



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE QUIXADÁ
CURSO DE GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

JESSICA MARIA NUNES DA SILVA

**PERCEPÇÃO SOBRE REQUISITOS DE QUALIDADE DE DADOS PARA SISTEMAS
BASEADOS EM APRENDIZADO DE MÁQUINA: UM ESTUDO PRELIMINAR**

QUIXADÁ
2025

JESSICA MARIA NUNES DA SILVA

PERCEPÇÃO SOBRE REQUISITOS DE QUALIDADE DE DADOS PARA SISTEMAS
BASEADOS EM APRENDIZADO DE MÁQUINA: UM ESTUDO PRELIMINAR

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Sistemas de Informação
do Campus de Quixadá da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Sistemas de Informação.

Orientador: Prof. Me. Marcelo Martins
da Silva

Coorientador: Prof. Dr. Anderson Gon-
çalves Uchôa

QUIXADÁ

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

S58p Silva, Jessica Maria Nunes da.
Percepção sobre requisitos de qualidade de dados para sistemas baseados em aprendizado de máquina :
Um estudo preliminar / Jessica Maria Nunes da Silva. – 2025.
60 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Quixadá,
Curso de Sistemas de Informação, Quixadá, 2025.

Orientação: Prof. Me. Marcelo Martins da Silva .

Coorientação: Prof. Dr. Anderson Gonçalves Uchôa.

1. Aprendizado de máquina. 2. Qualidade dos dados. 3. Requisitos de qualidade. I. Título.

CDD 005

JESSICA MARIA NUNES DA SILVA

PERCEPÇÃO SOBRE REQUISITOS DE QUALIDADE DE DADOS PARA SISTEMAS
BASEADOS EM APRENDIZADO DE MÁQUINA: UM ESTUDO PRELIMINAR

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Sistemas de Informação
do Campus de Quixadá da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Sistemas de Informação.

Aprovada em: 12 de Março de 2025

BANCA EXAMINADORA

Prof. Me. Marcelo Martins da Silva (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Anderson Gonçalves Uchôa (Coorientador)
Universidade Federal do Ceará (UFC)

Prof. Me. Francisco Victor da Silva Pinheiro
Universidade Federal do Ceará (UFC)

Dr. Hugo Ricardo Guarin Villamizar
Pontifícia Universidade Católica do Rio de Janeiro
(PUC-Rio)

Este trabalho é todo dedicado a minha mãe que sempre me apoio e me incentivou a correr atrás dos meus sonhos. É graças ao seu esforço que hoje posso concluir o meu curso, obrigada!

AGRADECIMENTOS

Gostaria de expressar minha sincera gratidão a todas as pessoas que contribuíram para a realização deste trabalho. Seus apoios e orientações foram fundamentais para o sucesso deste projeto.

Primeiramente, agradeço sinceramente ao meu orientador, Marcelo Martins, por sua orientação constante e paciência ao longo deste processo. Sua dedicação e compromisso em me guiar foram fundamentais para a conclusão deste trabalho. Também estendo minha gratidão ao meu coorientador, Anderson Uchôa, cujo apoio e valiosas contribuições enriqueceram ainda mais este estudo.

Desejo também agradecer às minhas amigas queridas, Rayane, Deigela e Stefane, que permaneceram ao meu lado durante toda essa jornada acadêmica. Suas palavras de incentivo, pensamentos construtivos e momentos compartilhados foram essenciais para manter minha motivação e inspiração.

Não posso deixar de expressar meu agradecimento aos meus amigos e colegas de estudo, Samuel, Alcides e Severo. Suas discussões estimulantes, trocas de ideias e momentos de descontração foram um verdadeiro alívio durante os desafios deste trabalho.

Um agradecimento especial a Hugo Guarín, cuja contribuição e apoio foram essenciais para a realização deste projeto. Sua ajuda foi inestimável e fez toda a diferença.

À minha família, que sempre me apoiou em todas as etapas da minha vida, minha eterna gratidão.

Por fim, deixo aqui meu sincero agradecimento a todos que acreditaram em mim. Muito obrigada!

Nem sempre você terá uma vida confortável e nem sempre você estará apta a solucionar todos os problemas do mundo de uma vez. Mas nunca subestime a sua importância, porque a história já nos mostrou que a coragem pode ser contagiosa e que a esperança pode ter vida própria.

(Michelle Obama)

RESUMO

O Aprendizado de Máquina (AM) é uma área da Inteligência Artificial que desenvolve algoritmos capazes de aprender a partir de dados e melhorar seu desempenho com a experiência. Com a crescente adoção de sistemas baseados em AM, a qualidade dos dados utilizados nesses sistemas tornou-se um fator crítico. Essa qualidade está diretamente relacionada aos requisitos não funcionais (RNFs), fundamentais para a eficácia e confiabilidade dos modelos de AM. No entanto, a aplicação de RNFs em sistemas AM ainda apresenta desafios, pois alguns requisitos tornam-se mais críticos, outros mudam de significado e novos podem surgir.

Este estudo investigou a percepção dos desenvolvedores sobre os RNFs relacionados à qualidade dos dados em AM, identificando os requisitos mais relevantes, as práticas adotadas para avaliá-los e os desafios enfrentados. A pesquisa foi conduzida por meio de um questionário aplicado a profissionais da área, resultando em uma amostra diversificada de desenvolvedores, cientistas de dados e engenheiros de Machine Learning.

Os resultados indicaram que os principais atributos de qualidade dos dados considerados pelos profissionais incluem consistência, precisão, relevância, atualização e confiabilidade. Observou-se também que, embora os participantes possuam experiência prática com qualidade de dados, a aplicação de técnicas formais de Engenharia de Requisitos ainda é limitada no contexto de AM. A análise revelou que a qualidade dos dados é frequentemente discutida nas fases iniciais do desenvolvimento, mas sua avaliação contínua ao longo do ciclo de vida do sistema ainda enfrenta dificuldades.

Entre os principais desafios identificados, destacam-se a falta de processos padronizados para avaliação da qualidade dos dados, a dificuldade em estabelecer métricas objetivas e a ausência de ferramentas adequadas para a validação contínua. Além disso, a pesquisa evidenciou que muitos profissionais reconhecem a importância dos RNFs para a qualidade dos modelos, mas ainda há lacunas na adoção sistemática dessas práticas no desenvolvimento de sistemas AM.

Palavras-chave: aprendizado de máquina; requisitos não funcionais; qualidade dos dados; desenvolvimento de software.

ABSTRACT

Machine Learning (ML) is a field of Artificial Intelligence that develops algorithms capable of learning from data and improving their performance through experience. With the increasing adoption of ML-based systems, data quality has become a critical factor. This quality is directly related to non-functional requirements (NFRs), which are essential for the effectiveness and reliability of ML models. However, applying NFRs in ML systems presents challenges, as some requirements become more critical, others change in meaning, and new ones may emerge.

This study investigated developers' perceptions of NFRs related to data quality in ML, identifying the most relevant requirements, the practices adopted to evaluate them, and the challenges faced. The research was conducted through a survey with professionals in the field, resulting in a diverse sample of developers, data scientists, and machine learning engineers.

The results indicate that the main data quality attributes considered by professionals include consistency, accuracy, relevance, timeliness, and reliability. While participants have practical experience with data quality, the use of formal requirements engineering techniques in ML remains limited. The analysis revealed that data quality is often discussed in the early stages of development, but its continuous assessment throughout the system's lifecycle still faces difficulties.

The main challenges identified include the lack of standardized processes for evaluating data quality, difficulty in defining objective metrics, and the absence of adequate tools for continuous validation. Furthermore, the study highlighted that many professionals recognize the importance of NFRs for model quality, but there are still gaps in the systematic adoption of these practices in ML system development.

Keywords: machine learning; non-functional requirements; data quality; software development.

LISTA DE FIGURAS

Figura 1 – Aprendizado de máquina	21
Figura 2 – Fluxo de fases deste trabalho	31
Figura 3 – Distribuição de gênero	37
Figura 4 – Distribuição dos papéis no desenvolvimento de sistemas baseados em AM .	38
Figura 5 – Distribuição de idade	38
Figura 6 – Limpeza de dados	39
Figura 7 – Integração de multipla fontes de dados	40
Figura 8 – Normalização ou padrinonização de dados	40
Figura 9 – Detecção e remoção de outliers	41
Figura 10 – Aplicação de técnicas de transformação de dados	41
Figura 11 – Nuvem de palavras	43
Figura 12 – Impacto da qualidade dos dados	47
Figura 13 – Frequencia que os requisitos são formalmente discutidos	48
Figura 14 – Desafios para garantir a confiabilidade dos dados	49
Figura 15 – Suporte de outros equipes	50

LISTA DE TABELAS

Tabela 1 – Classificação dos atributos de qualidade por categoria de informação técnica	19
Tabela 2 – Análise comparativa entre trabalhos relacionados e este trabalho	30
Tabela 3 – Survey	35

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivos	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Requisitos não-funcionais (RNFs)	16
<i>2.1.1</i>	<i>Tipos de RNFs</i>	<i>16</i>
<i>2.1.2</i>	<i>Implementação de RNFs</i>	<i>19</i>
<i>2.1.3</i>	<i>Requisitos não funcionais e aprendizado de máquina</i>	<i>20</i>
2.2	Aprendizado de máquina (AM)	20
<i>2.2.1</i>	<i>Tipos de aprendizado de máquina</i>	<i>21</i>
<i>2.2.2</i>	<i>Exemplos de aplicações</i>	<i>23</i>
<i>2.2.3</i>	<i>Análise de fraude</i>	<i>23</i>
<i>2.2.4</i>	<i>Recomendação de conteúdo</i>	<i>23</i>
<i>2.2.5</i>	<i>Chatbot</i>	<i>24</i>
<i>2.2.6</i>	<i>Detecção de anomalia</i>	<i>24</i>
<i>2.2.7</i>	<i>Logística</i>	<i>24</i>
<i>2.2.8</i>	<i>Operadoras de saúde</i>	<i>25</i>
<i>2.2.9</i>	<i>Veículos autônomos</i>	<i>25</i>
<i>2.2.10</i>	<i>Sistemas de previsões</i>	<i>25</i>
3	TRABALHOS RELACIONADOS	26
3.1	<i>Engenharia de requisitos para aprendizado de máquina: perspectivas de cientistas de dados</i>	<i>26</i>
3.2	<i>Noções básicas sobre o processo de desenvolvimento de sistemas de aprendizado de máquina: desafios e soluções</i>	<i>27</i>
3.3	<i>Estudo qualitativo sobre requisitos não funcionais no desenvolvimento ágil de software</i>	<i>27</i>
3.4	<i>Identificação de preocupações ao especificar sistemas habilitados para aprendizado de máquina: uma abordagem baseada em perspectiva</i>	<i>28</i>
3.5	<i>Análise Comparativa</i>	<i>29</i>
4	METODOLOGIA	31
4.1	Criar o questionário	31

4.1.1	<i>Caracterização geral do participante</i>	32
4.1.2	<i>Experiência com qualidade de dados</i>	33
4.1.3	<i>Percepção da qualidade de dados como requisito</i>	33
4.1.4	<i>Implementação de requisitos no desenvolvimento</i>	33
4.2	Executar o teste piloto	34
4.3	Coleta de Dados	36
4.4	Análise dos Dados	36
5	RESULTADOS	37
5.1	Caracterização geral dos participantes	37
5.2	Caracterização da experiência com qualidade de dados em sistemas baseados em aprendizado de máquina	39
5.3	Percepção da qualidade de dados como requisitos de sistemas baseados em aprendizado de máquina	42
5.3.1	<i>Experiência dos Participantes com Engenharia de Requisitos</i>	43
5.3.2	<i>grau de importância e prioridade atribuída a diferentes características de qualidade dos dados em projetos de aprendizado de máquina</i>	45
5.4	Implementação de requisitos de qualidade de dados no processo de desenvolvimento	47
5.5	Respondendo às questões de pesquisa	50
5.5.1	<i>Como os desenvolvedores percebem e lidam com as características de qualidade dos dados em projetos de Aprendizado de Máquina (AM)?</i>	50
5.5.2	<i>Como os desenvolvedores avaliam as características de qualidade dos dados ao longo do ciclo de vida do desenvolvimento de sistemas baseados em AM?</i>	52
5.5.3	<i>Quais são os principais desafios enfrentados pelos desenvolvedores em relação à qualidade dos dados em projetos de AM?</i>	53
5.6	Limitações e Ameaças a Validade	54
6	CONCLUSÕES E TRABALHOS FUTUROS	56
	REFERÊNCIAS	58

1 INTRODUÇÃO

Aprendizado de Máquina (AM), do inglês *Machine learning*, é um subcampo da Inteligência Artificial (IA) que visa o desenvolvimento de *software* com a capacidade de aprender a executar uma determinada tarefa com sua própria experiência. Isso permite desenvolver sistemas que aprendem a partir de dados históricos, ajustando-se para melhorar seu desempenho em determinadas tarefas. Trata-se de uma área de pesquisa multidisciplinar que engloba IA, probabilidade e estatística, teoria da complexidade computacional, teoria da informação, filosofia, psicologia, neurobiologia, entre outros (Cerri *et al.*, 2019).

A área de AM é um campo em constante evolução, que se dedica ao desenvolvimento de algoritmos computacionais destinados a simular a inteligência humana, mais especificamente como o ser humano aprende com o ambiente ao seu redor. Técnicas baseadas em AM têm sido aplicadas com sucesso em diversos campos, desde reconhecimento de padrões, visão computacional, finanças, entretenimento, biologia computacional e aplicações biomédicas (Naqa; Murphy, 2015).

Segundo Domingos (2015), um algoritmo de aprendizado é como um mestre artesão, em que cada uma de suas produções se difere e se adapta às necessidades do cliente. Entretanto, em vez de transformar ouro em joias ou madeira em papel, os aprendizes transformam dados em informações. E quanto mais dados eles têm, mais complexos são os algoritmos.

