fuzzy

Um pesquisador polonês Jan Lukasiewicz (1878-1956), introduziu as primeiras noções de lógica dos conceitos “vagos” a partir da apresentação dos conjuntos com graus de pertinência

0,  $\frac{1}{2}$  e 1, expandindo mais tarde este conjunto para um número infinito de valores compreendidos no intervalo entre 0 e 1 (BOENTE, 2013, p. 71).

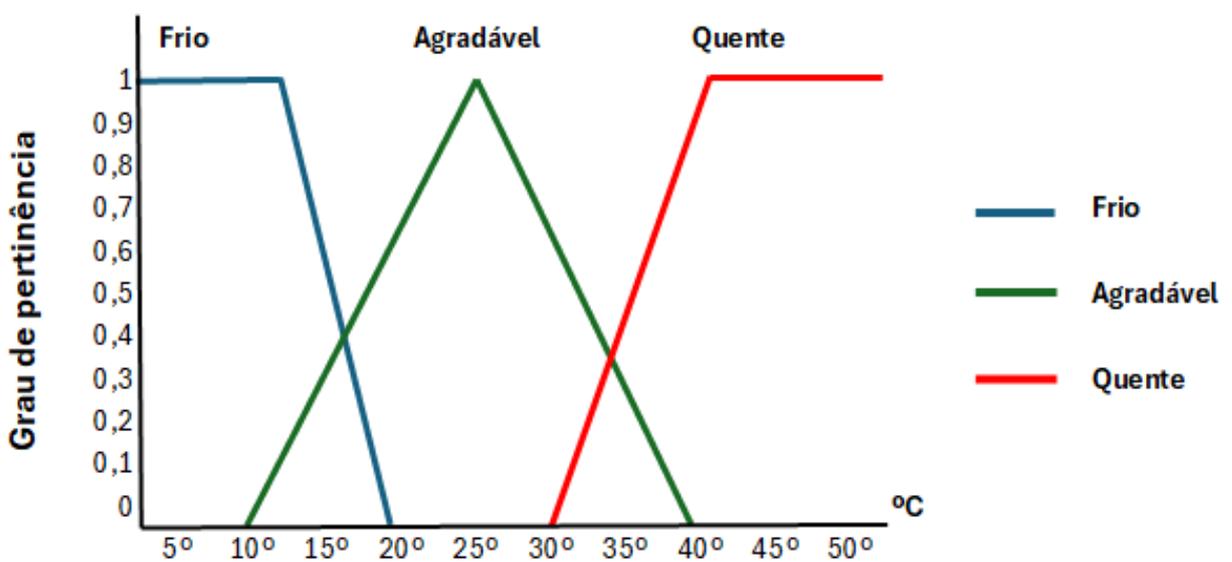
Os conjuntos *fuzzy* podem ser vistos como uma generalização da noção de conjunto na qual a função de pertinência pode assumir valores no intervalo entre 0 e 1, diferentemente da lógica clássica que entende valores como 0 ou 1.

A primeira publicação oficial sobre lógica *fuzzy* ocorreu no ano de 1965 por Lotfi Asker Zadeh, onde ele combinava os conceitos da lógica clássica e os conjuntos de Lukasiewicz, definindo, de forma mais concreta os graus de pertinência, formalizando, portanto, o que anos depois vinha a ser uma das maiores revoluções no setor matemático: a lógica *fuzzy* ou lógica nebulosa ou lógica difusa.

De acordo com Cosenza et al. (2006), esta teoria trata dos conjuntos não totalmente verdadeiros nem tampouco dos totalmente falsos devendo, portanto, a lógica *fuzzy* ser vista como uma teoria matemática formal para a representação de incertezas.

A lógica *fuzzy* é amplamente aplicada em várias áreas devido à sua habilidade de lidar com dados ambíguos e incompletos. Um exemplo clássico é o controle de temperatura em sistemas de aquecimento, onde a lógica *fuzzy* permite ajustes suaves e graduais, respondendo às variações de temperatura de forma mais natural e eficiente, conforme ilustrado na Figura 1.

**Figura 1** - Controle de Temperatura com Lógica Fuzzy



Fonte: LIMA e BOENTE (2024)

Por meio da ilustração da Figura 1 é possível observar como diferentes estados de temperatura são processados de forma contínua, permitindo um ajuste dinâmico que resulta em um ambiente mais estável e confortável. Isso contrasta com sistemas tradicionais, que operam em modos binários, ligando e desligando abruptamente.

### 2.3.2. Lógica Fuzzy na Educação Inclusiva

No campo da educação inclusiva, a lógica *fuzzy* tem se mostrado especialmente útil para avaliar as necessidades funcionais de alunos com deficiência. Ao contrário das abordagens tradicionais, que podem ser rígidas, a lógica *fuzzy* permite a consideração de uma gama mais ampla de respostas e condições, permitindo uma avaliação mais personalizada e eficaz.

### 2.3.3. Benefícios e Desafios da Lógica Fuzzy

A lógica *fuzzy* oferece flexibilidade e adaptabilidade em contextos em que a precisão absoluta é inatingível ou desnecessária. No entanto, definir corretamente as regras *fuzzy* e as funções de pertinência é crucial para o sucesso da aplicação. Isso exige uma compreensão profunda tanto do problema em questão quanto dos dados disponíveis.

Um ponto a ser considerado está na integração de sistemas *fuzzy* com outras tecnologias avançadas, como redes neurais artificiais, que pode ser bem desafiador, mas oferece grande potencial para a criação de sistemas altamente eficientes e adaptativos.

A lógica *fuzzy* é, portanto, uma ferramenta poderosa para lidar com incertezas e subjetividades, especialmente em áreas como a educação inclusiva, onde as necessidades dos alunos variam amplamente. Sua aplicação pode transformar práticas pedagógicas, criando ambientes de aprendizagem melhor adaptados às necessidades de todos os alunos.

## 2.4. REDES NEURAIIS ARTIFICIAIS

As redes neurais artificiais (RNAs) são modelos computacionais que se baseiam na estrutura e no funcionamento do cérebro humano. Esses modelos são compostos por camadas de nós, também conhecidos como neurônios, que estão interconectados.

De acordo com Jang (1993), as RNAs processam informações e aprendem padrões a partir dos dados que recebem, permitindo que façam previsões ou classificações com base em novos dados. A integração de RNAs com lógica *fuzzy*, resulta em sistemas neuro-*fuzzy*, e apresenta

uma abordagem que une a capacidade de aprendizado das redes neurais artificiais com a habilidade de lidar com incerteza e imprecisão da lógica *fuzzy*.

Pesquisas conduzidas por Jang (1993) e Kosko (1992) demonstram que os sistemas neuro-*fuzzy* podem ser aplicados em uma variedade de áreas, como controle de processos, reconhecimento de padrões e previsão de séries temporais. Esses sistemas são particularmente eficazes porque conseguem capturar a complexidade dos dados e lidar com informações que não são perfeitamente precisas. A aplicação dessas tecnologias na avaliação funcional de pessoas com deficiência pode aumentar significativamente a precisão e a robustez dos resultados, oferecendo suporte efetivo para a tomada de decisões em contextos em que as necessidades dos indivíduos são complexas e variadas.

Além disso, estudos recentes têm explorado a combinação de redes neurais profundas (*deep learning*) com lógica *fuzzy*. Essa combinação visa aprimorar ainda mais a precisão dos modelos e sua capacidade de generalização, ou seja, a habilidade de um modelo aprendido de desempenhar bem em novos dados não vistos durante o treinamento.

Segundo Goodfellow, Bengio e Courville (2016), redes neurais profundas são conhecidas por suas várias camadas ocultas, que permitem a extração de características complexas dos dados, enquanto a lógica *fuzzy* adiciona a capacidade de lidar com incertezas e ambiguidades. Juntas, essas tecnologias têm o potencial de criar modelos altamente sofisticados e eficazes para uma ampla gama de aplicações, incluindo a avaliação funcional de pessoas com deficiência.

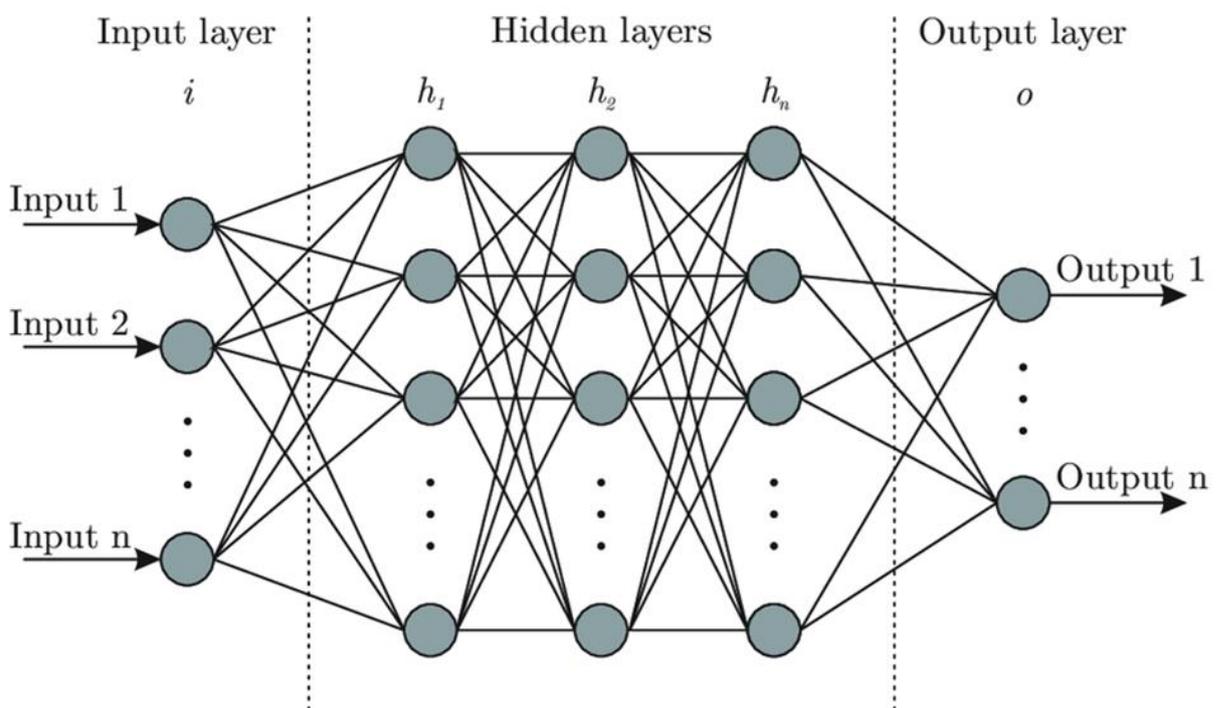
A pesquisa e desenvolvimento contínuos nessas áreas prometem melhorar ainda mais a precisão das avaliações e as decisões baseadas em dados, oferecendo soluções mais personalizadas e adequadas para atender às necessidades específicas de cada indivíduo.

A definição de uma arquitetura RNA inclui a determinação do número de entradas, saídas e informações ocultas. De acordo com Bre, Gimenez e Fachinotti (2018, p. 4), o teorema da aproximação universal afirma que uma rede *feed-forward* com uma única camada oculta contendo um número finito de neurônios pode aproximar-se de funções contínuas em subconjuntos compactos de  $\mathbb{R}^n$ , sendo  $n$  o número de entradas. No entanto, isso não significa que uma RNA com uma única camada oculta é ideal em termos de versatilidade, tempo de aprendizado e facilidade de implementação. Na verdade, dados os conjuntos de dados de entrada e de saída, não existe uma regra geral para definir a melhor arquitetura de RNA (número de neurônios e camadas ocultas).

Os autores propuseram um método para calibrar a arquitetura da RNA baseada em tentativa e erro de acordo com a complexidade de cada caso. Este método é composto por duas etapas: 1) uma calibração grosseira que é feita para determinar o número de camadas ocultas e 2) o treinamento com um aumentando número de neurônios ocultos (começando com alguns) até atingir o desempenho desejado.

A estrutura geral de uma rede neural artificial (RNA), conforme ilustrada na Figura 2, é composta por três tipos de camadas: camada de entrada, camadas ocultas e camada de saída.

**Figura 2** - Arquitetura de rede neural artificial (ANN ih 1-h 2-h no).



Fonte: BRE, GIMENEZ e FACHINOTTI (2018).

#### 2.4.1. Camada de Entrada

A camada de entrada de uma Rede Neural Artificial (RNA) desempenha um papel fundamental no processamento inicial dos dados. Esta camada serve como a interface entre os dados brutos recebidos do mundo exterior e o processamento subsequente realizado pelas camadas ocultas da rede. Sua principal função é converter esses dados em um formato que possa ser manipulado internamente pela RNA. Esse processo de conversão é crucial, pois a eficácia do sistema depende diretamente da precisão e da representatividade dos dados introduzidos na rede.

Para tarefas como a classificação de imagens, a camada de entrada é essencial. Cada imagem é composta por uma matriz de pixels, onde cada pixel representa uma unidade da imagem, geralmente em termos de intensidade de cor ou tons de cinza. Por exemplo, uma imagem digital de 28x28 pixels contém 784 pixels, sendo que cada pixel pode ser visto como uma característica individual que contribui para a representação completa da imagem. Assim, a camada de entrada de uma RNA projetada para processar tais imagens consistiria em 784 neurônios, com cada neurônio recebendo o valor de um pixel específico.