Com a crescente adoção de tecnologias de AM em diversas áreas, a atenção dada às características de qualidade das soluções desses sistemas também tem aumentado (Horkoff, 2019). Essas características, que são consideradas requisitos não funcionais (RNFs), muitas vezes estão relacionadas à funcionalidade do sistema como um todo, e não a uma funcionalidade específica. Ou seja, enquanto os requisitos funcionais descrevem o que o sistema fará, os RNFs descrevem como o sistema executará essas funções (Wiegers; Beatty, 2013).

A complexidade de um software é determinada em parte por sua funcionalidade, ou seja, o que o sistema faz, e em parte por requisitos gerais que fazem parte do desenvolvimento do software como custo, confiabilidade, manutenibilidade, portabilidade, custos operacionais, entre outros. Estes requisitos podem ser chamados de requisitos não funcionais, sendo os RNFs também conhecidos como atributos de qualidade (Cysneiros; Leite, 2001).

Os RNFs desempenham um papel crítico durante o desenvolvimento de sistemas, e erros devido a não elicitación ou à elicitación incorreta destes estão entre os mais caros e difíceis de corrigir, uma vez que um sistema tenha sido implementado (Cysneiros; Leite, 2001).

Ao analisar softwares habilitados para AM, surgem incertezas sobre a aplicabilidade do conhecimento acumulado acerca dos RNFs. Alguns RNFs, como justiça e imparcialidade, ganham ainda mais relevância nesses sistemas, enquanto outros, como privacidade, mantêm sua importância. Por outro lado, requisitos como usabilidade parecem ter um papel menos significativo. Ademais, o significado e a interpretação desses requisitos podem diferir substancialmente em comparação com sistemas tradicionais, indicando que a compreensão desses aspectos no contexto de AM ainda é limitada (Habibullah *et al.*, 2023).

Algumas pesquisas abordam diferentes aspectos da Engenharia de Requisitos para sistemas de aprendizado de máquina. (Vogelsang; Borg, 2019) exploram os desafios específicos desses sistemas, enfatizando requisitos como explicabilidade e ausência de discriminação. (Nascimento *et al.*, 2019) destacam a necessidade de maior clareza nos requisitos de dados, enquanto (Jarzębowicz; Weichbroth, 2021) investigam práticas para identificar e documentar requisitos não funcionais em projetos ágeis. Já (Villamizar, 2024) ressaltam a importância da qualidade dos dados para o desempenho de sistemas AM. Esses estudos contribuem para uma compreensão mais ampla dos desafios associados aos requisitos não funcionais em sistemas de AM, destacando a relevância da qualidade dos dados.

Neste trabalho, o foco será dado especificamente aos RNFs relacionados às características de qualidade dos dados usados em sistemas de AM, que incluem aspectos como justiça e privacidade, todos cruciais para a eficácia desses sistemas. Para isso, foram levantadas algumas questões de pesquisa:

QP1: Como os desenvolvedores percebem e lidam com as características de qualidade dos dados em projetos de Aprendizado de Máquina (AM)?

QP2: Como os desenvolvedores avaliam as características de qualidade dos dados ao longo do ciclo de vida do desenvolvimento de sistemas baseados em AM?

QP3: Quais são os principais desafios enfrentados pelos desenvolvedores em relação à qualidade dos dados em projetos de AM?

Para responder às questões de pesquisa, foi realizado um questionário cujo público específico eram profissionais da área de Aprendizagem de Máquina. Devido ao aumento da utilização dessa tecnologia na indústria e à atenção voltada para a qualidade das soluções desses sistemas, os RNFs relacionados às características de qualidade dos dados tornaram-se um ponto central de discussão em sistemas AM. Portanto, este trabalho tem como intuito analisar como os desenvolvedores de sistemas AM tratam esses requisitos, buscando compreender como

esses requisitos são interpretados, quais são mais relevantes e identificar possíveis dificuldades enfrentadas em relação a esses requisitos.

1.1 Objetivos

O objetivo geral deste trabalho é apresentar uma visão geral sobre os requisitos não funcionais (RNFs) relacionados às características de qualidade dos dados em sistemas baseados em aprendizado de máquina, a partir do ponto de vista dos desenvolvedores.

Os objetivos específicos são:

1. Identificar quais RNFs relacionados às características de qualidade dos dados são de particular importância para sistemas AM.
2. Entender como os desenvolvedores lidam com RNFs focados na qualidade dos dados em sistemas AM.
3. Identificar tendências e lacunas sobre RNFs relacionados à qualidade dos dados em sistemas AM.

O restante do trabalho está estruturado da seguinte forma. No Capítulo 2 são apresentados os principais conceitos para o desenvolvimento deste trabalho, os quais são RNFs e sistemas AM. O Capítulo 3 abrangerá uma apresentação e discussão dos trabalhos relacionados, que incluirá suas semelhanças e diferenças ao trabalho aqui proposto. No Capítulo 4 será explicada a metodologia que será aplicada para o desenvolvimento deste trabalho. No Capítulo 5 são relatados os resultados obtidos através da pesquisa. E, por fim, o Capítulo 6, que apresentará a conclusão deste trabalho e dos trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta Seção, serão apresentados os conceitos principais necessários para o entendimento deste trabalho.

2.1 Requisitos não-funcionais (RNFs)

De acordo com Wiegers e Beatty (2013) o sucesso do *software* não é apenas fornecer os recursos certos. Além disso, os usuários costumam ter grandes expectativas quanto ao desempenho do produto. Essas expectativas podem incluir facilidade de uso, velocidade de implementação, frequência de erros e capacidade de lidar com situações inesperadas. Coletivamente conhecidas como atributos de qualidade, fatores de qualidade, requisitos de qualidade ou requisitos de serviço, essas características representam a maioria dos requisitos não funcionais de um sistema. Para muitas pessoas, atributos de qualidade são sinônimos de requisitos não funcionais, mas isso é uma simplificação excessiva, pois existem outros fatores RNF que não são atributos de qualidade, como: interfaces externas restritas. Neste trabalho, consideraremos apenas RNFs do tipo característica de qualidade.

Os requisitos não funcionais dizem respeito à qualidade do serviço fornecido pelo sistema. Isso inclui, características como desempenho, disponibilidade, nível de segurança, portabilidade, proteção de dados, memória e consumo de disco, ou seja, definem restrições na funcionalidade do sistema (Valente, 2020). Com o intuito de entender melhor esses requisitos na próxima seção são citados e definidos os principais tipos de requisitos não funcionais.

2.1.1 Tipos de RNFs

Existem duas categorias para RNFs do tipo atributo de qualidade: atributos de qualidade interno e atributos de qualidade externo (Wiegers; Beatty, 2013).

Os atributos de qualidade interno, não são observáveis diretamente durante a execução do *software*. Eles são propriedades que um desenvolvedor percebe enquanto olha o design ou código do sistema, para modificá-lo. Esses atributos são classificados em eficiência, modificabilidade, portabilidade, utilização, escalabilidade e verificabilidade (Wiegers; Beatty, 2013).

Quando se fala em eficiência estamos no referindo a utilização adequada dos recursos, para maximizar os resultados pré-determinados. Exemplo: o relatório é finalizado em tempo

menor do que o esperado. Já quando falamos em modificabilidade estamos nos referindo a capacidade do software de evitar efeitos colaterais causados pelas alterações feitas no sistema (Benitti Fabiane Barreto Vavassori e Rhoden, 2015).

Falando de forma bem direta, quando nos referimos a portabilidade estamos nos referindo a capacidade do sistema de funcionar em diferentes sistemas de computador, hardware, software ou uma combinação deles (Silva, 2019)

A capacidade de reutilização indica o esforço relativo necessário para converter um componente de *software* para uso em outras aplicações. O *software* reutilizável deve ser modular, bem documentado, independente de um aplicativo e de um ambiente operacional específico e genérico em capacidade. Diferentes artefatos de projeto oferecem potencial para reutilização, incluindo requisitos, arquiteturas, designs, código, testes, regras de negócios, modelos de dados, descrições de classes de usuários, perfis de partes interessadas e termos do glossário (Wiegers; Beatty, 2013).

Os requisitos de escalabilidade tratam da capacidade do aplicativo de crescer para acomodar mais usuários, dados, servidores, localizações geográficas, transações, tráfego de rede, pesquisas e outros serviços sem comprometer o desempenho ou a exatidão do dispositivo. Já a verificabilidade refere-se a quão bem os componentes de software ou o produto integrado, podem ser avaliados para demonstrar que o sistema funciona conforme o esperado, ou seja, um requisito é verificável, se e só se, existir um processo finito e de custo aceitável através do qual uma pessoa ou uma máquina pode verificar que o produto de *software* cumpre essa exigência (Marques, 2019).

Por outro lado, os atributos de qualidade externos são aqueles medidos em termos de como o processo, produto ou recurso se relaciona como seu ambiente, ou seja, descreve características que são observadas durante a execução do software. Outro ponto importante a ressaltar, é que eles influenciam diretamente a experiência do usuário e a percepção do usuário sobre a qualidade do sistema. Esses atributos podem ser definido como disponibilidade, instalabilidade, integridade, interoperabilidade, desempenho, confiabilidade, robustez, proteção, segurança e usabilidade (Wiegers; Beatty, 2013).

A disponibilidade determina como os recursos, aqueles usados no sistema estão disponíveis. Em outras palavras que dizer, como os componentes utilizados pelo sistema serão disponibilizados para utilização (Silva, 2019).

Instalabilidade está relacionado com a capacidade de um componente ou sistema,

tem para ser instalado ou desinstalado corretamente num ambiente especificado. A partir do momento que é aumentada a capacidade de instalação de um sistema, podemos ver redução no tempo, custo, interrupção do usuário, frequência de erro e nível de habilidade necessária para uma operação de instalação (Wiegers; Beatty, 2013).

A integridade se refere a capacidade do software de impedir o acesso ou modificação de programas ou dados do computador, ou seja, os requisitos de integridade devem garantir que os dados recebidos de outros sistemas correspondam aos dados enviados e vice-versa, impedindo que os dados sofram ameaças como, perda acidental ou corrupção, apagamento acidental de arquivos ou substituição de dados pelos usuários, ataques intencionais que tentam corromper ou roubar dados (Benitti Fabiane Barreto Vavassori e Rhoden, 2015).

Interoperabilidade indica com que rapidez o sistema pode trocar dados e serviços com outros sistemas de *software* e com que facilidade pode se integrar com dispositivos de hardware externos. A probabilidade de um *software* ser executado sem falha por um período específico de tempo é conhecida como confiabilidade. Podem ocorrer problemas de confiabilidade devido a entradas inadequadas, erros no próprio código do *software*, componentes que não estão disponíveis quando necessários e falhas de hardware. Robustez e disponibilidade estão intimamente relacionadas à confiabilidade. Maneiras de especificar e medir a confiabilidade do *software*, inclui a porcentagem de operações concluídas corretamente, o tempo médio de execução do sistema antes de falhar e a probabilidade máxima aceitável de falha durante um determinado período (Wiegers; Beatty, 2013).

Do ponto de vista dos requisitos, uma maneira de tornar um sistema confiável e robusto, é especificar as condições de exceção e como elas devem ser tratadas. Exceções mal tratadas podem transmitir aos usuários uma impressão de baixa confiabilidade e usabilidade. Um site que apaga as informações que um usuário inseriu num formulário ao encontrar um único valor de entrada incorreto é exasperante. Os desenvolvedores podem tornar os sistemas mais confiáveis praticando técnicas de programação defensiva, como testar a validade de todos os valores de dados de entrada e confirmar se as operações de gravação de disco foram concluídas com êxito (Wiegers; Beatty, 2013).

Quando falamos de robustez, estamos falando da capacidade do sistema de funcionar mesmo em condições incomuns. Exemplo: um sistema médico deve permitir a visualização dos prontuários locais quando a conexão com o sistema central for perdida, indicando uma situação anormal (Benitti Fabiane Barreto Vavassori e Rhoden, 2015). Quando se tratar de obter

requisitos de robustez, é importante perguntar aos usuários sobre as condições de erro que o sistema pode encontrar, e como o sistema deve reagir, para que assim seja possível obter formas de se recuperar de determinadas falhas (Wiegers; Beatty, 2013).

A segurança tem como papel, bloquear o acesso não autorizado às funções ou dados do sistema, garantindo que o *software* esteja protegido contra-ataque de malware, já a usabilidade abrange vários subdomínios além da facilidade de uso, como facilidade de aprendizado, memorabilidade, prevenção, tratamento e recuperação de erros, eficiência das interações e acessibilidade (Wiegers; Beatty, 2013).

2.1.2 Implementação de RNFs

Para cada tipo de sistema, os designers e os programadores terão que determinar a melhor maneira de satisfazer cada requisito de qualidade. Apesar de serem requisitos não-funcionais, eles podem levar a requisitos funcionais derivados, diretrizes de projeto ou outros tipos de informações técnicas que produzirão as características desejadas do produto. A Tabela 1 indica as prováveis categorias de informações técnicas, que diferentes tipos de atributos de qualidade irão gerar (Wiegers; Beatty, 2013) .

Tabela 1 – Classificação dos atributos de qualidade por categoria de informação técnica

Atributos de qualidade	Provável categoria de informação técnica
Instalabilidade, integridade, interoperabilidade, confiabilidade, robustez, segurança, usabilidade, verificabilidade	Requisito funcional
Disponibilidade, eficiência, modificabilidade, desempenho, confiabilidade, escalabilidade	Arquitetura do sistema
Interoperabilidade, segurança, usabilidade	Restrição de projeto
Eficiência, Modificabilidade, Portabilidade, Confiabilidade, Reutilização, Escalabilidade, Verificabilidade, Usabilidade	Diretriz de design
Portabilidade	Restrição de implementação

Fonte: Adaptada de Wiegers e Beatty (2013) .