Os neurônios de entrada não realizam processamento complexo; eles simplesmente transmitem as informações recebidas para as camadas ocultas subsequentes. No entanto, é vital que esses dados de entrada sejam corretamente normalizados ou padronizados, conforme o tipo de RNA utilizada. A normalização é o processo de ajustar os dados para que eles se encaixem em uma faixa específica, geralmente entre 0 e 1 ou -1 e 1. Isso é importante para evitar que certas entradas tenham uma influência desproporcional na saída da rede, facilitando o aprendizado e a convergência do modelo (BRE, GIMENEZ e FACHINOTTI, 2018).

Além das imagens, a camada de entrada pode ser adaptada para lidar com diferentes tipos de dados, como texto, som ou séries temporais. No caso de dados textuais, por exemplo, cada palavra ou caractere pode ser convertido em uma representação numérica, como vetores de palavras ou *embeddings*, antes de serem alimentados na camada de entrada. Para dados de áudio, características extraídas, como espectrogramas, podem servir como entradas. Cada tipo de dado requer uma abordagem específica de pré-processamento para garantir que as informações relevantes sejam capturadas e transmitidas adequadamente para as camadas ocultas.

Outro aspecto importante que a camada de entrada precisa considerar é o problema de dimensionamento. Em aplicações práticas, as imagens ou outros tipos de dados podem variar significativamente em tamanho ou formato. Para que uma RNA funcione de forma eficaz, é necessário que os dados de entrada sejam dimensionados de maneira uniforme. Por exemplo, uma rede treinada com imagens de 28x28 pixels não pode processar diretamente uma imagem de 50x50 pixels sem algum tipo de ajuste ou redimensionamento. Essa uniformidade garante que a RNA possa aplicar os mesmos pesos e cálculos em cada unidade de dados de forma consistente.

Além disso, a camada de entrada pode incluir informações contextuais ou metadados. Em alguns casos, informações adicionais sobre os dados, como idade do paciente, histórico médico ou sintomas em um sistema de diagnóstico médico, podem ser inseridas como entradas adicionais para a rede. Isso permite uma análise mais abrangente e contextual, melhorando a precisão do modelo.

De fato, a camada de entrada estabelece a base para o treinamento e o aprendizado da RNA. Durante o treinamento, os pesos associados às conexões entre a camada de entrada e as camadas ocultas são ajustados para minimizar o erro entre as previsões da rede e os resultados reais. Esse processo iterativo de ajuste de pesos, baseado em técnicas como retropropagação e otimização de gradiente, é essencial para que a rede aprenda a reconhecer padrões e faça previsões precisas. Portanto, a qualidade e a forma dos dados fornecidos na camada de entrada têm um impacto direto na capacidade da RNA de aprender e generalizar a partir dos dados de treinamento.

#### 2.4.2. Camada Oculta

As camadas ocultas de uma rede neural artificial são essenciais para o processo de aprendizado, pois é nelas que ocorre a "magia" da extração de características complexas dos dados. Essas camadas funcionam como filtros que aprendem a identificar padrões ou características específicas nos dados de entrada. À medida que os dados passam por várias transformações em diferentes camadas ocultas, são refinados, permitindo que a rede capte nuances e detalhes que podem não ser evidentes nas camadas iniciais.

Segundo Bre, Gimenez e Fachinotti (2018), cada camada oculta é composta por neurônios artificiais que recebem entradas das camadas anteriores, processam essas informações aplicando funções de ativação não-lineares e transmitem o resultado para a próxima camada. Esse processo iterativo possibilita que a rede construa uma representação hierárquica dos dados, em que as camadas superiores representam características mais abstratas e complexas, enquanto as camadas inferiores capturam padrões mais simples e locais.

Dois parâmetros críticos para determinar a capacidade da rede de aprender características complexas são a profundidade da rede, ou seja, o número de camadas ocultas, e a largura, que se refere ao número de neurônios em cada camada. Redes mais profundas e largas podem, teoricamente, aprender representações mais ricas e sofisticadas dos dados. No entanto, essa complexidade aumentada também traz o risco de sobreajuste, um fenômeno em que a rede se

torna excessivamente ajustada aos detalhes do conjunto de treinamento, perdendo sua capacidade de generalizar para novos dados não vistos.

O sobreajuste é um problema comum nas redes neurais, mas pode ser mitigado por várias técnicas, como a regularização, que adiciona uma penalidade ao custo total do modelo para desencorajar a aprendizagem de padrões muito específicos dos dados de treinamento; o *dropout*, que consiste em desligar aleatoriamente uma fração dos neurônios durante o treinamento para evitar a dependência excessiva de neurônios individuais; e o uso de conjuntos de validação, que ajudam a monitorar o desempenho da rede em dados que não foram usados durante o treinamento.

Portanto, o equilíbrio entre a profundidade e a generalização é fundamental para o sucesso do aprendizado em redes neurais. Estruturas mais complexas exigem mais dados e cuidados durante o treinamento para garantir que a rede mantenha sua capacidade de generalização. Assim, evita-se o sobreajuste e maximiza-se a eficácia da rede em tarefas reais, assegurando que ela consiga aplicar o conhecimento adquirido em situações novas e não vistas anteriormente.

#### 2.4.3. Camada de Saída

A camada de saída em uma Rede Neural Artificial (RNA) é crucial, pois é responsável por fornecer o resultado final do processamento de dados realizado pela rede. Em uma rede de classificação, o número de neurônios na camada de saída corresponde ao número de classes que a rede está sendo treinada para prever. Cada neurônio na camada de saída representa uma classe distinta, e a ativação desses neurônios indica o nível de confiança da rede na presença daquela classe específica nos dados de entrada.

De acordo com Goodfellow, Bengio e Courville (2016), a ativação de um neurônio na camada de saída, após a aplicação de uma função de ativação como *softmax*, reflete a probabilidade de que a entrada pertence a uma classe específica. Essa função de ativação é especialmente importante em problemas de classificação multiclasse, pois transforma os valores de saída dos neurônios em probabilidades que somam 1. Isso facilita a interpretação e análise dos resultados, permitindo que se identifique com qual probabilidade a rede acredita que os dados de entrada pertencem a cada uma das classes possíveis.

Bishop (2006) também enfatiza a importância da camada de saída nas RNAs, destacando que a escolha da função de ativação e a estrutura da camada devem estar alinhadas com a natureza do problema a ser resolvido. Por exemplo, em problemas de regressão, onde o objetivo é prever um valor contínuo, a camada de saída geralmente utiliza uma função de ativação linear. Isso permite que a rede gere saídas que não são limitadas a uma faixa específica, o que é essencial para prever valores como preços, temperaturas ou outras medidas quantitativas.

A estrutura e o funcionamento da camada de saída são fundamentais para garantir que a rede não apenas aprenda a classificar corretamente as entradas durante o treinamento, mas também consiga generalizar esse aprendizado para novos dados. A capacidade de generalização é central para o sucesso das aplicações de aprendizado de máquina, pois uma rede que não consegue generalizar bem provavelmente falhará em fornecer resultados precisos quando confrontada com dados fora do conjunto de treinamento.

Dessa forma, a camada de saída desempenha um papel essencial na definição da saída final da RNA, influenciando diretamente a precisão e a eficácia das previsões ou classificações realizadas pela rede. A escolha adequada da função de ativação e o alinhamento da estrutura da camada de saída com o problema específico são aspectos críticos que devem ser considerados no design de redes neurais artificiais.

#### **2.4.4. Exemplos Práticos de Aplicações**

##### *2.4.4.1. Reconhecimento de Imagens*

As Redes Neurais Convolucionais (CNNs) têm revolucionado o campo da visão computacional, mostrando-se extremamente eficazes em tarefas de reconhecimento de imagens. Essas redes são projetadas para capturar e aprender padrões espaciais hierárquicos, o que as torna especialmente adequadas para identificar e classificar imagens complexas. Em uma CNN treinada para identificar objetos, as camadas iniciais são responsáveis por aprender a detectar bordas e texturas simples (LeCun, Bengio e Hinton, 2015). À medida que se avança para camadas mais profundas, a rede desenvolve a capacidade de reconhecer formas e objetos inteiros, permitindo uma compreensão mais precisa das imagens analisadas.

A capacidade das CNNs de aprender características de forma hierárquica as torna ideais para uma ampla gama de aplicações, incluindo reconhecimento facial, diagnóstico médico a partir de imagens e análise de vídeos. No reconhecimento facial, as CNNs podem identificar e

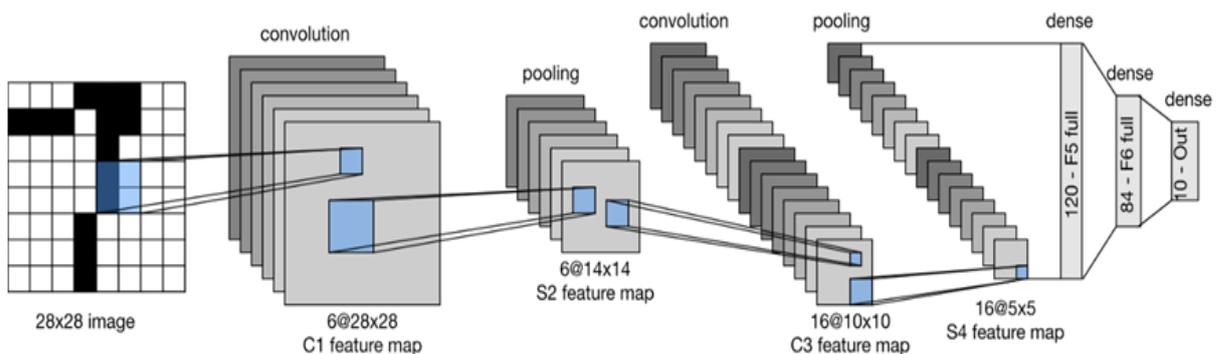
diferenciar rostos com alta precisão, mesmo diante de variações de iluminação, ângulos de visão e expressões faciais. No campo médico, essas redes são utilizadas para a análise de imagens, como radiografias e tomografias, auxiliando na detecção precoce de doenças e fornecendo suporte valioso para decisões clínicas. Na análise de vídeos, as CNNs são capazes de processar informações espaciais e temporais, facilitando a identificação de objetos e ações em sequências de vídeo.

A eficácia e a versatilidade das CNNs foram amplamente discutidas por LeCun, Bengio e Hinton (2015) no artigo "*Deep Learning*". Os autores destacam como essas redes têm sido aplicadas com sucesso em diversos domínios, proporcionando avanços significativos em áreas como segurança, medicina e entretenimento. As CNNs continuam a ser uma área de intensa pesquisa e desenvolvimento, com novas arquiteturas e técnicas surgindo para aprimorar ainda mais suas capacidades de processamento e reconhecimento de imagens.

A ilustração da Figura 3 representa a estrutura de uma Rede Neural Convolutiva (CNN), que é uma arquitetura de rede neural projetada para processar dados com um padrão de grade, como imagens. A CNN consiste em várias camadas especializadas, cada uma desempenhando um papel crucial no processamento da imagem de entrada.

A partir da imagem de entrada, esta é uma matriz de pixels onde cada célula representa um valor de pixel. As camadas convolucionais aplicam filtros pequenos (também chamados de *kernels*) à imagem de entrada para detectar características específicas, como bordas e texturas. Esses filtros se movem sobre a imagem, criando mapas de características que destacam as características detectadas.

**Figura 3** - Exemplo de Redes Neurais Convolucionais.



Fonte: Zhang et al. (2023)

Após a convolução, a imagem passa pelas camadas de *pooling*, que reduzem a dimensionalidade dos mapas de características. Isso é feito selecionando o valor máximo em pequenas regiões da imagem, uma técnica conhecida como *max pooling*. Esse processo reduz a complexidade computacional e ajuda a evitar o *overfitting*, preservando as características mais importantes.

Por fim, conforme afirmam (ZHANG et al., 2023), a informação é passada para as camadas totalmente conectadas, onde cada neurônio de uma camada está ligado a todos os neurônios da camada seguinte. Essas camadas usam as características extraídas pelas camadas anteriores para fazer a classificação final ou outra forma de previsão, dependendo do objetivo da rede. A camada de saída é onde a rede neural fornece seu resultado final, como a probabilidade de uma imagem pertencer a uma determinada classe.

#### 2.4.4.2. Processamento de Linguagem Natural (NLP)

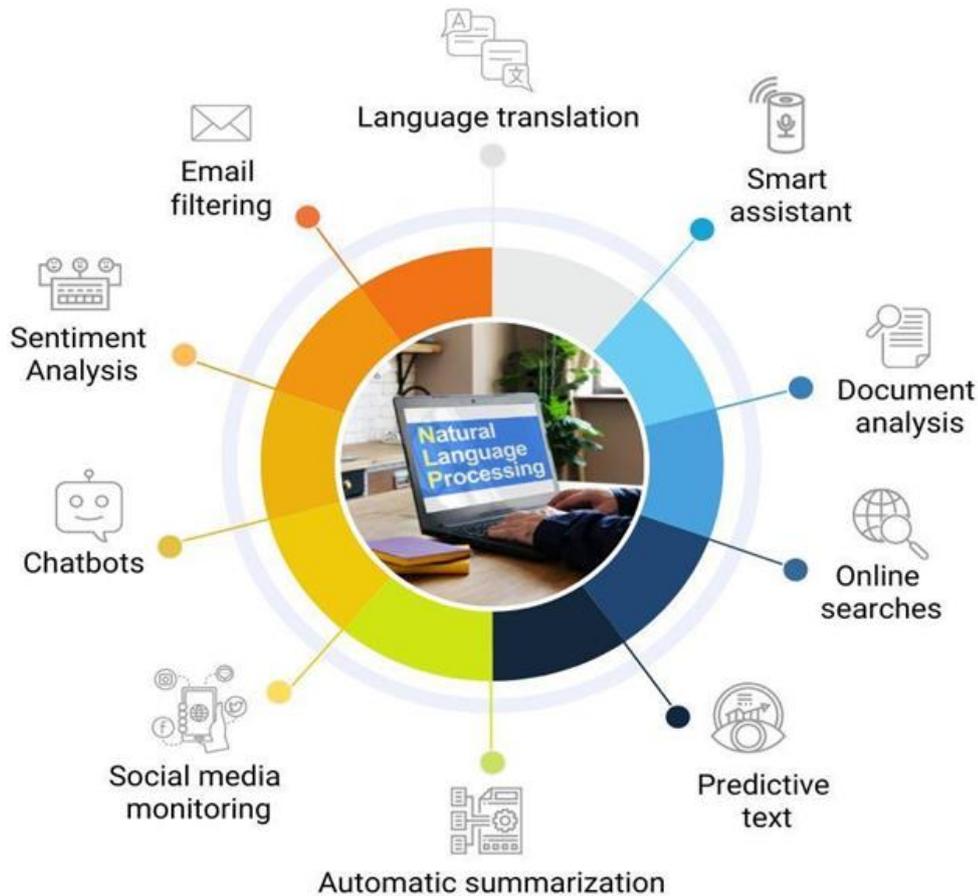
As Redes Neurais Artificiais (RNAs) têm uma ampla gama de aplicações no campo do Processamento de Linguagem Natural (NLP). Modelos avançados, como Transformers e suas variantes (por exemplo, BERT, GPT), demonstram uma capacidade impressionante de compreender o contexto e a semântica de textos. Essa compreensão é essencial para uma série de tarefas, incluindo tradução automática, resposta a perguntas e análise de sentimentos.