Levando em consideração a escalabilidade, que pode ser afetada pelas escolhas de arquitetura e design, os requisitos de escalabilidade podem levar o desenvolvedor a reter buffers de desempenho (espaço em disco, consumo de CPU, largura de banda da rede) para acomodar o crescimento potencial sem danificar o desempenho do sistema. As expectativas de escalabilidade podem afetar as decisões de *hardware* e ambiente operacional. É por isso que é importante

obter e documentar os requisitos de escalabilidade desde o início, para que os desenvolvedores possam garantir que o produto possa crescer conforme o esperado e ainda exibir um desempenho aceitável. Essa também é uma das razões pelas quais é importante envolver os desenvolvedores desde o início, da elicitação, as revisões de requisitos (Wiegers; Beatty, 2013).

2.1.3 Requisitos não funcionais e aprendizado de máquina

Consideramos que os requisitos não funcionais são critérios que não estão diretamente relacionados com as funcionalidades do sistema, mais que tem impacto no seu desempenho e qualidade. Quando nos referimos a aprendizado de máquina, os requisitos não funcionais passam por mudanças, como justiça, transparência, imparcialidade, explicabilidade e privacidade que se tornam mais importante, enquanto outros, como modularidade e usabilidade, podem se torna menos relevante. Podem surgir novos RNFs, como retreinabilidade. Além disso, o significado e a interpretação dos RNFS para sistemas AM podem diferir dos sistemas tradicionais e ainda não ser bem compreendidos.

2.2 Aprendizado de máquina (AM)

Na segunda metade do século XX, o AM evoluiu como um subcampo da IA que envolvia algoritmos de aprendizagem, que derivam do conhecimento de dados para fazer previsões. Neste subcampo em vez de exigir que humanos derivem regras e construam modelos manualmente a partir da análise de dados, o AM oferece uma alternativa mais eficiente para capturar o conhecimento em dados, para melhorar gradualmente o desempenho de modelos preditivos e tomar decisões baseadas em dados (Raschka; Mirjalili, 2019).

O AM é a ciência de fazer com que os computadores funcionem sem serem explicitamente programados, ou seja, o AM é um método que faz a máquina receber dados, observar esses dados e interagir a partir deles. É importante salientar que os desenvolvedores não irão ensinar, mas sim deixar que a máquina sozinha aprenda a relação entre os dados (Raschka; Mirjalili, 2019).

Segundo Chollet (2021), para descrever aprendizagem profundo e outras abordagens de aprendizado de máquina, primeiro é necessário compreender o que fazem os algoritmos de aprendizado de máquina. Portanto, para gerar aprendizado de máquina, é essencial três coisas:

1. Pontos de dados de entrada — Por exemplo, se a tarefa for reconhecimento de fala, esses

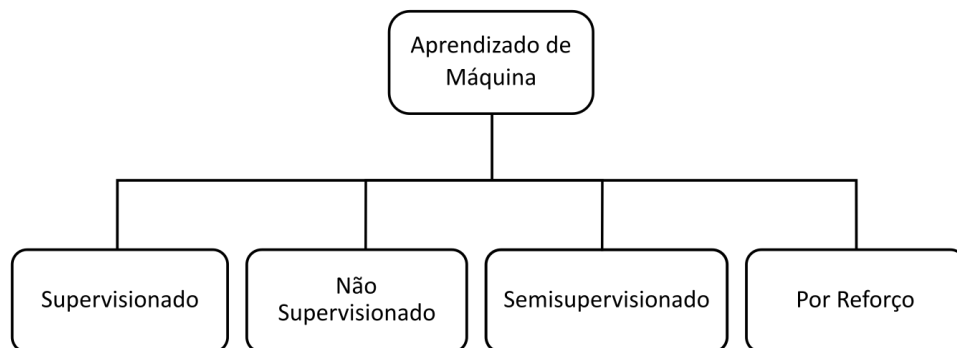
pontos de dados podem ser arquivos de som de pessoas falando. Se a tarefa for marcação de imagens, elas podem ser fotos.

2. Exemplos da saída esperada — Em uma tarefa de reconhecimento de fala, eles podem ser transcrições geradas por humanos de arquivos de som. Em uma tarefa de imagem, as saídas esperadas podem ser tags como "cachorro", "gato" e assim por diante.
3. Uma maneira de medir se o algoritmo está fazendo um bom trabalho — Isso é necessário para determinar a distância entre a saída atual do algoritmo e sua saída esperada. A medição é usada como um sinal de *feedback* para ajustar a maneira como o algoritmo funciona. Essa etapa de ajuste é chamada de aprendizado.

2.2.1 Tipos de aprendizado de máquina

A Figura 1 apresenta os quatro tipos de AM: aprendizado supervisionado, aprendizado não-supervisionado, aprendizado semi-supervisionado e aprendizado por reforço (Silva, 2020).

Figura 1 – Aprendizado de máquina



Fonte: Adaptada de Silva (2020)

O principal objetivo do aprendizado supervisionado é oferecer um modelo de dados de treinamento rotulados que podem ser usados para prever dados não vistos ou futuros. Esse termo se refere a um conjunto de amostras onde os sinais de saída já são conhecidos, ou seja, a máquina aprende a partir de resultados predefinidos usando os valores das variáveis de entrada para aprender sua saída. Tem também a classificação, uma subcategoria do aprendizado supervisionado que prever os identificadores de classe categórica de novos casos com base em observações anteriores. Esses identificadores de classe são valores discretos e não ordenados que podem ser considerados membros de um grupo de instâncias (Raschka; Mirjalili, 2019).

O aprendizado não-supervisionado é uma técnica de aprendizado de máquina onde

os modelos não são treinados usando dados de treinamento. Em vez disso, os próprios modelos encontram padrões e *sights* nos dados fornecidos, ou seja, a máquina aprende por meio de dados de teste que não foram previamente rotulados, classificados ou categorizados, e sim reconhecendo semelhanças nos dados e reagindo a cada nova informação com base na presença ou ausência de semelhanças. O objetivo do aprendizado não supervisionado é encontrar a estrutura subjacente do material, agrupar essas informações por semelhanças e apresentar esse conjunto de dados em um formato compactado (JavaTPoint, 2022).

No aprendizado semi-supervisionado, o algoritmo é treinado com base em uma combinação de dados marcados e não marcados. Normalmente, essa combinação conterá uma quantidade muito pequena de dados rotulados e uma quantidade muito grande de dados não rotulados. Nesse tipo de aprendizado, primeiro o programador agrupa os dados semelhantes, usando um algoritmo de aprendizagem não-supervisionado e em seguida, usa os dados rotulados existentes para rotular o resto dos dados não rotulados, ou seja, são unidos o aprendizado supervisionado e as técnicas de aprendizado não-supervisionado para resolver os principais desafios. Com ele, um modelo inicial é treinado com algumas amostras rotuladas e depois o aplica iterativamente ao maior número de dados não rotulados (AcervoLima, 2022).

Por fim, e não menos importante, existe o aprendizado por reforço, em que o objetivo é fazer com que a máquina aprenda com base nas interações com o meio ambiente, onde o agente realiza uma ação no ambiente, e essa ação vai ter uma recompensa, podendo ser essa recompensa positiva ou negativa. Se o agente se aproximar do objetivo sua recompensa é positiva, mas se ele se distancia do objetivo sua recompensa será negativa. Como o agente irá realizar várias ações no ambiente, isso possibilita que a máquina comece a aprender cada vez mais sobre o ambiente que está interagindo. Um exemplo popular de aprendizagem por reforço é uma máquina de xadrez. No qual o agente decide sobre uma série de movimentos, no qual dependendo do estado do tabuleiro, e a recompensa pode ser definida como, ganhar ou perder no final do jogo. Explorando mais o exemplo do xadrez, imagine em visitar certos locais no tabuleiro de xadrez associados a um evento positivo como, por exemplo, remover uma peça de xadrez do oponente do tabuleiro ou ameaçar a rainha, já outras posições, no entanto, podem ser consideradas um evento negativo, como perder uma peça de xadrez para o oponente no turno seguinte (Raschka; Mirjalili, 2019).

2.2.2 Exemplos de aplicações

Com o propósito de compreender como o aprendizado de máquina, vem sendo utilizado atualmente, em seguida será apresentado exemplo de aplicação dessa ferramenta.

2.2.3 Análise de fraude

A análise de fraudes utiliza o aprendizado por máquina para examinar todos os dados pertinentes a uma transação e atribui uma pontuação de risco à transação. Com base na pontuação de risco, faz uma recomendação para permitir a transação, bloquear a transação ou solicitar uma autenticação por etapas antes de permitir a transação. E tudo isto pode ser feito em tempo real com ou sem intervenção humana, proporcionando à instituição financeira uma maior prevenção de fraudes. Cada transação, desde o *login* até o *logout*, pode ser examinada quanto ao potencial risco de fraude (OneSpan, 2022).

2.2.4 Recomendação de conteúdo

Os Sistemas de recomendação, ou algoritmos de recomendação, são aplicações que conseguem sugerir algo a uma pessoa, com a ajuda de uma predição probabilística de que ele vai gostar da sugestão. Nesse sistema é realizado uma análise profunda para compreender padrões, correlações entre os dados e até mesmo a distância entre variáveis existentes na base de dados. Geralmente, esse algoritmo é desenvolvido de forma não supervisionada, a partir de uma visão descritiva da base de dados. Ou seja, a pessoa, no caso o cientista de dados, passa um conjunto de dados sem saídas predefinidas para os sistemas, em que o objetivo é esperar que o sistema aprenda e extraia os padrões internos já existentes para gerar saída (Somostera, 2022).

Como exemplo desse sistema podemos citar o modelo de recomendação da Netflix, em que sempre que uma pessoa entra na plataforma, ela é recebida com alguns filmes e séries recomendados. Para chegar a essas sugestões, o sistema usa dados de histórico de visualizações, avaliações, quanto tempo a pessoa assiste, a hora do dia em que vê e os dispositivos utilizados. Então, realiza um grande cruzamento colaborativo para encontrar usuários similares e recomendar a partir do que os outros veem. Outro exemplo é o Edu, um sistema para recomendar artigos para leitores, que se baseia na criação de grupos de usuários similares, a partir de outros artigos que eles avaliaram. Diante dessa similaridade, o algoritmo aplica a filtragem colaborativa para chegar ao melhor resultado e sugerir um novo item (Somostera, 2022).

2.2.5 Chatbot

No chatbot, o *software* é treinado para traduzir as informações dadas pelo usuário para um valor de saída desejado. Esses dados de entrada são analisados pelo bot, a fim de formar um contexto para identificar os elementos relevantes para reagir. A máquina pode descobrir sozinha novos padrões nos dados, extrair e salvar. Assim acontece o aprendizado.

O mecanismo NLP (Neuro-Linguistic Programming ou Programação Neuro-linguística), que pode usar AM, é composto por múltiplas bibliotecas com capacidades diversas. A função é compreender e imitar os padrões da fala, com a simulação do tom humano, o que permite interações mais íntimas. Ao receber uma fala do usuário, o NLP identifica e extrai entidades, as partes mais importantes da informação. Para isso, são usadas tarefas de processamento de linguagem natural como a *tokenização*.

A *tokenização* consiste em separar as palavras de uma frase, remover a pontuação, enquanto o reconhecimento de entidade nomeada busca por palavras em categorias predefinidas, como nomes e endereços. Já a biblioteca normalizadora consegue identificar erros ortográficos, abreviações e outras variações da escrita. Esse é o básico do NLP, mas se o objetivo for um chatbot mais complexo, serão necessários recursos adicionais capazes de entender a relação entre as palavras, estabelecer contexto e intenção (techtudo, 2021).

2.2.6 Detecção de anomalia

Da mesma forma que o AM pode identificar comportamentos anômalos em sistemas de TI, ele também pode detectar anomalias em produtos manufaturados ou itens alimentares. Em vez de contratar inspetores para examinar produtos visualmente, as fábricas podem usar sistemas de AM treinados para identificar itens que não atendem aos padrões ou especificações (Academy, 2022).

2.2.7 Logística

Para empresas de transporte, configurar horários e rotas é uma tarefa complexa e demorada. Os sistemas de AM podem ajudar a identificar a maneira mais eficiente e econômica de transportar bens ou pessoas do ponto A ao ponto B (Academy, 2022).

2.2.8 Operadoras de saúde

como importantes entidades médicas e companhias do ramo de seguros de saúde, também usam o aprendizado de máquina por meio de aparelhos e sensores que possibilitam aos médicos acessar e monitorar, em tempo real, informações sobre seus pacientes. Isso pode auxiliar na identificação de doenças ou na emissão de alerta sobre possíveis condições, permitindo que o tratamento seja iniciado mais precocemente e, potencialmente, salvando vidas (Cerri *et al.*, 2019).

2.2.9 Veículos autônomos

representam mais uma instância presente em nossa rotina que utiliza o aprendizado de máquina. A criação de algoritmos desse tipo é crucial para a operação independente desses automóveis, que necessitam de reconhecimento e processos decisórios fundamentados em informações provenientes de sensores e câmeras (Cerri *et al.*, 2019).

2.2.10 Sistemas de previsões

Uma das principais utilizações do aprendizado de máquina na atualidade está relacionada a previsões. Os algoritmos dessa tecnologia podem ser empregados para examinar dados passados, permitindo, por exemplo, estimar rapidamente a demanda por determinados produtos de maneira eficaz. Outras situações em que essa aplicação se destaca incluem a previsão de valores e o desempenho. Essas estimativas são bastante relevantes durante processos de decisão, seja em questões empresariais significativas ou na orientação sobre como os consumidores devem administrar seus gastos (Cerri *et al.*, 2019).

3 TRABALHOS RELACIONADOS

Nesta Seção, serão apresentados 4 trabalhos, julgados de maior importância para a composição deste trabalho.

3.1 *Engenharia de requisitos para aprendizado de máquina: perspectivas de cientistas de dados*

O trabalho Vogelsang e Borg (2019) descreve características e desafios exclusivos da engenharia de requisitos (ER) para sistemas baseados em aprendizado de máquina (AM). Como primeira etapa, foram conduzidas entrevistas com quatro cientistas de dados, em que cada entrevista durou cerca de uma hora. O objetivo desse estudo é entender como os profissionais de sistemas AM tratam a elicitacão, a especificacão, a garantia de requisitos e expectativas. Na entrevista foram abordados requisitos específicos para sistemas AM, como explicabilidade e ausência de discriminação, desafios envolvidos na ER para AM, e como o processo de ER precisa evoluir.

Após a entrevista foi possível chegar em algumas conclusões em relação às etapas da ER. Primeiro, a especificacão dos requisitos para esses sistemas foca nos requisitos de dados. O engenheiro de requisitos deve identificar e especificar os requisitos relativos à coleta, os formatos dos dados e os intervalos de dados. Estas informacões são coletadas do domínio do problema, e esses mesmos dados são utilizados como entrada pelos cientistas de dados, onde eles analisam as informacões fornecidas com base nos requisitos. Na verificacão e validacão é crucial definir ações que garantam os dados de treinamento realmente correspondentes aos dados reais. Como as características dos dados podem realmente mudar com o tempo, a validacão dos requisitos precisa ser executada constantemente durante a realizacão do sistema. O monitoramento e a análise dos dados em tempo de execução é essencial para manter o desempenho do sistema AM.

Com o trabalho foi concluído que a engenharia de requisitos para sistemas AM é única, devido ao paradigma diferente usado no desenvolvimento das soluções baseadas em dados. Os resultados mostraram que os cientistas de dados atualmente tomam muitas decisões para melhorar seus modelos AM, com isso eles usam e referem-se a conceitos e medidas técnicas que muitas vezes não são bem compreendidas pelo cliente. A principal conclusão é que os engenheiros de requisitos precisam conhecer as novas categorias de requisitos, como, por exemplo, explicabilidade. Ao final do estudo, os entrevistados foram apresentados a uma lista

de melhores práticas da ER e questionados sobre as melhores práticas que eles usam em seus projetos.

3.2 *Noções básicas sobre o processo de desenvolvimento de sistemas de aprendizado de máquina: desafios e soluções*

O trabalho de Nascimento *et al.* (2019) busca identificar como a Engenharia de Software (ES) pode apoiar melhor os desenvolvedores de sistemas AM. Com isso, o objetivo do trabalho é dividido em duas partes. Entender melhor o processo que os desenvolvedores utilizam para construir os sistemas AM e identificar os principais desafios que os desenvolvedores enfrentam, e assim propor maneiras de superá-los. Esse estudo foi conduzido por meio de entrevista, realizada com sete desenvolvedores de três pequenas empresas de software que desenvolvem sistemas AM. Na entrevista foram realizadas três perguntas: como os desenvolvedores de software constroem sistemas AM em pequenas empresas? Quais desafios são percebidos pelos desenvolvedores durante o desenvolvimento de sistemas AM, em pequenas empresas? É possível auxiliar os desenvolvedores a superar esses desafios?

A Partir das respostas obtidas na entrevista, foi realizado um estudo qualitativo para identificar como as equipes de pequenas empresas desenvolvem sistemas AM, e quais são os desafios percebidos no desenvolvimento de tais sistemas. Ao finalizar o estudo foi possível concluir que o processo de desenvolvimento dos sistemas AM das empresas segue normalmente quatro etapas. Entendimento do problema; tratamento dos dados; construção do modelo; e Monitoramento do modelo. Os principais desafios enfrentados pelos profissionais entrevistados são: dificuldade em identificar métricas de negócios, falta de um processo definido e dificuldade de projetar a estrutura do banco de dados. Com o auxílio do grupo focal, foi verificado que a lista de verificação proposta fornece suporte durante a identificação das métricas de negócio do cliente e no aumento de visibilidade do andamento das tarefas do projeto.

3.3 *Estudo qualitativo sobre requisitos não funcionais no desenvolvimento ágil de software*

O trabalho de Jarzębowicz e Weichbroth (2021) procura identificar e investigar as práticas utilizadas em projetos industriais de desenvolvimento ágil de software para identificar, eliciar e documentar RNFs. A metodologia utilizada nesse estudo, foi uma revisão sistemática da

literatura, em que os resultados da revisão serviu de base para preparação de um guia de entrevista. Ao finalizar o guia de entrevista, foi realizada uma série de entrevistas semiestruturada com 10 praticantes de desenvolvimento ágil. Completada a revisão sistemática, foram definidas três questões de pesquisa. Quando os requisitos não-funcionais são identificados no ciclo de vida do projeto? Como os requisitos não-funcionais são elicitados? Como os requisitos não-funcionais são documentados?

Para responder às questões de pesquisa, foi utilizado uma abordagem qualitativa, que aconteceu em duas etapas subsequentes, uma revisão sistemática da literatura, e uma série de entrevistas com praticantes ágeis. Na primeira etapa, foi identificado e registrado as práticas descritas na literatura, e na segunda foi desenvolvido um protocolo de orientações para entrevistas semiestruturadas com praticantes ágeis.

Ao final do trabalho foi concluído que os RNFs são identificados no ciclo de vida do projeto, mostrando que não há consenso sobre esse assunto entre os profissionais. Apenas um entrevistado afirmou que os RNFs são identificados de maneira contínua, em cada iteração e segundo os processos iterativos de desenvolvimento ágil. A maioria dos entrevistados relatou que suas organizações optam pela identificação precoce dos RNFs. O único consenso observado diz respeito à importância dos RNFs e a atitude de identificá-los de forma abrangente, de modo a reduzir riscos significativos para o projeto de software.

3.4 Identificação de preocupações ao especificar sistemas habilitados para aprendizado de máquina: uma abordagem baseada em perspectiva

O trabalho de (Villamizar, 2024) aborda o impacto da qualidade dos dados no desenvolvimento de sistemas de Aprendizado Profundo e sua relação com Engenharia de Requisitos (ER). Tradicionalmente, requisitos são especificados em documentos como Software Requirements Specification (SRS) e avaliados com base em critérios como completude, consistência e verificabilidade. No entanto, no contexto de DL, os dados assumem um papel central como requisitos fundamentais para o funcionamento dos modelos. O estudo propõe que, em vez de somente corrigir falhas nos requisitos, é necessário explorar atributos inerentes à qualidade dos dados, como precisão, consistência e atualidade, para avaliar e melhorar os sistemas de DL.

Para validar essa abordagem, os autores conduziram um estudo de caso com o Metropolitan Sewer District of Greater Cincinnati (MSDGC), analisando o impacto da qualidade dos dados na previsão de transbordamento de esgoto combinado (Combined Sewer Overflow

- CSO). Foi utilizado um modelo de rede neural recorrente (RNN) para prever o fluxo de esgoto com base em dados temporais multivariados coletados por sensores. O estudo focou na estacionaridade dos dados, um atributo essencial para garantir previsões consistentes. A metodologia incluiu a aplicação de um teste metamórfico, onde os dados foram propositalmente alterados para avaliar como variações na qualidade dos dados impactam a performance do modelo de DL.

3.5 *Análise Comparativa*

O trabalho de Vogelsang e Borg (2019) foca em definir características e desafios da Engenharia de Requisitos para sistemas baseados em AM, para isso é realizado uma entrevista com quatro cientistas de dados, e o trabalho Nascimento *et al.* (2019) busca compreender como a Engenharia de software pode apoiar melhor o desenvolvimento de sistemas AM. Para tal fim foi conduzida entrevistas com sete desenvolvedores de três pequenas empresas de software que desenvolvem sistemas AM. Já este trabalho busca compreender como os desenvolvedores de sistemas AM lidam com os requisitos não-funcionais para sistemas baseados em AM. Para esse fim, um questionário será enviado aos desenvolvimento de sistemas AM de pequenas e grandes empresas.

O trabalho de Jarzębowicz e Weichbroth (2021) procura identificar e investigar as práticas de engenharia de requisitos em projetos, que utiliza métodos ágeis de desenvolvimento de *software* para compreender como os requisitos não-funcionais são identificados, elicitados e documentado. O trabalho proposto também realiza um estudo sobre requisitos não funcionais. A diferença é que ele busca compreender como esses requisitos são tratados pelos desenvolvedores de sistemas AM. Outra diferença é a técnica utilizada para levantamento de dados, que vai ser por meio de questionário disponibilizado em redes sociais e contatos já conhecidos e não por entrevistas. Já o trabalho de (Villamizar, 2024) discute a importância da qualidade dos dados como um fator essencial para o desempenho dos sistemas de Deep Learning (DL), argumentando que os dados devem ser tratados como requisitos fundamentais. Enfatiza que na engenharia de requisitos para DL, os desafios são diferentes, pois os sistemas dependem fortemente de grandes volumes de dados em vez de especificações documentadas, enquanto o trabalho proposto foca nos requisitos não funcionais para sistema AM, buscando assim compreender quais são os desafios relacionados as características de qualidade dos dados em sistemas AM.

As semelhanças entre os trabalhos apresentados e este trabalho, é que todos buscam

contribuir com novos conhecimentos para uma determinada área, seja ela para sistemas de aprendizado de máquina ou para métodos ágeis de desenvolvimento de *software*. Em que esses novos conhecimentos vão apoiar tanto os desenvolvedores como a indústria no processo de desenvolvimento de sistemas.

Tabela 2 – Análise comparativa entre trabalhos relacionados e este trabalho

Características	(Vogelsang; Borg, 2019)	(Nascimento <i>et al.</i> , 2019)	(Jarzębowicz; Weichbroth, 2021)	(Villamizar, 2024)	Trabalho proposto
Método de coleta	Entrevista	Entrevista	Revisão sistemática e entrevista	Estudo de caso	Questionário
Público alvo	Desenvolvedores de sistemas AM	Desenvolvedores de sistemas AM	Desenvolvedores de sistemas	cientistas de dados, engenheiros de software, project managers	Desenvolvedores de sistemas AM
Tipo de análise	Qualitativa	Qualitativa	Qualitativa	Qualitativa	Quantitativa e qualitativa
Escopo	Engenharia de requisitos	Engenharia de software	Desenvolvimento ágil	Engenharia de requisitos e aprendizado profundo	Requisitos não funcionais

Fonte: Elaborado pela autora deste trabalho.

A Tabela 2 acima apresenta uma análise comparativa entre estudos relacionados e o presente trabalho, destacando quatro dimensões principais: método de coleta de dados, público-alvo, tipo de análise e escopo.

Método de Coleta: Os estudos analisados utilizaram entrevistas, revisões sistemáticas da literatura e estudos de caso para obtenção de dados. O presente trabalho, por sua vez, adota um questionário como principal instrumento de coleta.

Público-alvo: A maioria dos trabalhos foca em desenvolvedores de sistemas AM, enquanto um dos estudos analisados tem como público pesquisadores e acadêmicos.

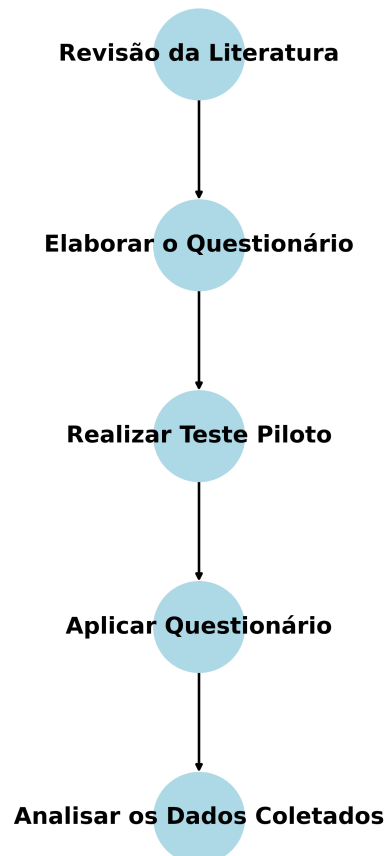
Tipo de Análise: A abordagem predominante nos trabalhos revisados é qualitativa, enquanto o presente estudo combina análises qualitativas e quantitativas para obter uma visão mais abrangente.

Escopo: Os estudos analisados abrangem diversas áreas, como engenharia de requisitos, engenharia de software e desenvolvimento ágil. O trabalho proposto se diferencia ao focar especificamente em RNFs relacionados à qualidade dos dados em sistemas AM.

4 METODOLOGIA

Nesta Seção, são apresentadas as etapas necessárias para a realização deste trabalho. A Figura 3 fornece uma visão geral do fluxo dessas etapas. A seguir, cada uma delas é descrita em detalhes.

Figura 2 – Fluxo de fases deste trabalho



Fonte: Elaborado pela autora deste trabalho.

4.1 Criar o questionário

Após a revisão da literatura, cujo objetivo foi aprofundar o entendimento sobre Aprendizado de Máquina e requisitos não funcionais, o próximo passo foi a elaboração do questionário no Google Forms. O questionário foi estruturado com vinte e três perguntas, abrangendo dados demográficos, questões relacionadas a requisitos não funcionais e aspectos do Aprendizado de Máquina. Antes dessas seções, foi inserida uma introdução contendo informações sobre o propósito da pesquisa, os pesquisadores envolvidos e o Termo de Consentimento Livre e

Esclarecido (TCLE).