Os modelos de Transformers utilizam mecanismos de atenção, que permitem considerar a relação entre todas as palavras de uma frase simultaneamente. Isso resulta em uma compreensão mais rica e precisa do texto, capturando nuances e relações complexas que são cruciais para o processamento da linguagem. Por exemplo, em tarefas de tradução automática, esses modelos podem lidar com a variação significativa na estrutura e no contexto das frases entre diferentes idiomas, oferecendo traduções mais precisas e contextualmente adequadas.

Além disso, na resposta a perguntas, os modelos podem entender a pergunta e buscar a resposta em grandes volumes de texto, fornecendo respostas concisas e relevantes. Na análise de sentimentos, esses modelos são capazes de detectar emoções e opiniões expressas nos textos, identificando se o tom é positivo, negativo ou neutro. Essas aplicações têm um impacto significativo em áreas como atendimento ao cliente, marketing e monitoramento de mídias sociais.

O desenvolvimento contínuo de modelos de NLP baseados em RNAs continua a expandir as fronteiras do que é possível em termos de compreensão e geração de linguagem natural, tornando essas tecnologias cada vez mais integradas em diversas aplicações cotidianas.

**Figura 4** - Processamento em Linguagem Natural.



Fonte: ALAM (2022)

Conforme ilustra a Figura 4, várias aplicações do Processamento de Linguagem Natural (NLP), que é uma subárea da inteligência artificial focada na interação entre computadores e linguagem humana, são exemplificados.

A seguir, temos um detalhamento de cada aplicação mencionada na imagem.

**Email Filtering:** Algoritmos de NLP são utilizados para classificar e filtrar emails automaticamente, incluindo a detecção de spam, categorização de emails e filtragem de conteúdo indesejado. Isso melhora significativamente a eficiência na gestão de emails ao separar mensagens importantes de spam.

Exemplo de aplicação: Uma empresa utiliza filtros de email baseados em NLP para identificar e mover automaticamente emails de spam para a pasta apropriada. O sistema analisa o conteúdo dos emails, identificando características típicas de spam, como ofertas enganosas ou conteúdo não solicitado.

***Language Translation:*** Ferramentas de tradução automática utilizam NLP para traduzir texto entre diferentes idiomas. Modelos avançados, como o Google Translate, empregam redes neurais para fornecer traduções mais precisas e contextualmente adequadas, levando em consideração a estrutura e o contexto das frases nos idiomas de origem e destino.

Exemplo de aplicação: Um viajante utiliza o Google Translate para traduzir placas de rua e menus de restaurantes durante uma visita a um país estrangeiro. O aplicativo emprega NLP para interpretar e traduzir o texto capturado pela câmera do smartphone, facilitando a comunicação e compreensão do idioma local.

***Smart Assistant:*** Assistentes virtuais como Siri, Google Assistant e Alexa utilizam NLP para entender e responder a comandos de voz em linguagem natural. Eles interpretam as solicitações dos usuários e realizam ações como definir lembretes, responder perguntas e controlar dispositivos conectados.

Exemplo de aplicação: Um usuário pede à Alexa para tocar uma lista de reprodução específica ou ajustar a temperatura do termostato inteligente. O assistente virtual utiliza NLP para entender o comando de voz e executar a tarefa solicitada, integrando-se com dispositivos domésticos conectados.

***Document Analysis:*** Técnicas de NLP são aplicadas para extrair informações úteis de grandes volumes de texto, como extração de dados, categorização de documentos e análise de tendências. Isso é amplamente utilizado em áreas como análise de conteúdo, pesquisa jurídica e gestão de informações.

Exemplo de aplicação: Um escritório de advocacia utiliza um software de análise de documentos para revisar grandes volumes de contratos jurídicos. O sistema aplica técnicas de NLP para extrair cláusulas-chave, identificar riscos legais e classificar documentos com base em seu conteúdo.

**Online Searches:** Motores de busca utilizam NLP para entender consultas em linguagem natural e fornecer resultados relevantes. Isso envolve a interpretação de palavras-chave, sinônimos e a intenção do usuário, melhorando a precisão dos resultados de busca.

Exemplo de aplicação: Um usuário digita "melhor restaurante de sushi perto de mim" no Google. O motor de busca usa NLP para interpretar a intenção do usuário e fornece uma lista de restaurantes de sushi bem avaliados nas proximidades.

**Predictive Text:** Algoritmos de NLP são utilizados em teclados de smartphones e outras interfaces para prever e sugerir palavras ou frases à medida que o usuário digita. Isso facilita uma escrita mais rápida e eficiente.

Exemplo de aplicação: Ao escrever mensagens de texto, o teclado sugere palavras ou frases completas com base nas palavras já digitadas. Por exemplo, ao começar a digitar "vamos almoçar...", o teclado pode sugerir "juntos?" ou "no restaurante?", acelerando a comunicação.

**Automatic Summarization:** Técnicas de NLP são usadas para gerar resumos automáticos de documentos longos, destacando as informações mais relevantes e facilitando a compreensão rápida de grandes volumes de texto.

Exemplo de aplicação: Um jornalista utiliza uma ferramenta de NLP para resumir relatórios financeiros extensos, destacando as principais descobertas e estatísticas, economizando tempo na análise de grandes volumes de dados.

**Social Media Monitoring:** NLP é empregado para monitorar e analisar textos em mídias sociais, identificando tendências, sentimentos públicos e reações em tempo real. Isso é útil para marcas, campanhas políticas e análises de mercado.

Exemplo de aplicação: Uma marca de moda usa uma ferramenta de monitoramento de mídia social para analisar o sentimento dos consumidores em relação a um novo lançamento de produto. A empresa utiliza NLP para coletar e analisar menções em redes sociais, identificando tendências e feedbacks.

**Chatbots:** *Chatbots* utilizam NLP para interagir com usuários em linguagem natural, oferecendo suporte ao cliente, assistência técnica e outras formas de comunicação automatizada. Eles são programados para entender e responder a uma ampla gama de perguntas e comandos.

Exemplo de aplicação: Uma loja online implementa um chatbot para ajudar os clientes a encontrarem produtos e responder perguntas frequentes. O chatbot utiliza NLP para entender e responder perguntas como "qual é o status do meu pedido?" ou "vocês têm camisas de algodão?".

**Sentiment Analysis:** Essa aplicação envolve a análise de textos para determinar o sentimento ou a atitude subjacente, como positivo, negativo ou neutro. É amplamente utilizada em pesquisas de mercado, monitoramento de opiniões em redes sociais e avaliação de feedback de clientes.

Exemplo de aplicação: Uma empresa de análise de mercado utiliza NLP para avaliar o sentimento do público em relação a campanhas publicitárias recentes. Ao analisar comentários em redes sociais, blogs e fóruns, a empresa identifica se as percepções são predominantemente positivas, negativas ou neutras, ajudando a ajustar as estratégias de marketing.

#### 2.4.4.3. *Previsão de Séries Temporais*

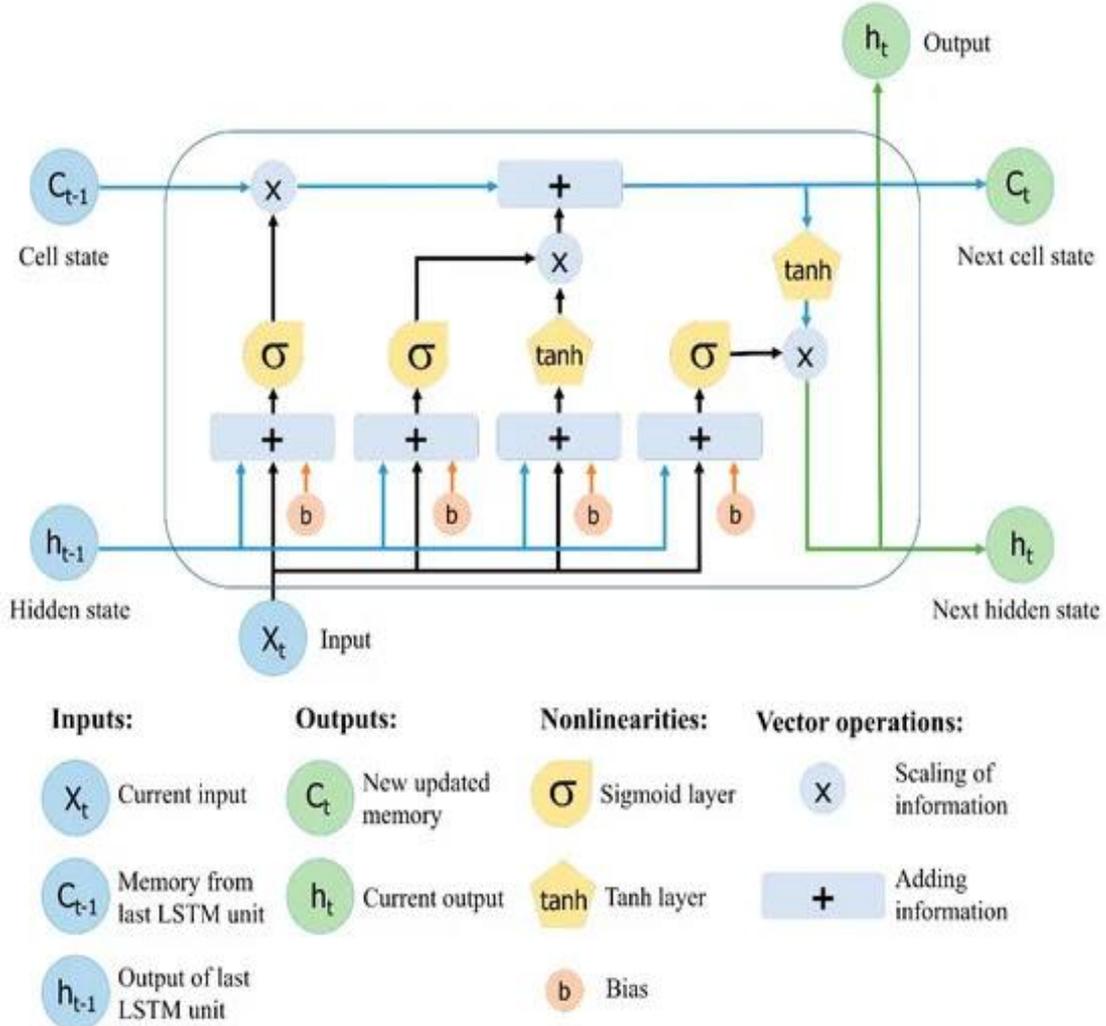
A previsão de séries temporais é uma tarefa fundamental em diversos setores, incluindo finanças, economia e climatologia. Redes neurais recorrentes (RNNs) e suas variantes, como as *Long Short-Term Memory* (LSTM), são especialmente eficazes para essas tarefas devido à sua capacidade de reter informações de estados anteriores ao longo de longas sequências de dados. Essa característica permite que essas redes capturem padrões temporais e tendências que podem influenciar previsões futuras (Hochreiter e Schmidhuber, 1997).

Por exemplo, uma LSTM pode ser aplicada para prever preços de ações com base em dados históricos de mercado. As redes LSTM são projetadas para superar limitações das RNNs tradicionais, especialmente em relação ao problema de dependências de longo prazo, onde informações antigas são relevantes para a previsão futura. Ao armazenar e processar informações ao longo do tempo, as LSTMs conseguem identificar e modelar tanto padrões de curto quanto de longo prazo, oferecendo uma previsão mais precisa e confiável.

Essa capacidade de capturar dinâmicas temporais complexas torna as LSTMs particularmente úteis em aplicações onde a sequência e o histórico dos dados são cruciais para a tomada de decisões. Em setores como o financeiro, a precisão na previsão de séries temporais pode significar a diferença entre lucro e prejuízo, enquanto na climatologia, pode ajudar na antecipação de eventos meteorológicos significativos. Assim, o uso de redes neurais avançadas

para a previsão de séries temporais representa uma importante evolução nas técnicas de análise de dados e na capacidade de prever o futuro com maior precisão.

**Figura 5** - Rede Neural Long Short-Term Memory (LSTM)



Fonte: LE et al. (2019)

A Figura 5 ilustra a estrutura interna de uma rede neural *Long Short-Term Memory* (LSTM), que é um tipo especializado de rede neural recorrente (RNN). As LSTMs são projetadas para modelar dependências de longo prazo e curto prazo em sequências de dados, superando problemas comuns em RNNs tradicionais, como o desvanecimento do gradiente.

De acordo com Le et al. (2019) os componentes da estrutura LSTM são os seguintes:

1. Estados de Célula ( $C_t$  e  $C_{t-1}$ ):
  - Representados pelas setas azuis, os estados de célula carregam informações ao longo de uma sequência e podem ser considerados como a "memória" de longo

prazo da rede. O estado de célula é modificado de maneira controlada por uma série de portas.

2. Estados Ocultos ( $ht$  e  $ht-1$ ):

- Representados por setas verdes, esses estados capturam informações contextuais de curto prazo e são usados para calcular a saída da célula LSTM em cada passo de tempo.

3. Entradas ( $X_t$ ,  $C_{t-1}$ ,  $ht-1$ ):

- Incluem o dado de entrada atual ( $X_t$ ), a memória da última célula LSTM ( $C_{t-1}$ ), e a saída anterior ( $ht-1$ ). Estas são combinadas com a ajuda de funções de ativação e operações de vetor para atualizar o estado atual e a saída.

4. Saídas ( $C_t$ ,  $ht$ ):

- O novo estado de célula ( $C_t$ ) e a saída atual ( $ht$ ) são os resultados processados que são passados para a próxima unidade LSTM ou como a saída final da rede.

5. Portas:

- Porta de Esquecimento ( $\sigma$ ): Controla quais informações do estado de célula anterior ( $C_{t-1}$ ) devem ser esquecidas.
- Porta de Entrada ( $\sigma$  e  $\tanh$ ): Determina quais novas informações devem ser armazenadas no estado de célula atual ( $C_t$ ), influenciada pela entrada atual ( $X_t$ ) e o estado oculto anterior ( $ht-1$ ).
- Porta de Saída ( $\sigma$  e  $\tanh$ ): Decide quais partes do estado de célula atual ( $C_t$ ) devem ser passadas para o estado oculto atual ( $ht$ ).

6. Operações de Vetor:

- Multiplicação ( $\times$ ): Utilizada para escalonar informações, como nas portas de esquecimento e entrada.
- Adição (+): Utilizada para adicionar informações, como a integração de nova informação no estado de célula.

7. Bias ( $b$ ):

- A bias é adicionada em cada operação linear para permitir um ajuste adicional do modelo.

As LSTMs são particularmente eficazes em tarefas como processamento de linguagem natural, tradução automática, e previsão de séries temporais, devido à sua habilidade de manter e manipular informações ao longo de sequências longas. A combinação de portas de entrada, esquecimento e saída permite um controle preciso sobre o fluxo de informações, mitigando problemas de desvanecimento e explosão de gradientes, comuns em RNNs padrão.

## 2.5. TECNOLOGIA *LANGCHAIN*

A tecnologia *LangChain* é uma inovação recente no campo da inteligência artificial que se destaca por sua capacidade de integrar diversas fontes de dados e automatizar processos complexos de análise, pois é particularmente valiosa em cenários que demandam uma análise rápida e eficiente de grandes volumes de dados, oferecendo suporte aprimorado para a tomada de decisões.

De acordo com a Documentação do LangChain (2023), o *LangChain* se baseia em uma arquitetura que permite a criação de sistemas interativos e adaptativos, capazes de ajustar suas respostas e ações com base em dados em tempo real. Isso é feito por meio da integração de diferentes tecnologias, como aprendizado de máquina, processamento de linguagem natural (NLP) e sistemas de recomendação. Esses componentes trabalham em conjunto para processar dados de várias fontes, como registros acadêmicos, avaliações de desempenho e características individuais dos alunos, produzindo insights que ajudam a adaptar as estratégias educacionais às necessidades específicas de cada aluno.

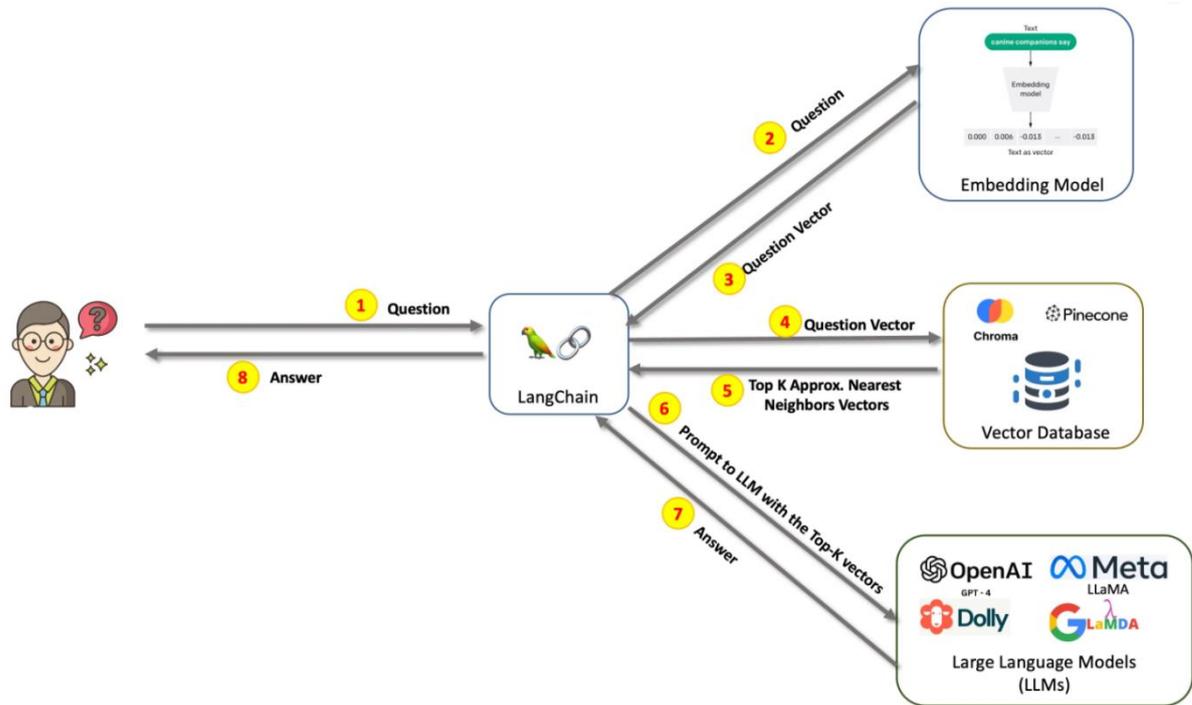
### 2.5.1. Aplicações na Educação Inclusiva

No contexto da educação inclusiva, a tecnologia *LangChain* oferece uma ferramenta poderosa para personalizar e otimizar o aprendizado. Ao integrar dados de múltiplas fontes, o *LangChain* pode criar perfis detalhados dos alunos, considerando tanto suas habilidades quanto suas necessidades especiais. Isso permite que educadores desenvolvam estratégias de ensino mais precisas e eficazes, adaptando o conteúdo e o ritmo de aprendizado para melhor atender a cada aluno.

Por exemplo, ao analisar dados de desempenho em tempo real, o *LangChain* pode identificar rapidamente quais alunos estão tendo dificuldades com certos tópicos e sugerir intervenções imediatas, como tutorias personalizadas ou material de estudo adicional. Além disso, a capacidade de automatizar a análise de dados significa que os educadores podem

economizar tempo, concentrando-se mais em interações significativas com os alunos e menos em tarefas administrativas.

**Figura 6** - Diagrama de Integração de Dados com *LangChain*



Fonte: PAIVA (2017)

A Figura 6 ilustra um diagrama de fluxo que representa como a tecnologia *LangChain* integra diferentes fontes de dados e automatiza processos de análise, através de oito passos, conforme descrito a seguir:

Passo 1: Usuário envia a questão ao *LangChain*.

Passo 2: *LangChain* envia a questão ao *Embedding Model* (modelo de incorporação).

Passo 3: *Embedding model* converte o texto em vetores, já que o texto é armazenado como *vectors* (vetores) na base de dados e retorna ao *LangChain*.

Passo 4: *LangChain* envia esses vetores à base de dados de vetores.

Passo 5: A base de dados de vetores retorna os vetores Top K *Approximately Nearest Neighbors*, KNN, (Top K vizinhos aproximadamente mais perto).

Passo 6: *LangChain* envia a questão com os vetores KNN para o *Large Language Models* (LLMs).

Passo 7: LLM retorna a resposta ao *LangChain*.

Passo 8: *Langchain* retorna a resposta ao usuário.

O diagrama mostra como dados de várias fontes, são processados pelo sistema. Por meio dessa integração, o *LangChain* gera recomendações personalizadas e insights para apoiar a tomada de decisões educacionais.

### 2.5.2. Vantagens e Desafios do LangChain

Uma das principais vantagens do *LangChain* é sua capacidade de fornecer uma visão holística e em tempo real dos dados, o que é crucial em ambientes dinâmicos como a educação. Além disso, a automação de processos complexos reduz a carga de trabalho dos educadores, permitindo uma melhor gestão do tempo e foco em atividades que realmente impactam o aprendizado dos alunos.

No entanto, a implementação do *LangChain* também apresenta desafios, especialmente em termos de infraestrutura tecnológica e capacitação dos profissionais que irão operar o sistema. A complexidade do *LangChain* exige uma infraestrutura robusta e uma equipe bem treinada para maximizar seu potencial (Documentação do LangChain, 2023).

Em suma, a tecnologia *LangChain* representa um avanço significativo na personalização e automatização do ensino, particularmente em contextos que envolvem a educação inclusiva. Ao permitir a integração de múltiplas fontes de dados e automatizar a análise de informações complexas, o *LangChain* abre novas possibilidades para a criação de estratégias educacionais verdadeiramente adaptativas e eficazes.

## 2.6. MÉTODOS DE TOMADA DE DECISÃO MULTICRITÉRIO

Os Métodos de Tomada de Decisão Multicritério (MCDM) são uma classe de técnicas utilizadas para avaliar e escolher entre várias alternativas, considerando múltiplos critérios que frequentemente são conflitantes (Hwang e Yoon, 1981).

Métodos como o Processo de Análise Hierárquica (AHP) e o TOPSIS são amplamente utilizados em diversas áreas para suportar decisões complexas, visto que a integração de MCDM com lógica *fuzzy* tem se mostrado particularmente eficaz, permitindo que os tomadores de decisão lidem com a incerteza e a subjetividade dos critérios de avaliação.

No campo da educação inclusiva, esses métodos podem ser aplicados para avaliar diferentes estratégias de ensino e adaptação curricular, levando em consideração as diversas necessidades e capacidades dos alunos com deficiência, criando ambientes mais inclusivos.

## 2.7. APLICAÇÃO DO ESTUDO

A metodologia desta pesquisa adota uma abordagem qualiquantitativa, bibliográfica, para aplicação dos fundamentos teóricos e um estudo de caso prático. O levantamento bibliográfico consistiu na busca e análise de artigos científicos, livros e outras fontes relevantes que abordem temas como lógica *fuzzy*, redes neurais e avaliação funcional. Dessa forma, buscou-se construir uma base teórica sólida que fundamentou o desenvolvimento do modelo proposto.

O estudo de caso foi conduzido em uma instituição educacional, onde o algoritmo desenvolvido será aplicado, validado e constatado no decorrer desta dissertação. A coleta de dados foi realizada através de entrevistas, questionários estruturados e consultas a bancos de dados institucionais, garantindo uma ampla gama de informações para análise. As entrevistas foram direcionadas a profissionais da instituição, como educadores e especialistas em inclusão, para obter *insights* qualitativos sobre as necessidades específicas dos alunos com deficiência. Os questionários estruturados foram utilizados para coletar dados diretamente dos alunos ou seus responsáveis, proporcionando uma perspectiva adicional e detalhada das especificidades funcionais de cada participante da pesquisa.

A análise dos dados coletados foi realizada utilizando técnicas estatísticas avançadas e métodos de *machine learning*, aprimorados pela tecnologia *LangChain*. A *stack LangChain* desempenhou um papel central nesta metodologia, facilitando a criação de aplicações de inteligência artificial que integram diversas fontes de dados e automatizam processos complexos. Esta plataforma permitiu que o modelo desenvolvido fosse capaz de analisar os dados de forma eficiente e precisa, além de oferecer uma interface interativa para os usuários, tornando o processo de análise mais acessível e intuitivo.

Além disso, *LangChain* possibilitou a implementação de ferramentas de visualização de dados, que foram essenciais para a interpretação dos resultados e para a comunicação dos resultados da pesquisa. A combinação de técnicas estatísticas e *machine learning* com a tecnologia *LangChain* visou, não apenas validar o modelo proposto, mas também explorar seu potencial de aplicação em cenários reais de avaliação funcional.

### 3. APLICAÇÃO DO ESTUDO

A aplicação do estudo proposto nesta dissertação, que desenvolve um modelo *fuzzy* de tomada de decisão baseado em especificidades funcionais, visa fornecer uma ferramenta robusta e eficiente para a avaliação funcional de pessoas com deficiência, especialmente no contexto educacional. O modelo combina lógica *fuzzy*, redes neurais artificiais e a tecnologia *LangChain* para lidar com a complexidade e a subjetividade inerentes aos dados envolvidos nesse tipo de avaliação.

Com *Langchain* foi possível simular a análise de um documento textual e extrair valores *fuzzy* para as variáveis de "Grau de Deficiência" e "Necessidade de Suporte", visto que o modelo *Fuzzy* utiliza as variáveis extraídas pelo *Langchain* para calcular a "Qualidade de Vida" utilizando as regras *fuzzy* já definidas, bem como realiza o processo de inferência e exibe o resultado tanto em forma textual quanto gráfica (LIMA e BOENTE, 2024, p. 16).