A construção do questionário foi feita com o objetivo de responder às três questões de pesquisa:

QP1: *Como os desenvolvedores percebem e lidam com as características de qualidade dos dados em projetos de Aprendizado de Máquina (AM)?* Essa questão busca compreender a percepção dos desenvolvedores em relação à qualidade dos dados em projetos de AM. Especificamente, investiga quais aspectos da qualidade dos dados são mais relevantes para eles, como avaliam a adequação dos dados para o projeto e se há uma preocupação explícita com essas características ou se elas são consideradas secundárias no processo de desenvolvimento.

QP2: *Como os desenvolvedores avaliam as características de qualidade dos dados ao longo do ciclo de vida do desenvolvimento de sistemas baseados em AM?* O objetivo dessa questão é analisar em que momentos e de que maneira os desenvolvedores avaliam a qualidade dos dados durante as diferentes fases do ciclo de vida de um projeto de AM. Isso inclui identificar práticas adotadas, metodologias utilizadas e possíveis lacunas na verificação da qualidade dos dados ao longo do desenvolvimento.

QP3: *Quais são os principais desafios enfrentados pelos desenvolvedores em relação à qualidade dos dados em projetos de AM?* Essa questão visa identificar os principais obstáculos e dificuldades que os desenvolvedores enfrentam na prática ao lidar com a qualidade dos dados. Entre os desafios possíveis, destacam-se barreiras técnicas, falta de ferramentas adequadas, problemas organizacionais e dificuldades para garantir a conformidade dos dados com os requisitos de qualidade necessários.

O questionário foi elaborado para investigar a percepção e a experiência dos participantes em relação à qualidade de dados em projetos de aprendizado de máquina. A estrutura permite uma análise abrangente, desde o perfil dos participantes até a forma como a qualidade dos dados é tratada no desenvolvimento de soluções baseadas em IA. Ele está organizado em quatro seções principais:

4.1.1 Caracterização geral do participante

O objetivo é coletar informações demográficas e profissionais dos respondentes, permitindo uma análise do perfil dos participantes.

- Q1 a Q4: Perguntas sobre idade, localização, gênero e nível de escolaridade ajudam a contextualizar a diversidade do grupo de respondentes.

- Q5 a Q7: Questões sobre o papel na equipe, senioridade e número de projetos em que já atuou ajudam a entender o nível de experiência do participante em aprendizado de máquina.

4.1.2 Experiência com qualidade de dados

O objetivo é avaliar o nível de familiaridade do participante com o processamento e a qualidade dos dados.

- Q8: Pergunta sobre a habilidade em tarefas de processamento de dados, buscando identificar a experiência prática do participante com o tema.

4.1.3 Percepção da qualidade de dados como requisito

O objetivo foi investigar como os participantes conceituam qualidade de dados e a importância que atribuem a diferentes características.

- Q9: Questiona sobre as primeiras palavras que vêm à mente ao pensar em qualidade de dados, ajudando a mapear associações espontâneas com o tema.
- Q10: Explora a experiência do participante com Engenharia de Requisitos, verificando se já participou desse processo.
- Q11: Pede para classificar a importância de diferentes características de qualidade dos dados.
- Q12 e Q14: Solicitam justificativas para as características consideradas mais importantes e prioritárias, respectivamente.
- Q13: Questiona como os participantes priorizam características de qualidade dos dados, fornecendo insights sobre critérios de decisão.
- Q15: Explora como os participantes equilibram precisão, compreensibilidade e eficiência computacional, aspectos fundamentais no uso de dados.
- Q16: Pergunta sobre o impacto do controle de versão dos dados na qualidade, buscando entender a percepção sobre esse fator crítico.

4.1.4 Implementação de requisitos no desenvolvimento

Para compreender como os requisitos de qualidade de dados são aplicados no dia a dia do desenvolvimento de projetos de aprendizado de máquina.

- Q17: Investiga como a qualidade dos dados é incorporada ao processo de desenvolvimento.
- Q18: Pergunta como os participantes medem o impacto da qualidade dos dados no desempenho dos modelos.
- Q19: Questiona a frequência com que o tema qualidade dos dados é discutido nos projetos, avaliando sua relevância prática.
- Q20: Analisa como questões de qualidade dos dados são documentadas e comunicadas.
- Q21: Identifica desafios enfrentados para garantir a confiabilidade dos dados.
- Q22: Pergunta sobre a frequência de suporte recebido de outras equipes para tratar questões de qualidade de dados.
- Q23: Dá a opção de os participantes fornecerem seu e-mail para receber os resultados e participarem de uma entrevista futura.

4.2 Executar o teste piloto

Após a elaboração inicial do questionário, foi realizado um teste piloto visando avaliar a qualidade das questões formuladas. Para isso, o questionário foi enviado a dois profissionais especializados: um engenheiro de dados, mestre em Informática, um bacharel em engenharia de software e doutorando em ciências da computação. Com base no feedback recebido, efetuamos ajustes significativos para aprimorar a pesquisa. As correções incluíram a revisão das perguntas, com a remoção de questões redundantes, bem como a adição de novas perguntas para melhorar a clareza e a relevância do conteúdo. A versão final do questionário que conta com as 23 perguntas está apresentada na Tabela 3, onde as questões foram organizadas e identificadas por um código único (ID), sendo também classificadas em categorias específicas para facilitar a análise.

Tabela 3 – Survey

ID	Perguntas
Caracterização geral do participante	
Q1	Qual é a sua idade?
Q2	Em qual estado você reside atualmente?
Q3	Qual é o seu gênero?
Q4	Qual é o seu nível de escolaridade?
Q5	Qual papel melhor descreve sua atuação em projetos de aprendizado de máquina?
Q6	Qual a sua senioridade na equipe?
Q7	Quantos projetos de aprendizado de máquina você já participou?
Experiência com qualidade de dados	
Q8	Como você classifica sua habilidade em tarefas de processamento de dados?
Percepção da qualidade de dados como requisito	
Q9	Quais são as cinco primeiras palavras que vêm à sua mente quando pensa em qualidade de dados?
Q10	Qual é sua experiência com Engenharia de Requisitos? Já participou desse processo?
Q11	Qual o nível de importância das seguintes características de qualidade dos dados?
Q12	Para as características que você considerou importantes, justifique sua escolha.
Q13	Como você prioriza as características de qualidade dos dados?
Q14	Para as características que você considerou prioritárias, justifique sua escolha.
Q15	Como você equilibra precisão, compreensibilidade e eficiência computacional?
Q16	Como o controle de versão dos dados impacta a qualidade dos dados?
Implementação de requisitos no desenvolvimento	
Q17	Como a qualidade dos dados é incorporada no processo de desenvolvimento?
Q18	Como você mede o impacto da qualidade dos dados no desempenho do modelo?
Q19	Com que frequência a qualidade dos dados é discutida nos projetos?
Q20	Como você documenta e comunica questões de qualidade dos dados?
Q21	Quais são os principais desafios para garantir a confiabilidade dos dados?
Q22	Com que frequência você recebe suporte de outras equipes sobre qualidade dos dados?
Q23	Se deseja receber os resultados deste estudo e participar de uma futura entrevista, informe seu e-mail.

Fonte: Elaborado pela autora deste trabalho.

4.3 Coleta de Dados

Após as revisões necessárias, o questionário foi disponibilizado online no idioma: português. O público-alvo incluiu profissionais com experiência no desenvolvimento de sistemas baseados em aprendizado de máquina, seja atualmente ou no passado. A divulgação ocorreu por meio de grupos especializados em aprendizado de máquina, do LinkedIn dos pesquisadores e de contatos previamente estabelecidos.

O formulário esteve disponível entre 13 de fevereiro e 1º de março de 2025, período no qual foram coletadas 23 respostas. A análise dos resultados foi realizada a partir de abordagens quantitativas e qualitativas, permitindo uma compreensão abrangente das percepções dos participantes.

4.4 Análise dos Dados

A análise dos dados neste trabalho foi realizada por meio de uma abordagem quantitativa e qualitativa. A avaliação quantitativa foi conduzida com base nas respostas fechadas do questionário, possibilitando a identificação de padrões e tendências nas percepções dos participantes. Esta avaliação incluiu a contagem de respostas, o cálculo de porcentagens e a utilização de gráficos para ilustrar a relevância atribuída às diferentes características de qualidade dos dados, como precisão, consistência e credibilidade. As respostas foram organizadas e analisadas estatisticamente para compreender a distribuição das opiniões e identificar quais características eram mais valorizadas pelos desenvolvedores.

A análise qualitativa concentrou-se nas respostas discursivas do questionário, visando compreender os fundamentos das escolhas dos participantes. Essa fase envolveu a leitura minuciosa das justificativas apresentadas, a identificação de temas recorrentes e a categorização dessas respostas em tópicos específicos. Essa análise interpretativa procurou captar não somente o que os desenvolvedores consideraram relevante, mas também os motivos e os contextos dessas percepções.

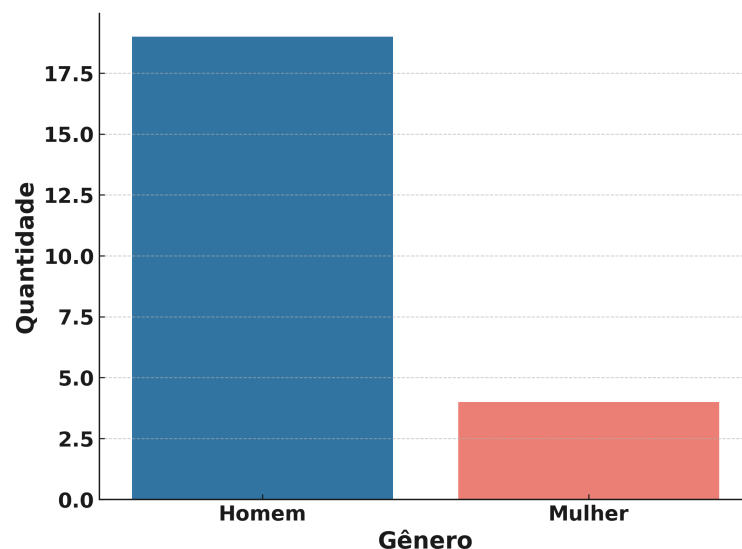
5 RESULTADOS

Este Capítulo apresenta os achados da pesquisa sobre a percepção dos desenvolvedores em relação aos requisitos não funcionais ligados à qualidade dos dados em sistemas de Aprendizado de Máquina. São abordadas a caracterização dos participantes, a importância dos atributos de qualidade dos dados e os desafios enfrentados na sua implementação. Por fim, os resultados são sintetizados para responder às questões de pesquisa, destacando práticas e dificuldades no desenvolvimento de sistemas AM.

5.1 Caracterização geral dos participantes

Nesta Seção, apresentaremos informações básicas e dados pessoais dos participantes, com o objetivo de compreender melhor seus perfis.


Figura 3 – Distribuição de gênero



Fonte: Elaborado pela autora deste trabalho.

Conforme demonstrado na Figura 3, a amostra foi composta majoritariamente por homens (82,6%), seguidos por mulheres (17,4%). Esses dados indicam que a maioria dos participantes se identifica com o gênero masculino.


Figura 4 – Distribuição dos papéis no desenvolvimento de sistemas baseados em AM



Fonte: Elaborado pela autora deste trabalho.

Ao analisar a Figura 4, que representa a distribuição dos papéis no desenvolvimento de sistemas baseados em AM, observa-se a colaboração de profissionais de diversas áreas. A maior parte das respostas foi de cientistas de dados (52,2%), seguidos por desenvolvedores de software (34,8%) e engenheiros de dados (4,3%). Além disso, a amostra também inclui engenheiros de Machine Learning e gerentes de produto, evidenciando a diversidade de perfis entre os participantes.

Figura 5 – Distribuição de idade



Fonte: Elaborado pela autora deste trabalho.

Ao analisar a distribuição etária dos participantes, observa-se que a faixa de 25 a 34 anos (56,5%) representa a maior parcela da amostra, indicando que essa é a idade predominante

entre os respondentes. Faixas etárias superiores aparecem com percentuais menores, sugerindo uma diversidade de idades, embora haja uma concentração significativa nesse intervalo específico.


Além disso, o estudo contou com a participação de profissionais de diferentes estados brasileiros, incluindo Ceará, Alagoas, Bahia, Paraíba, Pernambuco, São Paulo, Rio de Janeiro e Rio Grande do Sul.

Em relação ao grau de instrução, a maioria dos participantes possui graduação e doutorado (26,1%), seguidos por alunos de mestrado e doutorado (17,4%) e profissionais com mestrado concluído (8,7%). Essa diversidade geográfica e acadêmica evidencia o amplo interesse e envolvimento de profissionais em projetos de aprendizado de máquina no Brasil.

5.2 Caracterização da experiência com qualidade de dados em sistemas baseados em aprendizado de máquina


O objetivo desta seção é descrever e analisar como os participantes da pesquisa percebem e lidam com a qualidade dos dados durante o desenvolvimento e manutenção de sistemas baseados em Aprendizado de Máquina (AM).