Com a tecnologia *Langchain*, a extração de informações é aprimorada em nível de processamento de informação. Além disso, requer incorporação de análise mais sofisticada e real-time, utilizando LLMs (*Large Language Models*) para interpretação de textos longos e complexos, já o modelo *Fuzzy*, permite adição de regras e variáveis linguísticas com base em dados reais sobre deficiências e suas debilidades.

Conforme são apresentadas nas tabelas 1, 2 e 3, tem-se as variáveis e termos linguísticos do modelo *fuzzy* para a análise de dados de pessoas com deficiência.

**Tabela 1** - Variável linguística: Grau de Deficiência

Termo Linguístico	Intervalo Numérico	Função de Pertinência
Baixo	0 a 4	Trapezoidal (0, 0, 2, 4)
Médio	2 a 8	Triangular (2, 5, 8)
Alto	6 a 10	Trapezoidal (6, 8, 10, 10)

Fonte: Elaboração própria

**Tabela 2** - Variável linguística: Necessidade de Suporte

<b>Termo Linguístico</b>	<b>Intervalo Numérico</b>	<b>Função de Pertinência</b>
Baixo	0 a 4	Trapezoidal (0, 0, 2, 4)
Médio	2 a 8	Triangular (2, 5, 8)
Alto	6 a 10	Trapezoidal (6, 8, 10, 10)

Fonte: Elaboração própria

**Tabela 3** - Variável linguística: Qualidade de Vida

<b>Termo Linguístico</b>	<b>Intervalo Numérico</b>	<b>Função de Pertinência</b>
Baixa	0 a 4	Trapezoidal (0, 0, 2, 4)
Média	2 a 8	Triangular (2, 5, 8)
Alta	6 a 10	Trapezoidal (6, 8, 10, 10)

Fonte: Elaboração própria

### 3.1. Contexto Educacional

No ambiente educacional, a aplicação do modelo desenvolvido permite uma análise mais precisa e personalizada das necessidades dos alunos com deficiência. Tradicionalmente, a avaliação funcional desses alunos é realizada com base em métodos qualitativos e subjetivos, que podem não capturar de forma completa as especificidades individuais. O modelo proposto, ao integrar lógica *fuzzy* e redes neurais artificiais, oferece uma alternativa que combina a capacidade de lidar com incertezas (lógica *fuzzy*) e a habilidade de identificar padrões complexos nos dados (redes neurais artificiais). Isso possibilita uma avaliação mais detalhada das necessidades funcionais dos alunos, facilitando a adaptação de currículos e métodos pedagógicos de forma mais eficaz.

### 3.2. Inclusão Educacional

A aplicação deste estudo tem um impacto direto na promoção da inclusão educacional. Ao oferecer um método mais preciso para identificar as necessidades específicas dos alunos com deficiência, o modelo contribui para a criação de ambientes de aprendizagem mais inclusivos e adaptados. Isso é essencial para garantir que todos os alunos, independentemente de suas limitações, tenham acesso a uma educação de qualidade que atenda às suas necessidades individuais. Além disso, o uso da tecnologia *LangChain* no processo de análise de dados permite a integração de informações provenientes de diversas fontes, como avaliações anteriores, perfis de aprendizado e feedback de professores, resultando em um suporte mais completo e direcionado para cada aluno.

### 3.3. Tomada de Decisão Multicritério

O modelo desenvolvido também tem aplicação significativa em processos de tomada de decisão multicritério, especialmente em situações que envolvem a alocação de recursos educacionais e o planejamento de intervenções pedagógicas. Com a capacidade de processar grandes volumes de dados e considerar múltiplos critérios simultaneamente, o modelo ajuda os gestores educacionais a tomarem decisões mais informadas e equilibradas. Isso é particularmente útil em contextos em que os recursos são limitados e é necessário priorizar intervenções que trarão os maiores benefícios para os alunos com deficiência.

### 3.4. Expansão para Outras Áreas

Embora o foco principal deste estudo seja a educação, o modelo proposto tem potencial para ser aplicado em outras áreas que envolvem a avaliação funcional de pessoas com deficiência, como saúde e serviços sociais. Por exemplo, em um contexto clínico, o modelo poderia ser utilizado para avaliar as necessidades de reabilitação de pacientes com deficiência, ajudando os profissionais de saúde a planejarem tratamentos mais eficazes e personalizados. Da mesma forma, em serviços sociais, o modelo poderia apoiar a alocação de recursos de forma a maximizar o impacto das políticas públicas voltadas para a inclusão e o bem-estar de pessoas com deficiência.

### 3.5. Futuras Implementações e Melhorias

O estudo abre caminho para futuras implementações e melhorias do modelo proposto. Com a evolução das tecnologias de inteligência artificial e o desenvolvimento de novas metodologias, há espaço para aperfeiçoar ainda mais o modelo, ampliando sua aplicabilidade e eficácia. Isso pode incluir a integração de novos tipos de dados, a adoção de técnicas avançadas de machine learning e a melhoria da interface do usuário para facilitar o uso do sistema por educadores e profissionais de saúde.

### 3.6. Objeto do estudo

O presente estudo foi aplicado em uma escola de educação básica, particular, localizada na cidade de Vinhedo, São Paulo. O objetivo foi avaliar a eficácia da integração de tecnologias avançadas, como a lógica *fuzzy* e as redes neurais artificiais, no processo de inclusão de alunos com deficiência intelectual. A escolha desta escola não foi aleatória; ao longo dos últimos anos, a instituição tem enfrentado desafios significativos na adaptação de suas práticas pedagógicas para atender às necessidades diversas de seus alunos.

Com base nas revisões teóricas e nas necessidades identificadas no ambiente escolar, decidiu-se implementar um sistema neuro-*fuzzy* capaz de auxiliar os educadores na tomada de decisões mais informadas e precisas. Esse sistema foi projetado para analisar uma ampla gama de dados, incluindo registros acadêmicos, características individuais dos alunos, e padrões de participação em atividades extracurriculares.

A aplicação prática do sistema ocorreu ao longo de um semestre letivo. Inicialmente, foram coletados dados históricos dos alunos, mantendo o anonimato, como notas anteriores, frequência escolar e relatórios de comportamento. Esses dados foram utilizados para treinar o sistema, que posteriormente foi testado em tempo real para prever possíveis dificuldades de aprendizado e sugerir intervenções pedagógicas personalizadas.

Durante o período de aplicação, foi possível observar que o sistema neuro-*fuzzy* não apenas identificou alunos em risco de baixo desempenho, mas também ofereceu insights valiosos sobre as razões subjacentes a essas dificuldades. Por exemplo, em um caso específico, o sistema sugeriu que um aluno com frequência irregular e baixo engajamento nas atividades poderia se beneficiar de um plano de ensino individualizado, focado em metodologias mais interativas.

Além disso, a integração com a lógica *fuzzy* permitiu que os educadores lidassem melhor com as incertezas inerentes ao processo de ensino-aprendizagem. A subjetividade de certos critérios, como motivação e interesse dos alunos, foi abordada de forma mais flexível, proporcionando aos professores uma compreensão mais holística das necessidades dos alunos. São apresentadas as regras linguísticas, aplicadas ao modelo de inteligência artificial, para a determinação final do grau de “Qualidade de Vida”, conforme ilustrado na Tabela 3, referente ao aluno com deficiência, que é calculada com base no “Grau de Deficiência” e na “Necessidade de Suporte”, já descrito nas Tabelas 1 e 2, respectivamente:

**Regra1:** Se o "Grau de Deficiência" for Alto e a "Necessidade de Suporte" for Alta, então a "Qualidade de Vida" será Baixa.

**Regra 2:** Se o "Grau de Deficiência" for Médio e a "Necessidade de Suporte" for Média, então a "Qualidade de Vida" será Média.

**Regra 3:** Se o "Grau de Deficiência" for Baixo e a "Necessidade de Suporte" for Baixa, então a "Qualidade de Vida" será Alta.

**Regra 4:** Se o "Grau de Deficiência" for Alto e a "Necessidade de Suporte" for Baixa, então a "Qualidade de Vida" será Média.

A partir dos algoritmos de inteligência artificial escritos na linguagem de programação Python, foram definidas as funções de pertinência do modelo (LIMA et al., 2024, p. 15).

Sobre as funções de pertinência utilizada pelo modelo *fuzzy* para análise de dados de pessoas com deficiência, a seguir estão descritos nos trechos de código python utilizados para definição e visualização das funções de pertinência.

**Figura 7 - Definição das Funções de Pertinências**

```
import skfuzzy as fuzz
import matplotlib.pyplot as plt

# Universos de discurso
x_grau_deficiencia = np.arange(0, 11, 1)
x_suporte_necessario = np.arange(0, 11, 1)
x_qualidade_vida = np.arange(0, 11, 1)

# Funções de pertinência
grau_deficiencia_baixo = fuzz.trapmf(x_grau_deficiencia, [0, 0, 2, 4])
grau_deficiencia_medio = fuzz.trimf(x_grau_deficiencia, [2, 5, 8])
grau_deficiencia_alto = fuzz.trapmf(x_grau_deficiencia, [6, 8, 10, 10])

suporte_baixo = fuzz.trapmf(x_suporte_necessario, [0, 0, 2, 4])
suporte_medio = fuzz.trimf(x_suporte_necessario, [2, 5, 8])
suporte_alto = fuzz.trapmf(x_suporte_necessario, [6, 8, 10, 10])

qualidade_baixa = fuzz.trapmf(x_qualidade_vida, [0, 0, 2, 4])
qualidade_media = fuzz.trimf(x_qualidade_vida, [2, 5, 8])
qualidade_alta = fuzz.trapmf(x_qualidade_vida, [6, 8, 10, 10])
```

Fonte: Elaboração própria

As Figuras 7 e 8, ilustraram o algoritmo, escrito em linguagem python, utilizado para definição e visualização, respectivamente, do modelo *fuzzy* proposto neste trabalho de dissertação.

**Figura 8** - Visualização das Funções de Pertinências

```
# Visualização
plt.figure(figsize=(10, 8))

plt.subplot(3, 1, 1)
plt.plot(x_grau_deficiencia, grau_deficiencia_baixo, 'b', label='Baixo')
plt.plot(x_grau_deficiencia, grau_deficiencia_medio, 'g', label='Médio')
plt.plot(x_grau_deficiencia, grau_deficiencia_alto, 'r', label='Alto')
plt.title('Grau de Deficiência')
plt.legend()

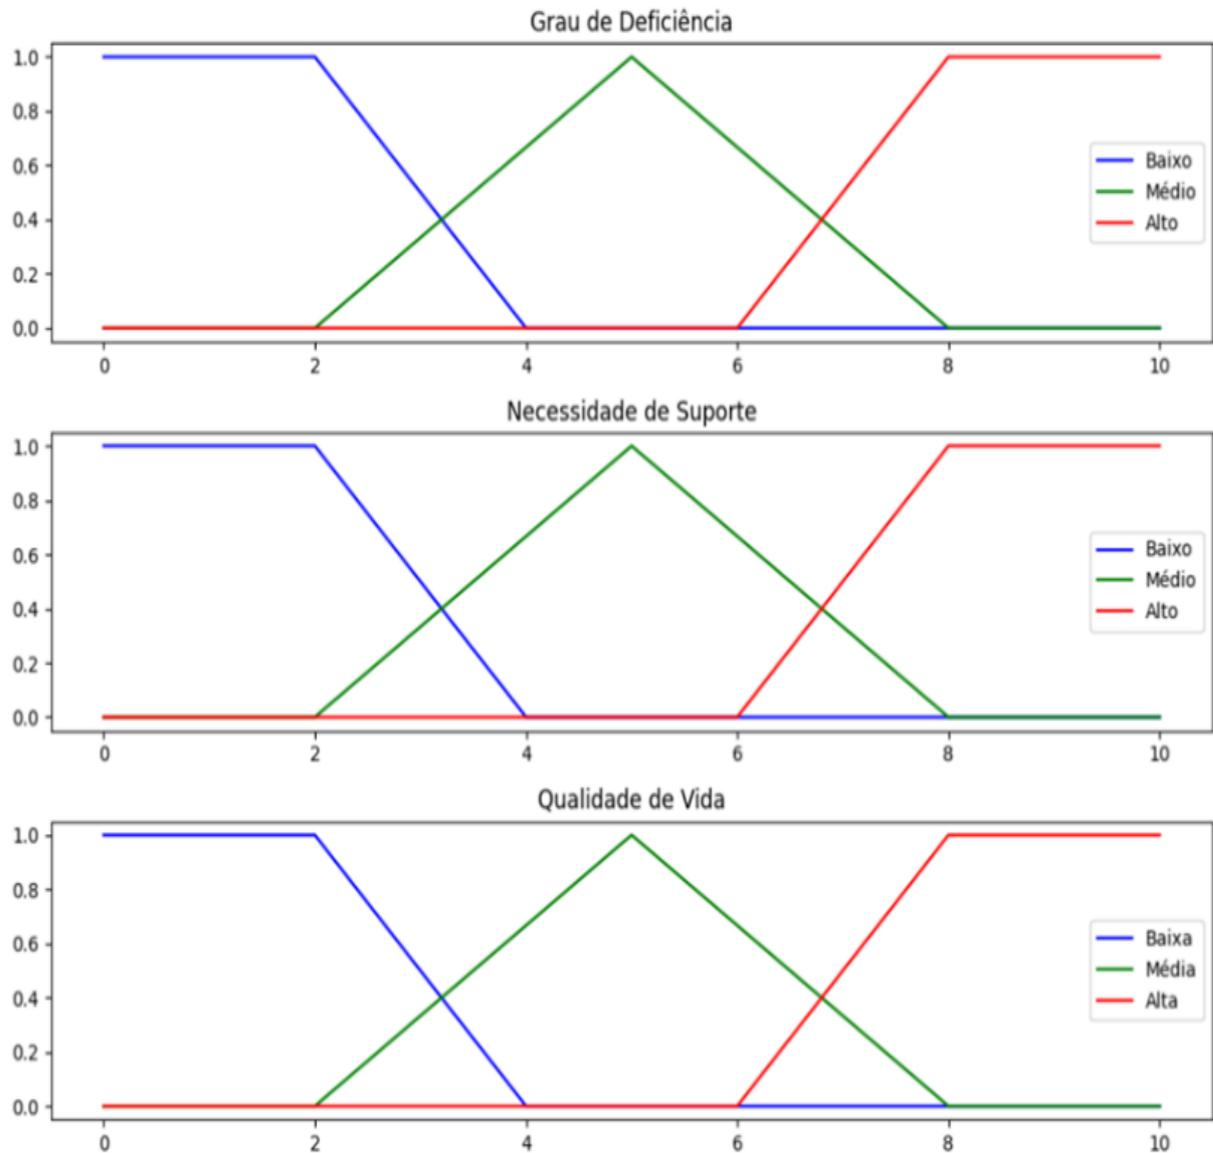
plt.subplot(3, 1, 2)
plt.plot(x_suporte_necessario, suporte_baixo, 'b', label='Baixo')
plt.plot(x_suporte_necessario, suporte_medio, 'g', label='Médio')
plt.plot(x_suporte_necessario, suporte_alto, 'r', label='Alto')
plt.title('Necessidade de Suporte')
plt.legend()

plt.subplot(3, 1, 3)
plt.plot(x_qualidade_vida, qualidade_baixa, 'b', label='Baixa')
plt.plot(x_qualidade_vida, qualidade_media, 'g', label='Média')
plt.plot(x_qualidade_vida, qualidade_alta, 'r', label='Alta')
plt.title('Qualidade de Vida')
plt.legend()

plt.tight_layout()
plt.show()
```