Figura 6 – Limpeza de dados



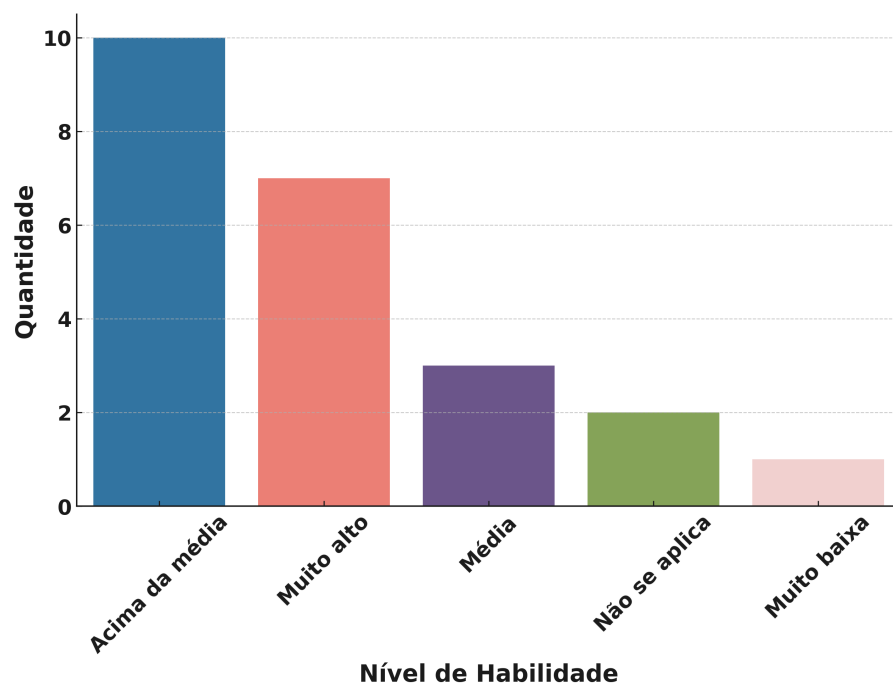
Fonte: Elaborado pela autora deste trabalho.

Figura 7 – Integração de multipla fontes de dados



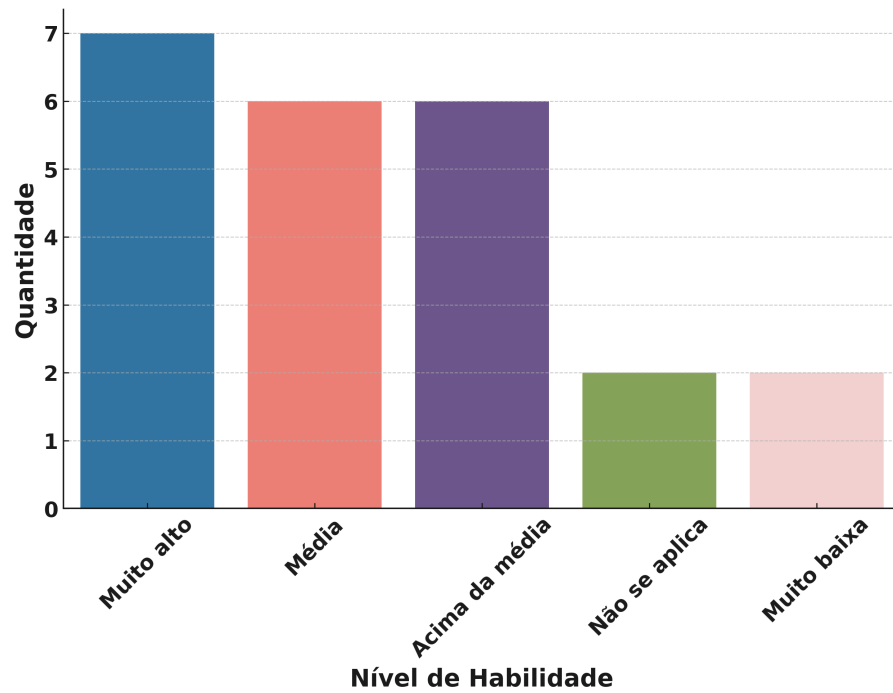
Fonte: Elaborado pela autora deste trabalho.

Figura 8 – Normalização ou padrinonização de dados




Fonte: Elaborado pela autora deste trabalho.

Figura 9 – Detecção e remoção de outliers



Fonte: Elaborado pela autora deste trabalho.

Figura 10 – Aplicação de técnicas de transformação de dados



Fonte: Elaborado pela autora deste trabalho.

As Figuras 6, 7, 8, 9 e 10 apresentam a distribuição das respostas dos participantes sobre seu nível de habilidade em diversas atividades relacionadas ao processamento de dados

em sistemas de aprendizado de máquina. As atividades analisadas incluem limpeza de dados, transformação de dados, integração de dados, redução de dimensionalidade, balanceamento de dados, análise exploratória de dados, seleção de características, detecção e tratamento de outliers, análise de correlação entre variáveis e automatização de tarefas de processamento de dados.

De maneira geral, os gráficos indicam que os participantes possuem uma sólida experiência em tarefas de processamento de dados, especialmente em aspectos fundamentais como limpeza de dados, análise exploratória e automação de processos. Essas atividades são essenciais para garantir a qualidade dos dados e influenciam diretamente o desempenho dos modelos de aprendizado de máquina. No entanto, atividades mais avançadas, como redução de dimensionalidade e seleção de características, apresentam maior variação nas respostas, sugerindo que, embora muitos participantes tenham familiaridade com essas técnicas, ainda há oportunidades para aprimoramento e especialização.

Além disso, a baixa incidência de respostas nos níveis iniciais reforça a percepção de que a maioria dos participantes já possui um grau considerável de experiência no campo do aprendizado de máquina. Esse perfil experiente da amostra sugere que os desafios e dificuldades relatados pelos respondentes são baseados em vivências práticas e não somente em conhecimento teórico, tornando as informações obtidas ainda mais relevantes para a compreensão das demandas reais enfrentadas por profissionais da área.

5.3 Percepção da qualidade de dados como requisitos de sistemas baseados em aprendizado de máquina

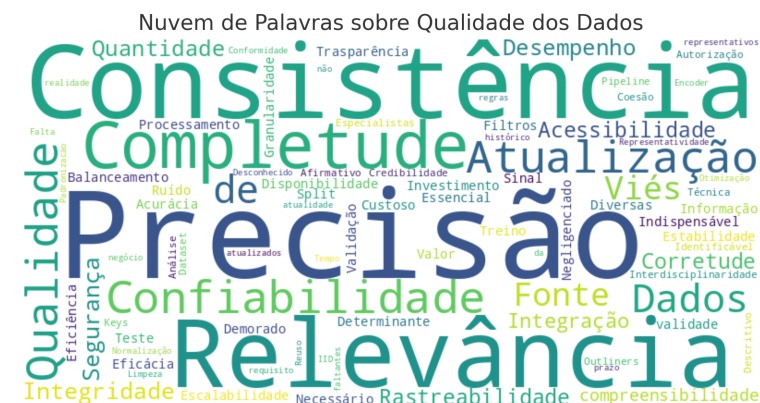
Nesta seção é analisado e discutido como os participantes enxergam a qualidade dos dados como um componente essencial dos requisitos não funcionais em sistemas de Aprendizado de Máquina (AM).

Quando solicitamos aos participantes que listassem as cinco primeiras palavras que lhes vêm à mente ao pensar na qualidade dos dados como um requisito em projetos de aprendizado de máquina, as respostas mais frequentes incluíram termos como: *consistência*, *precisão*, *relevância*, *atualização* e *confiabilidade*. Esses termos refletem aspectos essenciais para garantir que os dados utilizados em modelos de aprendizado de máquina sejam adequados, eficazes e proporcionem resultados confiáveis. A *consistência* e a *precisão* são frequentemente vistas como fundamentais para a integridade dos dados, enquanto a *relevância* e a *atualização* indicam a importância de trabalhar com dados que sejam pertinentes e recentes. Já a *confiabilidade* destaca

a necessidade de garantir que os dados sejam verdadeiros e possam ser usados sem comprometer a qualidade dos modelos.

A Figura 11 ilustra visualmente todas as palavras mencionadas pelos participantes, destacando aquelas que foram citadas com maior frequência. Através dessa representação, é possível observar de maneira clara quais atributos são mais valorizados pelos profissionais quando consideram a qualidade dos dados, proporcionando uma visão importante sobre as prioridades do grupo em relação aos requisitos de dados em projetos de aprendizado de máquina.

Figura 11 – Nuvem de palavras



Fonte: Elaborado pela autora deste trabalho.

5.3.1 Experiência dos Participantes com Engenharia de Requisitos

Para avaliar o conhecimento dos participantes sobre as práticas de Engenharia de Requisitos em projetos de aprendizado de máquina, foi solicitado que descrevessem brevemente suas experiências relacionadas ao tema. As respostas revelaram uma ampla variedade de vivências, abrangendo desde a ausência total de experiência até o envolvimento ativo em todas as etapas do ciclo de vida dos projetos.

Alguns participantes relataram participação em processos formais de registro e documentação de requisitos, abordando tanto especificações funcionais quanto não funcionais. Esses processos incluíam a definição clara dos objetivos do sistema, a identificação das necessidades dos stakeholders e a elaboração de critérios de aceitação. Por outro lado, houve participantes cujo envolvimento foi mais restrito, limitando-se à coleta de requisitos iniciais ou à documentação de dependências técnicas, como bibliotecas, APIs e ferramentas específicas utilizadas no desenvolvimento dos modelos de aprendizado de máquina.

Os resultados evidenciam que a Engenharia de Requisitos ainda é percebida de ma-

neira heterogênea dentro desse campo, com alguns profissionais adotando práticas estruturadas, enquanto outros atuam de forma mais informal e adaptativa, dependendo das necessidades do projeto e do nível de maturidade da equipe.

Dentre aqueles com experiência em Engenharia de Requisitos, destacam-se relatos de participação em várias atividades cruciais para o sucesso de projetos de aprendizado de máquina:

- **Elicitação de requisitos:** Muitos participantes mencionaram a utilização de métodos como análise de documentos e entrevistas semiestruturadas para levantar as necessidades dos stakeholders e entender os objetivos do projeto. Esses métodos permitiram a coleta de informações detalhadas e relevantes, essenciais para o desenvolvimento de sistemas eficazes.
- **Definição e refinamento de requisitos:** Outro ponto comum foi a participação em discussões com as equipes de desenvolvimento, com o intuito de alinhar expectativas e capacidades técnicas. Esses debates ajudaram a garantir que os requisitos fossem viáveis dentro do escopo e das limitações do projeto.
- **Documentação de requisitos para modelos de aprendizado de máquina:** Um caso específico relatado por um participante envolveu a ausência de requisitos claros para os modelos de aprendizado de máquina. Isso gerou desafios de alinhamento com os stakeholders, pois as expectativas não estavam bem definidas. Em resposta, o participante tomou a iniciativa de definir e documentar esses requisitos, o que resultou em melhorias significativas na qualidade dos testes e das métricas aplicadas, garantindo um melhor desempenho e consistência nos modelos desenvolvidos.

Por outro lado, uma parcela dos respondentes indicou não possuir experiência prática com Engenharia de Requisitos. Para esses participantes, suas contribuições se limitaram a atividades mais indiretas, como a documentação de código ou a participação em auditorias conduzidas por outros times, com o foco em garantir conformidade com padrões técnicos ou regulatórios, mas sem envolvimento direto na definição e gerenciamento de requisitos.

Trazendo algumas respostas de alguns participantes, temos:

***P1.** Ainda não tive experiência com requisitos em projetos maiores, somente em trabalhos acadêmicos.*

***P2.** Nesse caso, minha experiência nessa parte é mais voltada para a documentação do código e na criação de diagramas referentes a pipelines, já participei de algumas auditorias*

feitas pelo time de requisitos, mas não me considero uma pessoa com experiência na área.

P3. *Trabalho em um projeto há dois anos onde desenvolvemos uma ferramenta que utiliza ML e visão computacional. Durante esses dois anos só foram levantados requisitos dos softwares que envolviam a ferramenta (web, mobile, api) mas não do modelo de ML em si, que era desenvolvido exclusivamente pela equipe de IA. Apenas durante os últimos meses levantei a necessidade de termos requisitos claros estabelecidos para o modelo, para alinhar o comportamento e performance. Realizei pessoalmente, com auxílio do time de QA, a definição e documentação de requisitos do modelo. A partir disso, ficou muito claro como e o que era necessário testar no modelo para garantir a qualidade. Isso nos permitiu ir além das métricas tradicionais obtidas com hold-out validation e obter análises mais completas.*

Esta variedade de respostas evidencia que, embora a Engenharia de Requisitos seja amplamente reconhecida como uma prática crucial para o sucesso de projetos de aprendizado de máquina, sua aplicação prática ainda apresenta uma grande variação. Essa variação é influenciada por diversos fatores, como o ambiente organizacional, que pode determinar a formalidade ou flexibilidade dos processos, e o grau de maturidade dos processos de desenvolvimento implementados nas equipes. Em organizações mais maduras, com processos bem definidos, a Engenharia de Requisitos tende a ser mais estruturada e amplamente adotada, enquanto em equipes com menor maturidade, a prática pode ser menos formalizada, com ênfase em métodos ágeis ou abordagens mais adaptativas.

5.3.2 grau de importância e prioridade atribuída a diferentes características de qualidade dos dados em projetos de aprendizado de máquina

As características analisadas incluem: Precisão, Completude, Consistência, Credibilidade, Atualidade, Acessibilidade, Conformidade, Confiabilidade, Eficiência, Rastreabilidade, Compreensibilidade, Disponibilidade e Recuperabilidade.

Respostas de participantes sobre a importância das características de qualidade dos dados:

P10. *Para mim todas as características são de extrema importância, pois a garantia delas influenciam muito positivamente o desenvolvimento de sistemas que utilizam aprendizado de máquina. Dados de má qualidade (e aqui má qualidade vai desde a falta de disponibilidade a dados com pouca precisão e pouco representativos) são um grande problema na área e dificultam o desenvolvimento de novas técnicas.*

***P12.** Todas as características são importantes ou muito importantes. A separação que fiz foi mais pensando em algo que podemos fazer/corrigir em um segundo momento ou algo que é fundamental de ser pensado desde o início. Considero que algo que se reflete na qualidade dos dados, da informação presente naquele dado são coisas inegociáveis desde o momento inicial. Já questões de documentação, tornar esses dados acessíveis e consistentes entre diferentes base de dados podem ser corrigidas no decorrer do processo, apesar de serem também muito importantes.*

Respostas de participantes em relação ao grau de prioridade das características e qualidade dos dados:

***P14.** São as características que vejo como essenciais para reproduzir técnicas, seja para fins de pesquisa ou mercado. A garantia delas influencia também em um desenvolvimento mais rápido.*

***P20.** Consigo imaginar diversos cenários em que todas essas palavras são extremamente essenciais também. Mas vai depender demais do projeto em questão, então prefiro colocar neutro.*

Com base nas respostas dos participantes, pode-se concluir que Precisão, Consistência e Confiabilidade foram amplamente reconhecidas como as características mais importantes para a qualidade dos dados em projetos de aprendizado de máquina, recebendo a maior parte das respostas classificadas como “Muito relevante”. Em contraste, atributos como Acessibilidade, Recuperação e Rastreabilidade foram frequentemente classificados nos níveis “Neutro” ou “Pouco relevante”, sugerindo que são considerados menos essenciais em comparação com aspectos diretamente ligados à exatidão e à consistência dos dados. Além disso, Atualidade e Eficiência foram avaliadas como relevantes, embora com menor ênfase em relação às características mais críticas.