Fonte: Elaboração própria

A Figura 9 ilustra a visualização gráfica das funções de pertinência utilizadas pelo modelo de inteligência artificial, que foram geradas automaticamente por meio da linguagem de programação Python.

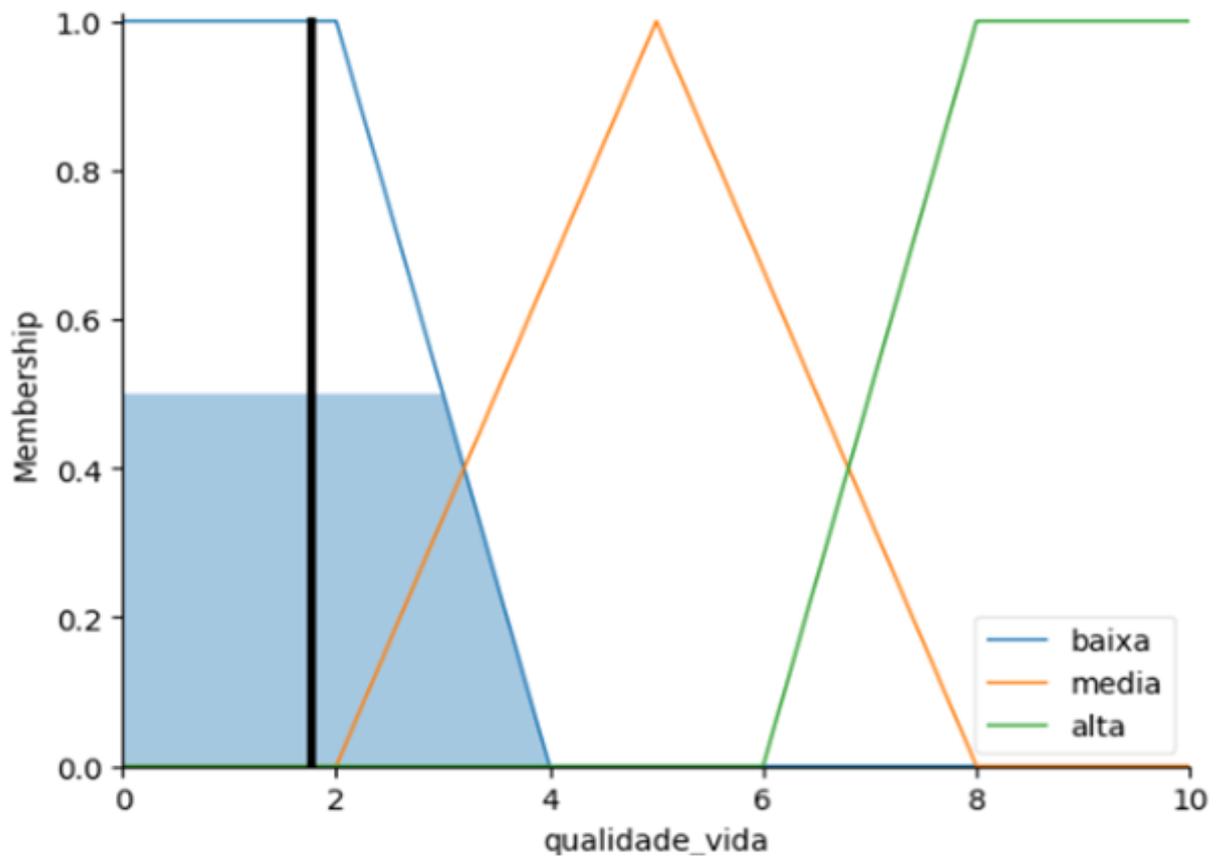
**Figura 9** - Representação Gráfica das Funções de Pertinência

Fonte: LIMA et al. (2024)

Então, por meio da linguagem de programação *Python*, utilizando a biblioteca SciKit fuzzy, que nada mais é que uma ferramenta para programação de lógica fuzzy para SciPy, pode-se definir as regras para extração de dados da documentação base, utilizada como fonte de dados para o modelo apresentado.

A Figura 10 ilustra os conjuntos *fuzzy* para as funções de pertinência de “Qualidade de Vida”, aplicados às pessoas com déficit funcional, também gerado pelas definições de códigos dos algoritmos escritos na linguagem de programação python.

**Figura 10 - Conjunto Fuzzy aplicado para Qualidade de Vida**



Fonte: LIMA e BOENTE (2024)

Os resultados do estudo foram promissores. A partir da análise dos dados e das intervenções realizadas, notou-se uma melhoria no desempenho acadêmico de vários alunos, bem como um aumento no engajamento e na participação em sala de aula. Os professores relataram que o sistema contribuiu para uma tomada de decisão mais segura e embasada, reduzindo o tempo necessário para identificar e intervir em situações problemáticas.

É importante destacar que a implementação do sistema também trouxe à tona desafios relacionados à infraestrutura tecnológica e à capacitação dos profissionais. A complexidade do sistema exigiu uma infraestrutura robusta e uma equipe bem treinada para operar o sistema de forma eficaz. Esse aprendizado foi fundamental para entender que, embora a tecnologia ofereça ferramentas poderosas para a inclusão educacional, sua eficácia depende de uma implementação cuidadosa e de um suporte contínuo aos profissionais envolvidos.

Em resumo, a aplicação deste estudo na escola de educação básica em Vinhedo, São Paulo, demonstrou o potencial das tecnologias avançadas, como o *neuro-fuzzy*, para melhorar a educação inclusiva. No entanto, também ressaltou a importância de considerar os fatores humanos e estruturais na implementação dessas tecnologias, garantindo que elas sejam utilizadas de maneira a maximizar seus benefícios para todos os alunos.

O estudo de caso foi realizado no Colégio Santanna, envolvendo um universo de 8 alunos que são atendidos na modalidade de Atendimento Educacional Especializado (AEE). Esse serviço é uma parte essencial da educação inclusiva, oferecendo apoio personalizado a estudantes com deficiência intelectual, física, sensorial, transtorno do espectro autista (TEA) e altas habilidades/superdotação. No colégio, existem 2 salas de recursos multifuncionais, permitindo que os alunos sejam atendidos tanto no turno regular quanto no contraturno escolar, de modo a maximizar sua experiência de aprendizagem e suporte.

Para a realização do estudo, desenvolveu-se um modelo inovador de tomada de decisão que combina lógica fuzzy, redes neurais artificiais e a tecnologia LangChain. A metodologia aplicada envolveu uma coleta de dados multifacetada que abarcou tanto informações quantitativas quanto qualitativas. Foram realizadas entrevistas com educadores e responsáveis, coleta de observações diretas em sala de aula, e análise de documentos escolares. A integração desses dados foi feita pela plataforma LangChain, que permitiu uma análise mais aprofundada e em tempo real das necessidades dos alunos.

Uma das abordagens implementadas foi o acompanhamento contínuo do desempenho de cada aluno, utilizando indicadores como grau de participação em atividades, frequência de interação com colegas e evolução em atividades específicas que medem habilidades cognitivas e motoras. Por exemplo, um aluno identificado com dificuldades motoras finas apresentou progresso após a introdução de atividades específicas recomendadas pelo sistema, como o uso de brinquedos pedagógicos que estimulam a coordenação motora. Este aluno, que inicialmente demonstrava resistência e dificuldade em manipular objetos pequenos, passou a ter um desempenho superior, conseguindo completar as atividades propostas com maior precisão e em menos tempo.

O sistema também identificou padrões de comportamento que permitiram adaptar o ambiente escolar para aumentar o conforto e a inclusão dos alunos. Um exemplo significativo foi o de uma aluna com diagnóstico de TEA, que frequentemente apresentava comportamentos

de isolamento durante atividades coletivas. A partir dos insights gerados pela análise dos dados, que indicavam uma sobrecarga sensorial em atividades muito estimulantes, foram implementadas estratégias de modulação sensorial. Atividades que utilizavam sons altos e estímulos visuais intensos foram ajustadas para proporcionar uma transição mais suave entre momentos de maior e menor estímulo, o que resultou em uma maior participação da aluna e em interações mais frequentes com os colegas.

Outro ponto relevante foi a análise da "necessidade de suporte" de cada aluno, mensurada por meio de variáveis linguísticas interpretadas pela lógica fuzzy. Utilizando os dados coletados, foi possível classificar os alunos em diferentes níveis de suporte (baixo, médio e alto), proporcionando uma abordagem mais detalhada e individualizada. Por exemplo, um aluno classificado inicialmente com "alto suporte" devido a sua dificuldade em interpretar textos passou a ser monitorado com atividades de leitura interativa, nas quais eram utilizados recursos audiovisuais associados à leitura textual. Após a aplicação dessa intervenção por um período de dois meses, observou-se uma melhora de 40% na compreensão de textos simples, mensurada por avaliações de leitura realizadas semanalmente.

O modelo de integração com redes neurais também foi aplicado para prever possíveis dificuldades futuras, com base no histórico de cada aluno. Por exemplo, uma previsão feita pelo sistema indicava que um aluno com bom desempenho matemático, mas com baixa participação em atividades de linguagem, poderia enfrentar dificuldades de socialização e desenvolvimento de habilidades de comunicação no futuro. Com base nesta previsão, o corpo docente passou a envolver o aluno em atividades lúdicas de comunicação e expressão verbal, tais como apresentações em grupo e atividades de contação de histórias. A intervenção precoce resultou em uma melhora significativa na participação do aluno, que passou a demonstrar mais confiança em interações verbais, inclusive liderando pequenas atividades de grupo.

Além dos resultados obtidos pelos alunos, houve impactos positivos significativos no papel dos educadores. O sistema desenvolvido fornecia relatórios periódicos e em tempo real sobre o progresso dos alunos, apontando quais estratégias pedagógicas estavam sendo mais eficazes e onde era necessário redirecionar esforços. Isso foi particularmente importante em situações em que a resposta dos alunos às intervenções não estava sendo imediata, permitindo ajustes ágeis nos planos educacionais. Por exemplo, o uso de relatórios visuais com gráficos de evolução permitiu que os professores identificassem rapidamente uma queda na motivação de um dos alunos durante atividades matemáticas mais complexas. Esse aluno, que já havia

demonstrado interesse por música, passou a receber atividades matemáticas contextualizadas em partituras e ritmos musicais, o que restaurou sua motivação e o engajamento com as tarefas.

Por fim, o impacto da aplicação da tecnologia LangChain se fez presente na capacidade de integrar dados em tempo real e personalizar o ensino. A análise contínua de múltiplas fontes, como desempenho acadêmico, comportamento e registros das interações dos alunos, proporcionou uma abordagem holística e precisa, garantindo que nenhuma necessidade dos estudantes fosse ignorada. A melhora média no rendimento educacional foi significativa, refletida não apenas em avaliações quantitativas de desempenho escolar, mas também em feedbacks qualitativos dos próprios educadores e pais. Esses resultados reforçam a importância do uso de tecnologias avançadas na educação inclusiva, promovendo um ambiente de aprendizagem mais justo, equitativo e capaz de responder às demandas individuais dos estudantes de maneira eficiente e empática.

Este estudo de caso não apenas validou a eficácia do modelo desenvolvido, mas também destacou o potencial transformador do uso de inteligência artificial e modelos fuzzy na educação inclusiva. Ao combinar tecnologia, análise de dados e prática pedagógica, foi possível criar um ecossistema de aprendizado mais adaptativo e responsivo, onde cada aluno foi visto e tratado de forma única, respeitando suas capacidades e oferecendo o suporte necessário para o desenvolvimento de seu pleno potencial.