Por outro lado, Conformidade e Credibilidade mostraram um equilíbrio entre os níveis “Muito importante” e “Importante”, indicando que, embora essas características sejam vistas como significativas, não são consideradas prioritárias. Dessa forma, conclui-se que Precisão, Consistência e Confiabilidade são os atributos mais valorizados para garantir a qualidade dos dados em aprendizado de máquina, enquanto Acessibilidade e Recuperabilidade são considerados de menor importância, com maior foco nas características que impactam diretamente o desempenho dos modelos.

Ao analisar a prioridade das características, observa-se que atributos como Precisão,


Consistência, Confiabilidade, Credibilidade e Completude são considerados os mais essenciais para assegurar a qualidade dos dados em projetos de aprendizado de máquina. Em contrapartida, características como Rastreabilidade, Compreensão, Disponibilidade e Recuperação foram vistas como relevantes, mas com prioridade moderada ou baixa.

Esses resultados indicam que os especialistas tendem a valorizar mais os elementos que impactam diretamente o desempenho e a confiabilidade dos sistemas de aprendizado de máquina, enquanto aspectos relacionados à acessibilidade e entendimento dos dados recebem menor atenção.

5.4 Implementação de requisitos de qualidade de dados no processo de desenvolvimento

Ao questionar os participantes sobre como a qualidade dos dados é incorporada no processo de desenvolvimento, 15 participantes (65,2%) informaram que a avaliação da qualidade é iniciada já na fase de coleta e preparação dos dados. Além disso, 13 participantes (56,5%) destacaram que o monitoramento da qualidade dos dados é contínuo, sendo realizado ao longo de todo o ciclo de vida do modelo. Outros 13 participantes (56,5%) afirmaram que conjuntos de testes são aplicados para validar a consistência, completude e precisão dos dados antes de sua utilização no treinamento. Por outro lado, 3 participantes (13%) mencionaram que não existe uma estratégia formal para garantir a qualidade dos dados durante o desenvolvimento. Apenas 1 participante (4,3%) afirmou não ter participado diretamente de nenhum processo relacionado à qualidade dos dados. Vale destacar que, nesta questão, os participantes podiam selecionar mais de uma opção.

Figura 12 – Impacto da qualidade dos dados




Fonte: Elaborado pela autora deste trabalho.

Na figura 12 podemos ver como foi a distribuição das respostas da seguinte pergunta: *Como você mede o impacto da qualidade dos dados no desempenho do modelo de aprendizado de máquina?*

Entre os 23 participantes, a maioria relatou utilizar uma combinação de análise de métricas de performance e revisão manual dos resultados para avaliar o impacto da qualidade dos dados nos modelos de aprendizado de máquina. Aproximadamente 21,7% dos profissionais optam por utilizar exclusivamente métricas quantitativas, enquanto outros 21,7% preferem combinar testes A/B com análise de métricas para obter uma visão mais abrangente. Apenas 4,3% dos participantes utilizam exclusivamente a revisão manual. Além disso, uma pequena parcela realiza análises detalhadas, ajustando as métricas conforme as necessidades específicas de cada projeto, como é o caso na área da saúde, onde a prioridade é minimizar falsos negativos. Assim como na questão anterior, os participantes puderam selecionar mais de uma alternativa e também adicionar outras opções.

Esses resultados indicam que a prática mais comum é a abordagem híbrida, combinando análise de métricas com revisão manual. Essa combinação sugere que os profissionais reconhecem a importância de equilibrar a objetividade das métricas com a interpretação detalhada, a fim de avaliar de forma eficaz como a qualidade dos dados impacta o desempenho dos modelos.

Figura 13 – Frequência que os requisitos são formalmente discutidos




Fonte: Elaborado pela autora deste trabalho.

A figura 13 mostra que a maioria dos profissionais prefere debater a qualidade dos dados semanalmente, adotando uma abordagem consistente que facilita a resolução de problemas de forma eficaz, sem sobrecarregar as equipes com encontros diários. A discussão mensal surge

como a segunda estratégia mais adotada, indicando que a qualidade dos dados é altamente valorizada, mas pode ser ajustada conforme a natureza e a prioridade dos projetos.

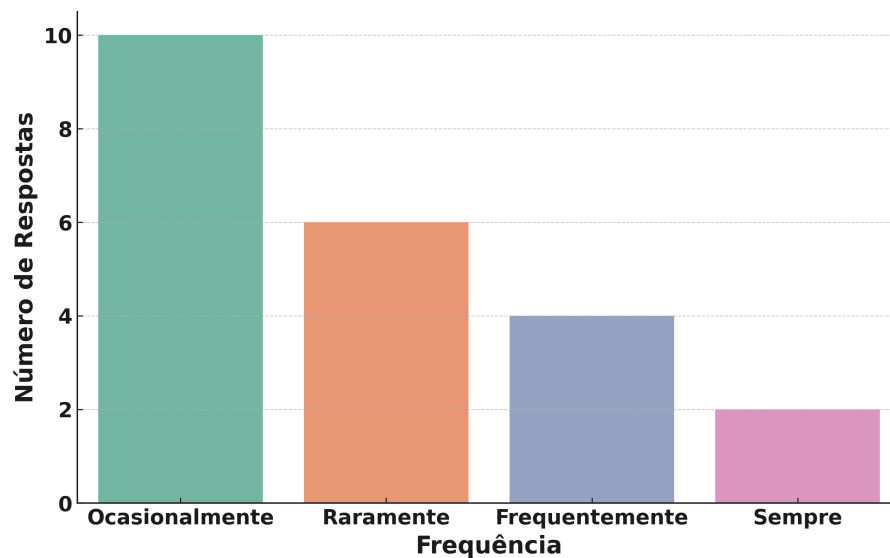
Figura 14 – Desafios para garantir a confiabilidade dos dados



Fonte: Elaborado pela autora deste trabalho.

O gráfico da figura 14 destaca que os desafios mais críticos estão relacionados à completude, atualização, consistência e padronização dos dados, indicando que essas áreas devem ser priorizadas nos esforços de otimização da qualidade dos dados para aprendizado de máquina. Além disso, a falta de ferramentas adequadas para validação e os erros durante a coleta dos dados surgem como preocupações significativas, evidenciando a necessidade de investir em processos automatizados e em melhores práticas para a gestão de dados.

Figura 15 – Suporte de outras equipes



Fonte: Elaborado pela autora deste trabalho.

A figura 15 ilustra a frequência com que os desenvolvedores recebem suporte de outras equipes para lidar com questões de qualidade de dados. A predominância das respostas “Ocasionalmente” e “Raramente” sugere que o suporte entre equipes para tratar da qualidade de dados ocorre de forma esporádica. Apenas uma pequena parcela dos participantes relatou receber suporte de maneira frequente ou constante.

5.5 Respondendo às questões de pesquisa

Essa seção pretende analisar e responder diretamente às perguntas centrais da pesquisa com base nos dados coletados.

5.5.1 *Como os desenvolvedores percebem e lidam com as características de qualidade dos dados em projetos de Aprendizado de Máquina (AM)?*

Com base nas respostas da pesquisa, os desenvolvedores indicaram que as características de precisão, consistência e credibilidade são as mais importantes para garantir a qualidade dos dados. A precisão foi apontada como fundamental por 19 dos 23 participantes, seguida pela consistência (16 participantes) e pela credibilidade (14 participantes). A completude também foi destacada como significativa por mais da metade dos respondentes. Em contrapartida, a atualidade dos dados gerou opiniões mais divergentes, sendo frequentemente considerada apenas “Importante”.

Essa priorização reflete um foco maior nas características que impactam diretamente a precisão e a confiabilidade dos modelos, relegando aspectos como a atualidade dos dados a um segundo plano. Além disso, as respostas sugerem que a prática mais comum consiste em tentar equilibrar precisão, compreensibilidade e eficiência computacional conforme as necessidades específicas de cada projeto, com uma leve tendência a priorizar a precisão.

O controle de versão dos dados é amplamente considerado essencial para manter a qualidade, especialmente no que diz respeito à consistência e rastreabilidade. Quase todos os desenvolvedores concordam que ele assegura esses aspectos, evidenciando um sólido consenso sobre sua importância.

Para integrar a excelência dos dados no desenvolvimento, a estratégia mais recorrente é a avaliação preliminar durante a coleta e preparação dos dados. Isso indica um foco significativo em garantir a qualidade desde as fases iniciais do processo. Além disso, a análise de índices de desempenho, como precisão e recall, é o método preferido para quantificar o impacto da qualidade dos dados no desempenho dos modelos. Esse cuidado com os índices de desempenho demonstra que os desenvolvedores se baseiam em indicadores quantitativos para medir a qualidade dos dados.

No que se refere à frequência das discussões sobre a qualidade dos dados, a maioria dos desenvolvedores relata que esses requisitos são debatidos pelo menos uma vez por semana, mas não diariamente. Isso revela que, embora a qualidade dos dados seja considerada relevante, ela não ocupa o primeiro plano nas reuniões diárias.

As práticas de documentação relacionadas à qualidade dos dados são bastante diversas. A abordagem mais comum envolve a utilização de linguagem estruturada (texto) e encontros de alinhamento. No entanto, a variedade nas respostas sugere a ausência de padronização, refletindo um cenário em que, mesmo reconhecendo a importância da documentação, as equipes adotam práticas distintas.

Os principais desafios para garantir a confiabilidade dos dados incluem a inconsistência entre diferentes fontes de informação, dados fragmentados e a falta de padronização. Esses problemas estão em linha com a percepção de que a combinação de múltiplas fontes de dados é um dos maiores obstáculos enfrentados pelos desenvolvedores.

O suporte de outras equipes para tratar questões relacionadas à qualidade dos dados ocorre ocasionalmente para a maioria dos desenvolvedores, indicando que a colaboração com times especializados não é contínua. Essa percepção sugere que, embora exista cooperação, ela

pode ser aprimorada para abordar de forma mais eficaz os problemas de qualidade dos dados.

De maneira geral, os desenvolvedores percebem a precisão, consistência e credibilidade como os aspectos mais críticos para a qualidade dos dados em projetos de Aprendizado de Máquina. A priorização dessas características, associada a práticas de controle de versão e avaliação inicial dos dados, reflete uma abordagem preventiva para lidar com problemas de qualidade. No entanto, a falta de padronização na documentação e comunicação, somada aos desafios de integração de fontes, revela oportunidades para aprimorar os processos relacionados à qualidade dos dados.

5.5.2 Como os desenvolvedores avaliam as características de qualidade dos dados ao longo do ciclo de vida do desenvolvimento de sistemas baseados em AM?

Os desenvolvedores avaliam as características de qualidade dos dados em diferentes fases do ciclo de vida do desenvolvimento de sistemas baseados em Aprendizado de Máquina (AM), com um foco maior nas etapas iniciais, especialmente durante a coleta e preparação dos dados. As práticas mais comuns incluem avaliações preventivas, monitoramento contínuo e o uso de métricas específicas para medir o impacto da qualidade dos dados no desempenho dos modelos.

A abordagem mais comum detectada nas respostas, é a avaliação inicial durante a coleta e preparação dos dados. Muitos desenvolvedores destacaram que garantir a precisão, consistência e completude dos dados desde o início do processo ajuda a evitar problemas nas etapas seguintes. Essa prática preventiva envolve técnicas como limpeza dos dados, remoção de duplicatas, tratamento de valores faltantes e inconsistências. Além disso, processos como normalização e validação dos dados são utilizados para assegurar conformidade com os padrões esperados. Esse destaque nas fases iniciais reflete uma tentativa de minimizar o impacto de dados de baixa qualidade nas fases de treinamento e teste dos modelos.

Além da avaliação inicial, os desenvolvedores destacaram a importância do monitoramento contínuo da qualidade dos dados. O controle de versão dos dados também é visto como essencial para garantir a consistência e a rastreabilidade ao longo do ciclo de vida do projeto. A prática de versionar datasets permite avaliar como mudanças nos dados influenciam o desempenho dos modelos ao longo do tempo. A automatização de pipelines de processamento de dados também foi mencionada como uma prática importante para assegurar que os dados sigam padrões de qualidade definidos anteriormente.

Para medir o impacto da qualidade dos dados, os desenvolvedores utilizam métricas de desempenho dos modelos, como precisão, recall, F1-score e acurácia. Essas métricas permitem avaliar objetivamente se a qualidade dos dados está afetando negativamente os resultados dos modelos. Além disso, métricas de eficiência computacional são usadas para avaliar se os dados estão sendo processados de forma otimizada, sem comprometer a velocidade ou os recursos do sistema. Essa abordagem quantitativa revela que os desenvolvedores confiam em indicadores objetivos para validar a qualidade dos dados ao longo do ciclo de vida do projeto.

A qualidade dos dados é um tema discutido com frequência durante o ciclo de vida dos projetos. A maioria dos desenvolvedores afirmou que os requisitos de qualidade são discutidos pelo menos uma vez por semana, sugerindo que essas avaliações não se limitam às fases iniciais, mas fazem parte de uma prática contínua. Em termos de documentação, as práticas mais comuns incluem o uso de linguagem estruturada (texto) e reuniões de alinhamento. No entanto, a diversidade das respostas sugere não haver um padrão claro de como essa documentação é feita, indicando uma área onde os processos poderiam ser aprimorados para assegurar que todos os envolvidos tenham uma compreensão uniforme sobre os padrões de qualidade dos dados.

Em resumo, os desenvolvedores avaliam a qualidade dos dados ao longo do ciclo de vida dos projetos AM, principalmente por meio de avaliações iniciais preventivas, monitoramento contínuo, uso de métricas de desempenho e discussões periódicas. A ênfase na precisão, consistência e completude, aliada a práticas como controle de versão e automação de pipelines, revela um foco claro em garantir a qualidade dos dados desde as fases iniciais até a produção. No entanto, a falta de padronização na documentação e os desafios com a integração de múltiplas fontes de dados apontam para oportunidades de melhoria nos processos de avaliação.

5.5.3 Quais são os principais desafios enfrentados pelos desenvolvedores em relação à qualidade dos dados em projetos de AM?

Os principais problemas enfrentados pelos desenvolvedores em relação à qualidade dos dados em projetos de Aprendizado de Máquina (AM) estão conectados à inconsistência entre fontes, incompletude, ausência de padronização, credibilidade, gerenciamento de versões e suporte inadequado de outras equipes. Estes problemas influenciam diretamente a capacidade de treinar modelos precisos, confiáveis e eficientes.

A inconsistência entre diferentes fontes de dados foi o desafio mais citado pelos desenvolvedores. Essa dificuldade surge especialmente em projetos que dependem da integração

de dados derivados de sistemas variados, onde diferenças em formatos, padrões e precisão complicam o processo de análise. A falta de padronização na coleta, armazenamento e processamento dos dados intensifica esse problema, exigindo maior esforço em etapas como limpeza, transformação e validação dos dados. Essa inconsistência não só compromete a precisão dos modelos, mas também aumenta a complexidade das pipelines de dados, demandando tempo e recursos adicionais para corrigir problemas.

A credibilidade dos dados também foi destacada como um desafio importante, especialmente em projetos que envolvem dados sensíveis ou regulamentados. A necessidade de garantir que os dados sejam confiáveis envolve validar a fonte, identificar e corrigir possíveis vieses e assegurar que os dados sejam representativos do problema em questão.

O gerenciamento de versões dos dados foi mencionado como um aspecto crucial para garantir a qualidade. Muitos desenvolvedores indicaram que a ausência de práticas sólidas de versionamento dificulta a rastreabilidade e a consistência dos dados utilizados nas diversas etapas dos projetos. Sem um controle efetivo de versões, torna-se complexo reproduzir experimentos, avaliar o impacto das alterações nos dados sobre os modelos e garantir que todos os envolvidos no projeto estejam utilizando as mesmas versões dos conjuntos de dados.

Além disso, a ausência de apoio contínuo de outras equipes, como engenheiros de dados e cientistas de dados especializados, se configura como um obstáculo considerável. A colaboração com esses grupos ocorre de modo esporádico, restringindo a capacidade dos desenvolvedores de abordar questões de qualidade de maneira eficiente e rápida.

Portanto, os principais obstáculos enfrentados pelos desenvolvedores em relação à qualidade dos dados em projetos de AM são a inconsistência entre fontes, incompletude, ausência de padronização, credibilidade, falta de controle eficaz de versões e suporte inadequado de outras equipes. Superar esses obstáculos requer a melhoria de processos de integração, padronização, controle de versões e colaboração entre equipes, além de estabelecer práticas mais robustas para assegurar a confiabilidade e a rastreabilidade dos dados ao longo de todo o ciclo de vida dos projetos.

5.6 Limitações e Ameaças a Validade

A pesquisa apresentou algumas limitações que podem ter impactado os resultados encontrados, comprometendo tanto a validade interna quanto a validade externa do estudo. Uma das principais limitações foi a quantidade limitada de respostas, com somente 23 participantes.

Esse tamanho de amostra reduzido compromete a robustez estatística dos resultados, dificultando a generalização das conclusões para um público mais amplo.

Outro ponto importante foi o alcance geográfico restrito da pesquisa. Os participantes estavam concentrados em determinados estados do Brasil, como Ceará, Pernambuco e São Paulo, o que pode ter influenciado os resultados devido a diferenças regionais em recursos, ferramentas e metodologias adotadas.

O período de coleta de dados, realizado entre 13 de fevereiro de 2025 e 01 de março de 2025, também representou uma limitação significativa. O intervalo relativamente curto pode ter reduzido a probabilidade de alcançar um número maior de participantes, considerando especialmente a proximidade com o início do ano e o Carnaval no Brasil, quando muitos profissionais podem estar em período de férias ou com menor disponibilidade para responder a questionários detalhados.

Já quanto às ameaças à validade externa, a ênfase dada a características específicas dos dados, como precisão e consistência, pode ter excluído outros aspectos relevantes, como acessibilidade e rastreabilidade, que também podem influenciar a eficácia dos sistemas de aprendizado de máquina em outros contextos. Isso limita a capacidade de generalizar os resultados para diferentes tipos de projetos ou setores.

Essas limitações sugerem que estudos futuros poderiam se beneficiar de amostras maiores, maior diversidade de participantes e períodos de coleta mais amplos. Além disso, uma divulgação mais abrangente e estratégias para evitar distorções na seleção dos participantes seriam fundamentais para aumentar a validade externa dos resultados.

6 CONCLUSÕES E TRABALHOS FUTUROS

O presente trabalho explorou de forma abrangente a percepção dos desenvolvedores sobre os requisitos de qualidade dos dados em sistemas de Aprendizado de Máquina (AM), evidenciando que a qualidade dos dados desempenha um papel central para a eficácia dos modelos. A partir da análise dos dados coletados, verificou-se que os desenvolvedores atribuem grande importância a características como precisão, consistência, confiabilidade e credibilidade dos dados, considerando-as essenciais para garantir a confiabilidade dos sistemas AM. Em contrapartida, aspectos como acessibilidade, recuperação e rastreabilidade foram vistos como menos prioritários, sugerindo que o foco dos profissionais está predominantemente nas características que influenciam diretamente o desempenho dos modelos.

Outro ponto relevante identificado foi a prática generalizada de realizar controles rigorosos de versão dos dados e a aplicação de métodos quantitativos, como métricas de desempenho, para mensurar o impacto da qualidade dos dados nos modelos. A preferência por indicadores objetivos reforça a necessidade de métricas bem definidas para avaliar a qualidade dos dados de forma contínua. Além disso, a avaliação preliminar da qualidade dos dados durante a fase de coleta e preparação se mostrou uma prática comum, indicando uma abordagem preventiva para minimizar problemas relacionados aos dados nos estágios iniciais do desenvolvimento.

Por outro lado, os resultados também revelaram desafios significativos enfrentados pelos desenvolvedores, tais como a falta de padronização na documentação dos requisitos de qualidade dos dados, dificuldades na integração de múltiplas fontes de dados e limitações no suporte. A colaboração eventual entre diferentes equipes para tratar questões de qualidade de dados aponta para uma oportunidade de melhoria, destacando a necessidade de processos mais integrados e suporte organizacional consistente. Adicionalmente, a ausência de estratégias formais para assegurar a qualidade dos dados em alguns casos revela uma lacuna importante a ser abordada.

A análise também revelou que a percepção dos desenvolvedores sobre os requisitos de qualidade dos dados está diretamente associada à sua experiência prática com Engenharia de Requisitos. Profissionais com maior experiência demonstraram maior preocupação em documentar de forma clara os requisitos e em aplicar práticas padronizadas para garantir a qualidade dos dados, enquanto aqueles com menos experiência mostraram-se mais focados em aspectos técnicos específicos do processamento de dados.

Com base nesses achados, conclui-se que tratar a qualidade dos dados como um

requisito não funcional de primeira ordem é fundamental para o desenvolvimento robusto de sistemas baseados em AM. A implementação de práticas padronizadas para documentação, processos automatizados de validação de dados e a ampliação do suporte colaborativo entre equipes aparecem como caminhos promissores para melhorar a qualidade dos dados e, conseqüentemente, o desempenho dos modelos.

Para estudos futuros, seria interessante explorar práticas mais padronizadas para documentar e integrar dados, além de desenvolver ferramentas que facilitem a colaboração entre equipes. Adotar métodos mais integrados para gerenciar a qualidade dos dados pode ajudar a melhorar significativamente a confiabilidade e a eficácia dos sistemas de Aprendizado de Máquina.

Dessa forma, espera-se que as contribuições deste estudo possam servir como um ponto de partida para aprimorar as práticas relacionadas aos requisitos de qualidade dos dados em sistemas AM, promovendo um desenvolvimento mais confiável, eficiente e alinhado às melhores práticas de Engenharia de Requisitos.

REFERÊNCIAS

- ACADEMY, D. S. **17 casos de uso ML**. 2022. Disponível em: <https://blog.dsacademy.com.br/17-casos-de-uso-de-machine-learning/>. Acesso em: 24 nov. 2022.
- AcervoLima. **Aprendizado de máquina**. 2022. Disponível em: <https://acervolima.com/ml-aprendizagem-semi-supervisionada/>. Acesso em: 24 nov. 2022.
- BENITTI FABIANE BARRETO VAVASSORI E RHODEN, J. S. Uma taxonomia unificada para requisitos não funcionais. **Revista Electronica de Sistemas de Informação**, v. 14, n. 3, p. 1, 2015.
- CERRI, R.; FERREIRA, A. C. P. de L.; OTHERS. Aprendizado de máquina: Breve introdução e aplicações. **Cadernos de Ciência & Tecnologia**, v. 34, n. 3, p. 297–313, 2019.
- CHOLLET, F. **Deep learning with Python**. [S. l.]: Simon and Schuster, 2021.
- CYSNEIROS, L. M.; LEITE, J. C. S. P. **Requisitos não funcionais**: Da elicitação ao modelo conceitual. 24 f p. Tese (Tese (Doutorado em Informática)) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Informática, Rio de Janeiro, 2001.
- DOMINGOS, P. **The master algorithm**: How the quest for the ultimate learning machine will remake our world. [S. l.]: Basic Books, 2015.
- HABIBULLAH, K. M.; GAY, G.; HORKOFF, J. Non-functional requirements for machine learning: understanding current use and challenges among practitioners. **Requirements Engineering**, Springer, v. 28, n. 2, p. 283–316, 2023.
- HORKOFF, J. Non-functional requirements for machine learning: challenges and new directions. In: IEEE, 27. **international requirements engineering conference (RE)**. [S. l.], 2019. p. 386–391.
- JARZĘBOWICZ, A.; WEICHBROTH, P. A qualitative study on non-functional requirements: In agile software development. **IEEE Access**, v. 9, p. 40458–40475, 2021.
- JavaTPoint. **Aprendizado de máquina**. 2022. Disponível em: <https://www.javatpoint.com/unsupervised-machine-learning>. Acesso em: 24 nov. 2022.
- MARQUES, J. C. Uma análise das características de especificação de requisitos de software em normas de ambientes regulados. In: **WER**. [S. l.: s. n.], 2019.
- NAQA, I. E.; MURPHY, M. J. What is machine learning? In: **Machine learning in radiation oncology: theory and applications**. [S. l.]: Springer, 2015. p. 3–11.
- NASCIMENTO, E. de S.; AHMED, I.; OLIVEIRA, E.; PALHETA, M. P.; STEINMACHER, I.; CONTE, T. Understanding development process of machine learning systems: Challenges and solutions. In: IEEE. **International Symposium on Empirical Software Engineering and Measurement (ESEM)**. [S. l.], 2019. p. 1–6.
- ONESPAN. **Análise de Fraudes**. 2022. Disponível em: <https://www.onespan.com/pt-br/topics/analise-de-fraudes>. Acesso em: 24 nov. 2022.
- RASCHKA, S.; MIRJALILI, V. **Python machine learning**: machine learning and deep learning with python, scikit-learn, and tensorflow 2. [S. l.]: Packt Publishing Ltd, 2019.

SILVA, J. C. P. **Um módulo inteligente baseado em aprendizado de máquina para treinamento de estudantes de medicina no DoTraining**. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal Rural do Semi-Árido, Brasil, 2020.

SILVA, R. A. d. **NFR4ES: um catálogo de requisitos não-funcionais para sistemas embarcados**. Dissertação (Dissertação (Mestrado em Engenharia de Software)) – Universidade Federal de Pernambuco, Recife, 2019.

Somostera. **Sistema de recomendação**. 2022. Disponível em: <https://blog.somostera.com/data-science/sistemas-de-recomendacao>. Acesso em: 24 nov. 2022.

TECHTUDO. **O que é chatbot? Entenda como funciona o robô que conversa com você**. 2021. Disponível em: <https://www.techtudo.com.br/noticias/2018/03/o-que-e-chatbot-entenda-como-funciona-o-robo-que-conversa-com-voce.ghtml>. Acesso em: 24 nov. 2022.

VALENTE, M. T. **Engenharia de software moderna (livro digital)**. 2020.

VILLAMIZAR, H. e. o. Identifying concerns when specifying machine learning-enabled systems: a perspective-based approach. **Journal of Systems and Software**, Elsevier, v. 213, p. 112053, 2024.

VOGELSANG, A.; BORG, M. Requirements engineering for machine learning: Perspectives from data scientists. In: IEEE, 27. **International Requirements Engineering Conference Workshops (REW)**. [S. l.], 2019. p. 245–251.

WIEGERS, K.; BEATTY, J. **Software requirements**. [S. l.]: Pearson Education, 2013.