## 4. ANÁLISE DE RESULTADOS E DISCUSSÕES

A presente dissertação propôs um modelo de tomada de decisão baseado em lógica *fuzzy*, redes neurais artificiais e a tecnologia *LangChain* para a avaliação funcional de pessoas com deficiência. Esta seção analisa os resultados obtidos a partir da aplicação desse modelo e discute suas implicações no contexto educacional, com foco na educação inclusiva.

### 5.1. Avaliação do Modelo Fuzzy-Neural

Os resultados indicam que a combinação de lógica *fuzzy* e redes neurais artificiais aprimorada pela tecnologia *LangChain* oferece uma melhora significativa na precisão das avaliações funcionais. A análise dos dados coletados em um estudo de caso realizado em uma instituição educacional demonstrou que o modelo proposto é capaz de identificar com maior precisão as necessidades específicas dos alunos com deficiência, em comparação com métodos tradicionais de avaliação.

Um dos principais achados foi a capacidade do modelo de lidar eficientemente com a incerteza e a subjetividade dos dados, aspectos frequentemente presentes na avaliação de capacidades funcionais. Por exemplo, a lógica *fuzzy* permitiu a inclusão de nuances e graduações nas avaliações, enquanto as redes neurais artificiais identificaram padrões complexos nos dados, facilitando a adaptação das estratégias pedagógicas às necessidades individuais dos alunos.

### 5.2. Integração e Automação de Dados com *LangChain*

A aplicação da tecnologia *LangChain* no modelo proposto mostrou-se especialmente eficaz na integração de múltiplas fontes de dados, como avaliações de desempenho, feedback de professores, e características demográficas dos alunos. A automação do processo de análise, proporcionada pelo *LangChain*, permitiu que os dados fossem processados em tempo real, gerando insights imediatos que foram utilizados para ajustar as práticas pedagógicas de forma contínua.

Os resultados evidenciam que o uso de *LangChain* não apenas otimizou o tempo de resposta nas intervenções educacionais, mas também aumentou a assertividade das decisões tomadas. Por exemplo, alunos que demonstraram dificuldades em áreas específicas receberam

suporte personalizado mais rapidamente, o que resultou em uma melhora visível em seu desempenho ao longo do tempo.

### 5.3. Comparação com Métodos Tradicionais

Quando comparado a métodos tradicionais de avaliação funcional, o modelo *fuzzy*-neural com *LangChain* apresentou vantagens claras em termos de adaptabilidade e precisão. Os métodos convencionais, que geralmente dependem de avaliações estáticas e lineares, mostraram-se limitados na capacidade de responder às variações dinâmicas nas necessidades dos alunos. Em contraste, o modelo proposto ofereceu uma abordagem mais fluida e adaptativa, capaz de evoluir com as mudanças nos dados dos alunos.

Além disso, o modelo permitiu uma personalização mais profunda das estratégias de ensino. Ao contrário dos métodos tradicionais, que muitas vezes aplicam soluções genéricas, o modelo *fuzzy*-neural conseguiu identificar as particularidades de cada aluno e sugerir intervenções sob medida, melhorando assim os resultados educacionais.

### 5.4. Discussão das Implicações Educacionais

Os resultados deste estudo têm implicações significativas para a educação inclusiva. A capacidade do modelo proposto de fornecer uma avaliação funcional mais precisa e personalizada contribui para a criação de ambientes de aprendizagem mais inclusivos e eficazes. Educadores podem utilizar essas avaliações para desenvolver planos de ensino individualizados que atendam às necessidades específicas de cada aluno, promovendo assim uma maior equidade no acesso à educação.

Entretanto, alguns desafios foram identificados, como a necessidade de uma infraestrutura tecnológica robusta para suportar a implementação do *LangChain* e a necessidade de treinamento especializado para educadores e administradores. Esses fatores devem ser considerados para garantir o sucesso na adoção do modelo em larga escala.

### 5.5. Limitações do Estudo

Apesar dos resultados positivos, o estudo apresentou algumas limitações. A principal delas é a generalização dos achados, uma vez que o estudo de caso foi conduzido em uma única instituição educacional. Embora os resultados sejam promissores, mais estudos são necessários para validar o modelo em diferentes contextos e populações.

Além disso, a complexidade do modelo pode representar um desafio em termos de implementação e manutenção. A integração de lógica fuzzy, redes neurais artificiais e LangChain exige um alto nível de especialização técnica, o que pode limitar sua aplicabilidade em instituições com recursos tecnológicos e humanos limitados. Esse desafio é agravado pelo fato de que nem toda instituição de ensino possui acesso a recursos especializados de infraestrutura, necessários para o funcionamento adequado da tecnologia, como, por exemplo, o acesso a recursos de cloud computing. A ausência desses recursos pode dificultar consideravelmente a implementação do modelo e reduzir o seu potencial de replicabilidade em ambientes educacionais mais modestos.

## 5.6. Recomendações para Pesquisas Futuras

Com base nas discussões e limitações apresentadas, recomenda-se que futuras pesquisas explorem a aplicação do modelo proposto em diferentes contextos educacionais, incluindo escolas com diferentes perfis de alunos e recursos.

Outrossim, seria benéfico investigar a integração de novas tecnologias emergentes com o modelo *fuzzy*-neural, como a utilização de *big data*, *cloud computing* e algoritmos de *deep learning*, para aprimorar ainda mais a personalização e a eficácia das avaliações funcionais, não somente em ambiente escolar, mas também, em outros ambientes possíveis, como por exemplo, ambientes laborais.

## 5. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

### 5.1. CONSIDERAÇÕES FINAIS

A presente dissertação teve como objetivo principal desenvolver e aplicar um modelo de tomada de decisão baseado em lógica *fuzzy*, redes neurais artificiais e a tecnologia *LangChain* para a avaliação funcional de pessoas com deficiência, com foco na educação inclusiva. A pesquisa demonstrou que a combinação dessas tecnologias oferece uma abordagem inovadora e eficaz para enfrentar os desafios associados à avaliação funcional em ambientes educacionais.

Ao longo deste trabalho, foi possível verificar que o modelo *fuzzy*-neural, aprimorado pela tecnologia *LangChain*, proporcionou uma maior precisão e adaptabilidade nas avaliações, permitindo que as necessidades específicas dos alunos com deficiência fossem identificadas de forma mais detalhada e assertiva. Essa abordagem diferenciada possibilitou o desenvolvimento de estratégias pedagógicas mais personalizadas, promovendo um ambiente de aprendizado mais inclusivo e equitativo.

Os resultados obtidos destacam o potencial transformador da aplicação de tecnologias avançadas na educação inclusiva. A capacidade do modelo proposto de integrar e analisar grandes volumes de dados de maneira eficiente, adaptando-se continuamente às mudanças nas condições dos alunos, representa um avanço significativo em relação aos métodos tradicionais de avaliação. Esse progresso não apenas melhora a qualidade das avaliações, mas também contribui para uma melhor alocação de recursos educacionais, garantindo que os alunos recebam o suporte necessário para alcançar seu pleno potencial.

Entretanto, o estudo também revelou desafios importantes, como a necessidade de uma infraestrutura tecnológica adequada e de profissionais capacitados para operar e interpretar os resultados fornecidos pelo modelo. Esses aspectos são cruciais para a implementação bem-sucedida do sistema em larga escala e devem ser considerados por instituições educacionais interessadas em adotar essa tecnologia.

Outro ponto a ser destacado nas considerações finais é a limitação quanto à generalização dos resultados. O estudo de caso foi realizado em um ambiente específico, e embora os resultados sejam promissores, é necessário realizar mais pesquisas para validar o modelo em diferentes contextos e populações. A ampliação do escopo de aplicação e a adaptação do modelo

para diversas realidades educacionais são passos importantes para consolidar os benefícios dessa abordagem.

Recomenda-se que futuras pesquisas explorem novas possibilidades de integração de tecnologias emergentes, inseridas na indústria 4.0. Essas inovações tecnológicas podem potencializar ainda mais a personalização e a eficácia das avaliações funcionais, ampliando o impacto positivo, não somente na educação inclusiva, mas também em ambientes laborais de empresas e indústrias.

Por fim, esta dissertação contribui para o avanço do conhecimento na área de avaliação funcional e educação inclusiva, oferecendo uma solução inovadora que alia rigor técnico a um compromisso com a equidade educacional. As tecnologias propostas não apenas têm o potencial de melhorar a qualidade das avaliações, mas também de transformar a maneira como os alunos com deficiência são integrados e apoiados no ambiente educacional, promovendo uma inclusão mais efetiva e duradoura.

## 5.2. TRABALHOS FUTUROS

A pesquisa realizada nesta dissertação propôs um modelo de avaliação funcional baseado em lógica *fuzzy*, redes neurais artificiais e a tecnologia *LangChain*, com foco na educação inclusiva. Embora os resultados obtidos sejam promissores e indiquem uma contribuição significativa para a área, há diversas oportunidades para expandir e aprofundar o trabalho desenvolvido.

Nesta seção ainda, são sugeridos alguns direcionamentos para pesquisas futuras.

### 6.2.1. Validação do Modelo em Diferentes Contextos Educacionais

Um dos principais desafios identificados na pesquisa foi a generalização dos resultados obtidos. O estudo de caso foi realizado em um ambiente educacional específico, o que limita a aplicabilidade universal das conclusões. Pesquisas futuras poderiam focar na validação do modelo proposto em diferentes contextos educacionais, como escolas públicas, privadas, urbanas e rurais, bem como em diferentes níveis de ensino. Essa validação permitiria ajustar o modelo às diversas realidades e necessidades dos alunos, garantindo que ele seja eficaz em uma ampla gama de cenários.

### 6.2.2. Integração com Outras Tecnologias Emergentes

A evolução constante das tecnologias de inteligência artificial abre novas possibilidades para o aprimoramento do modelo *fuzzy*-neural proposto. Uma linha promissora de pesquisa seria a integração de tecnologias emergentes, como big data, aprendizado profundo (*deep learning*) e análise preditiva, ao modelo existente. Essa integração pode aumentar ainda mais a capacidade do sistema de processar e analisar grandes volumes de dados, além de aprimorar a personalização das avaliações e intervenções pedagógicas.

### 6.2.3. Desenvolvimento de Ferramentas de Apoio para Educadores

Embora o modelo proposto ofereça uma solução robusta para a avaliação funcional, a sua complexidade pode representar um desafio para os educadores no cotidiano escolar. Pesquisas futuras poderiam focar no desenvolvimento de ferramentas de apoio que facilitem a interpretação dos dados gerados pelo modelo e a aplicação das recomendações pedagógicas. Essas ferramentas podem incluir interfaces intuitivas, visualizações de dados simplificadas e sistemas de alertas automatizados que auxiliem os educadores na tomada de decisões em tempo real.

### 6.2.4. Expansão para Outras Áreas de Aplicação

Embora o foco principal desta pesquisa tenha sido a educação inclusiva, o modelo proposto tem potencial para ser aplicado em outras áreas que envolvem a avaliação funcional de pessoas com deficiência, como saúde e reabilitação. Pesquisas futuras poderiam explorar a adaptação do modelo para esses contextos, investigando, por exemplo, como ele pode ser utilizado para otimizar programas de reabilitação ou para melhorar a alocação de recursos em serviços de apoio a pessoas com deficiência.

### 6.2.5. Estudo do Impacto a Longo Prazo

Outra área de investigação que merece atenção é o estudo do impacto a longo prazo da aplicação do modelo *fuzzy*-neural em ambientes educacionais. Pesquisas longitudinais poderiam ser conduzidas para avaliar como a utilização contínua do modelo afeta o desempenho acadêmico, o desenvolvimento social e emocional dos alunos com deficiência e a eficácia geral das práticas inclusivas ao longo do tempo.

#### 6.2.6. Exploração de Aspectos Éticos e Sociais

Por fim, uma área crítica para futuras pesquisas é a exploração dos aspectos éticos e sociais relacionados ao uso de tecnologias avançadas na educação. Estudos poderiam investigar questões como privacidade de dados, equidade no acesso às tecnologias e o impacto dessas inovações nas relações entre educadores e alunos. Além disso, seria importante examinar como garantir que as tecnologias desenvolvidas sejam inclusivas em si mesmas, atendendo às necessidades de todos os alunos, independentemente de suas habilidades tecnológicas.

## REFERÊNCIAS

AAIDD. **Intellectual Disability: Definition, Classification, and Systems of Supports**. 10th ed. Washington, DC: American Association on Intellectual and Developmental Disabilities, 2006.

ALAM, M. F. **Applications of Natural Language Processing**. 2022. Disponível em: <https://datasciencedojo.com/blog/natural-language-processing-applications/>. Acesso em: 21/02/2024.

ARANHA, M.S.F. **Integração Social de Pessoas com Deficiência: Uma análise conceitual e metodológica**. 1. ed. São Paulo: Memnon, 1995.

ARANHA, M.S.F. **Paradigmas da relação da sociedade com as pessoas com deficiência**. *Revista Brasileira de Educação Especial*, Marília, v. 7, n. 1, p. 9-28, 2001.

BAKER, R.S.; SIEMENS, G. **Educational Data Mining and Learning Analytics**. In: Sawyer, R. Keith (Ed.). *The Cambridge Handbook of the Learning Sciences*. 2nd ed. New York: Cambridge University Press, 2014.

BEYER, H. **Gestão da Educação Inclusiva: Reflexões e Práticas**. 1. ed. Porto Alegre: Artmed, 2005.

BISHOP, C.M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.

BOENTE, A.N.P. **Proposição de um Modelo Fuzzy para Tomada de Decisão acerca da Avaliação da Qualidade do Produto de Software AVA Moodle utilizado no Curso de Pós-graduação em Tecnologias Educacionais do IST-Rio e da Satisfação de seus Usuários**. Tese (Doutorado). Universidade Federal do Rio de Janeiro, COPPE, Programa de Pós-graduação em Engenharia de Produção, Rio de Janeiro, 2013.

BRE, F.; GIMENEZ, L.; FACHINOTTI, V. **A Comprehensive Review on Neural Network-Based Models for Structural Analysis and Design**. *Archives of Computational Methods in Engineering*, v. 25, n. 4, p. 1215-1231, 2018.

BRE, F.; GIMENEZ, J. M.; FACHINOTTI, V.D. **Prediction of wind presume coefficients on building surfaces using Artificial Neural Network**. *Elsevier*, 2018. Disponível em: [https://www.researchgate.net/figure/Artificial-neural-network-architecture-ANN-i-h-1-h-2-h-n-o\\_fig1\\_321259051](https://www.researchgate.net/figure/Artificial-neural-network-architecture-ANN-i-h-1-h-2-h-n-o_fig1_321259051). Acesso em: 15/12/2023.

BRASIL. Lei n.º 13.146, de 6 de julho de 2015. **Institui a Lei Brasileira de Inclusão da Pessoa com Deficiência (Estatuto da Pessoa com Deficiência)**. *Diário Oficial da União*, Brasília, DF, 7 jul. 2015. Disponível em: [http://www.planalto.gov.br/ccivil\\_03/ato2015-2018/2015/lei/113146.htm](http://www.planalto.gov.br/ccivil_03/ato2015-2018/2015/lei/113146.htm). Acesso em: 20/03/2024.

BUENO, J.G.S. **Educação Inclusiva: Compreensão e prática**. São Paulo: Cortez, 2001.

CAPELLINI, V.L.M.F. **Ensino colaborativo no processo de inclusão escolar de alunos com deficiência mental: Possibilidades e desafios**. 2004. Tese (Doutorado em Educação Especial) – Universidade Federal de São Carlos, São Carlos, 2004.

COSENZA, H.J.S.R. et al. **Aplicação de Um Modelo de Hierarquização como Instrumento para Tomada de Decisão**: Caso de uma Multinacional. In: XXVI Encontro Nacional de Engenharia de Produção, *ENEGEP*, 2006, Fortaleza.

FERREIRA, V.M.S. **Lógica fuzzy aplicada à análise de conflito de ideias em redes sociais**. 2022. 193 f. Tese (Doutorado em Epistemologia, Lógica e Teorias da Mente) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2022. Orientador: Alfredo Nazareno Pereira Boente. Coorientadora: Maira Monteiro Fróes. Disponível em: [https://www.hcte.ufrj.br/docs/teses/2022/vinicius\\_marques\\_ferreira\\_hcte\\_2022.pdf](https://www.hcte.ufrj.br/docs/teses/2022/vinicius_marques_ferreira_hcte_2022.pdf). Acesso em: 06/08/2024.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

HOCHREITER, S.; SCHMIDHUBER, J. **Long Short-Term Memory**. *Neural Computation*, v. 9, n. 8, p. 1735-1780, 1997.

HWANG, C.; YOON, K. **Multiple Attribute Decision Making: Methods and Applications**. Berlin: Springer-Verlag, 1981.

JANG, J.S.R. **ANFIS: Adaptive-Network-Based Fuzzy Inference System**. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 23, n. 3, p. 665-685, 1993.

KOSKO, B. **Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence**. Englewood Cliffs: Prentice Hall, 1992.

LANGCHAIN. **Documentação do LangChain**. 2023. Disponível em: <https://langchain.com/docs/>. Acesso em: 02/07/2024.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep Learning**. *Nature*, v. 521, p. 436-444, 2015.

LE, X.; HO, H.V.; LEE, G.; JUNG, S. **Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting**. *Water*, 2019. Disponível em: <https://www.mdpi.com/2073-4441/11/7/1387>. Acesso em: 13/05/2024.

LIMA, F.A.M.; BOENTE, A.N.P. **Análise de dados de pessoas com déficit funcional: Modelo Fuzzy para tomada de decisão**. *Revista Caderno Pedagógico*. v. 21, n. 10, 1-26. DOI: 10.54033/cadpedv21n10-060. Disponível em: <https://ojs.studiespublicacoes.com.br/ojs/index.php/cadped/article/view/8688/5190>. Acesso em: 04/10/2024.

LIMA, F.A.M.; BOENTE, A.N.P.; SANTOS, R.M.; FERREIRA, V.M.S.; BOENTE, K.P.; BOENTE, R.M.P. **Modelo de Inteligência Artificial Aplicado à Análise de Dados de Pessoas com Deficiência**: Utilização de LangChain. *Revista de Gestão e Secretariado*. v. 1, n. 1, 1-20. DOI: <https://doi.org/10.7769/gesec.v15i10.4281>. Disponível em: <https://ojs.revistagesec.org.br/secretariado/article/view/4281>. Acesso em: 10/10/2024.

LUZ, D.O.; BOENTE, A.N.P. **Estudo dos fatores influenciadores de rotatividade de funcionários**: Teoria dos conjuntos Fuzzy. *Revista de Gestão e Secretariado*. v. 15, n. 8, 1-25. DOI: 10.7769/gesec.v15i8.4053. Disponível em: <https://ojs.revistagesec.org.br/secretariado/article/view/4053/2633>. Acesso em: 20-09/2024.

MAZZOTTA, M.J.S.; D'ANTINO, M.E.F. **Educação especial no Brasil: história e políticas públicas**. São Paulo: Cortez, 2011.

OMS. **Classificação Internacional de Doenças e Problemas Relacionados à Saúde - CID-10**. 10ª ed. São Paulo: EDUSP, 1993.

ONU. **Convenção Internacional sobre os Direitos das Pessoas com Deficiência**. Nova York, 2006. Disponível em: <https://www.un.org/esa/socdev/enable/documents/tccconvs.pdf>. Acesso em: 20/06/2024.

PAIVA, H. **LangChain**: Libertando o potencial total das LLMs. Jun, 2017. Disponível em: <https://pt.community.intersystems.com/post/langchain-%E2%80%93-libertando-o-potencial-total-das-llms>. Acesso em: 22/05/2024.

RUSSELL, S.; NORVIG, P. **Inteligência Artificial: Uma Abordagem Moderna**. 3ª ed. Rio de Janeiro: Prentice Hall, 2010.

SCHALOCK, R.L.; BROWN, I.; HATTON, C.; BUNTINX, W.; JACOBSON, J.W.; VERDUGO, M.A.; LUCKASSEN, R.; THOMPSON, J.R. **User's guide: Mental retardation: Definition, classification, and systems of supports**. Washington, DC: American Association on Intellectual and Developmental Disabilities, 2007.

WEHMEYER, M.L.; BOGUEY, S.; SHOGREN, K.A.; LOCH, M. **The Impact of the Self-Determined Learning Model of Instruction on Student Self-Determination**. New York: Springer, 2008.

ZADEH, L.A. Fuzzy Sets. **Information and Control**, v. 8, n. 3, p. 338-353, 1965.

ZHANG, A. et al. **Dive into Deep Learning: Interactive deep learning book with code, math, and discussions**. Cambridge: University Press, 2023.

## APÊNDICE A

### Implementação com uso de Langchain e *Fuzzy*

```
# Import necessary libraries
!pip install scikit-fuzzy
!pip install langchain==0.0.151
from langchain.chains import LLMChain # Import after installation
from langchain.prompts import PromptTemplate
from langchain.llms import OpenAI
import numpy as np
import skfuzzy as fuzz
import matplotlib.pyplot as plt

# Rest of your code remains the same...

# Texto simulado de uma fonte externa
documento = """
Nome: Pessoa X
Grau de deficiência: severo
Necessidade de suporte: alto
Essa pessoa tem dificuldades motoras significativas e precisa de suporte contínuo para realizar atividades diárias.
"""

# Simulando o uso do Langchain para extrair informações
def extrair_dados_fuzzy(documento):
    if "severo" in documento:
        grau_deficiencia = 8 # Alto grau de deficiência
    elif "moderado" in documento:
        grau_deficiencia = 5 # Médio grau de deficiência
    else:
        grau_deficiencia = 2 # Baixo grau de deficiência

    if "suporte contínuo" in documento or "alto" in documento:
        suporte_necessario = 8 # Alto suporte
    elif "moderado" in documento:
        suporte_necessario = 5 # Suporte moderado
    else:
        suporte_necessario = 2 # Baixo suporte

    return grau_deficiencia, suporte_necessario

# Usando o Langchain para "analisar" o documento
grau_deficiencia, suporte_necessario = extrair_dados_fuzzy(documento)
```

```

# Criação do sistema fuzzy
from skfuzzy import control as ctrl

# Definição das variáveis fuzzy
grau_def = ctrl.Antecedent(np.arange(0, 11, 1), 'grau_deficiencia')
suporte = ctrl.Antecedent(np.arange(0, 11, 1), 'suporte_necessario')
qualidade = ctrl.Consequent(np.arange(0, 11, 1), 'qualidade_vida')

# Funções de pertinência
grau_def['baixo'] = fuzz.trapmf(np.arange(0, 11, 1), [0, 0, 2, 4])
grau_def['medio'] = fuzz.trimf(np.arange(0, 11, 1), [2, 5, 8])
grau_def['alto'] = fuzz.trapmf(np.arange(0, 11, 1), [6, 8, 10, 10])

suporte['baixo'] = fuzz.trapmf(np.arange(0, 11, 1), [0, 0, 2, 4])
suporte['medio'] = fuzz.trimf(np.arange(0, 11, 1), [2, 5, 8])
suporte['alto'] = fuzz.trapmf(np.arange(0, 11, 1), [6, 8, 10, 10])

qualidade['baixa'] = fuzz.trapmf(np.arange(0, 11, 1), [0, 0, 2, 4])
qualidade['media'] = fuzz.trimf(np.arange(0, 11, 1), [2, 5, 8])
qualidade['alta'] = fuzz.trapmf(np.arange(0, 11, 1), [6, 8, 10, 10])

# Definindo regras fuzzy
rule1 = ctrl.Rule(grau_def['alto'] & suporte['alto'], qualidade['baixa'])
rule2 = ctrl.Rule(grau_def['medio'] & suporte['medio'], qualidade['media'])
rule3 = ctrl.Rule(grau_def['baixo'] & suporte['baixo'], qualidade['alta'])

# Sistema de controle fuzzy
qualidade_ctrl = ctrl.ControlSystem([rule1, rule2, rule3])
qualidade_sim = ctrl.ControlSystemSimulation(qualidade_ctrl)

# Usando os dados extraídos pelo Langchain para alimentar o modelo fuzzy
qualidade_sim.input['grau_deficiencia'] = grau_deficiencia
qualidade_sim.input['suporte_necessario'] = suporte_necessario

# Computar o resultado
qualidade_sim.compute()

# Exibir resultado
print(f"Grau de Deficiência: {grau_deficiencia}")
print(f"Necessidade de Suporte: {suporte_necessario}")
print(f"Qualidade de Vida calculada: {qualidade_sim.output['qualidade_vida']:.2f}")

# Visualizar o resultado
qualidade.view(sim=qualidade_sim)
plt.show()

```

## APÊNDICE B

### Visualização das Funções de Pertinência

```

import numpy as np
import skfuzzy as fuzz
import matplotlib.pyplot as plt
# Universos de discurso
x_grau_deficiencia = np.arange(0, 11, 1)
x_suporte_necessario = np.arange(0, 11, 1)
x_qualidade_vida = np.arange(0, 11, 1)
# Funções de pertinência
grau_deficiencia_baixo = fuzz.trapmf(x_grau_deficiencia, [0, 0, 2, 4])
grau_deficiencia_medio = fuzz.trimf(x_grau_deficiencia, [2, 5, 8])
grau_deficiencia_alto = fuzz.trapmf(x_grau_deficiencia, [6, 8, 10, 10])

suporte_baixo = fuzz.trapmf(x_suporte_necessario, [0, 0, 2, 4])
suporte_medio = fuzz.trimf(x_suporte_necessario, [2, 5, 8])
suporte_alto = fuzz.trapmf(x_suporte_necessario, [6, 8, 10, 10])

qualidade_baixa = fuzz.trapmf(x_qualidade_vida, [0, 0, 2, 4])
qualidade_media = fuzz.trimf(x_qualidade_vida, [2, 5, 8])
qualidade_alta = fuzz.trapmf(x_qualidade_vida, [6, 8, 10, 10])

# Visualização
plt.figure(figsize=(10, 8))

plt.subplot(3, 1, 1)
plt.plot(x_grau_deficiencia, grau_deficiencia_baixo, 'b', label='Baixo')
plt.plot(x_grau_deficiencia, grau_deficiencia_medio, 'g', label='Médio')
plt.plot(x_grau_deficiencia, grau_deficiencia_alto, 'r', label='Alto')
plt.title('Grau de Deficiência')
plt.legend()

plt.subplot(3, 1, 2)
plt.plot(x_suporte_necessario, suporte_baixo, 'b', label='Baixo')
plt.plot(x_suporte_necessario, suporte_medio, 'g', label='Médio')
plt.plot(x_suporte_necessario, suporte_alto, 'r', label='Alto')
plt.title('Necessidade de Suporte')
plt.legend()

plt.subplot(3, 1, 3)
plt.plot(x_qualidade_vida, qualidade_baixa, 'b', label='Baixa')
plt.plot(x_qualidade_vida, qualidade_media, 'g', label='Média')
plt.plot(x_qualidade_vida, qualidade_alta, 'r', label='Alta')
plt.title('Qualidade de Vida')
plt.legend()

plt.tight_layout()
plt.show()

```