

**UNIVERSIDADE DE CAXIAS DO SUL
ÁREA DO CONHECIMENTO DE CIÊNCIAS EXATAS E
ENGENHARIAS**

FLAVIO LUÍS DA SILVA JÚNIOR

**AVALIANDO MODELOS DE MACHINE LEARNING APLICADOS À
GERONTECNOLOGIA**

CAXIAS DO SUL

2025

FLAVIO LUÍS DA SILVA JÚNIOR

**AVALIANDO MODELOS DE MACHINE LEARNING APLICADOS À
GERONTECNOLOGIA**

Trabalho de Conclusão de Curso
apresentado como requisito parcial
à obtenção do título de Bacharel em
Engenharia da Computação na Área
do Conhecimento de Ciências Exatas e
Engenharias da Universidade de Caxias
do Sul.

Orientador: Prof. Dra. Carine Gel-
trudes Webber

CAXIAS DO SUL

2025

FLAVIO LUÍS DA SILVA JÚNIOR

**AVALIANDO MODELOS DE MACHINE LEARNING APLICADOS À
GERONTECNOLOGIA**

Trabalho de Conclusão de Curso
apresentado como requisito parcial
à obtenção do título de Bacharel em
Engenharia da Computação na Área
do Conhecimento de Ciências Exatas e
Engenharias da Universidade de Caxias
do Sul.

BANCA EXAMINADORA

Prof. Dra. Carine Geltrudes Webber
Universidade de Caxias do Sul - UCS

Prof. Dra. Helena Graziottin Ribeiro
Universidade de Caxias do Sul - UCS

Prof. Dr. Tiago Luiz Schmitz
Universidade Estadual de Santa Catarina -
UDESC

RESUMO

A Inteligência Artificial (IA) é uma área de estudo de destaque na Ciência da Computação, que abrange o desenvolvimento de algoritmos para solucionar problemas em diversas áreas, como processamento de fala, classificação de dados e reconhecimento de padrões. Nos últimos anos, o uso de IA em Gerontecnologia tem recebido atenção, especialmente em iniciativas que visam promover a segurança e o bem-estar de idosos. Pesquisadores têm aplicado técnicas de *Machine Learning* para desenvolver sistemas que auxiliem na identificação de riscos no ambiente doméstico, com foco em prevenir acidentes como quedas. Este trabalho identifica e analisa, por meio de uma revisão sistemática, abordagens relacionadas ao uso de IA na Gerontecnologia, com destaque para algoritmos de classificação que monitoram atividades e condições do ambiente para identificar padrões de risco. Dentre as técnicas utilizadas, destaca-se o uso de Árvores de Decisão e Redes Neurais Artificiais para análise preditiva, dada a eficiência desses modelos em extrair padrões de dados coletados de sensores e dispositivos de monitoramento. As Árvores de Decisão são reconhecidas por sua facilidade de interpretação, característica essencial em contextos que demandam transparência. As Redes Neurais Artificiais, por sua vez, são eficazes na identificação de relações complexas entre variáveis, proporcionando maior precisão nas previsões. O desenvolvimento deste trabalho seguiu um percurso baseado na pesquisa exploratória, sendo uma abordagem apropriada para áreas com conhecimento emergente. A pesquisa exploratória incluiu revisão bibliográfica, levantamento de dados e construção de um modelo piloto. Para a implementação, foram definidas cinco etapas metodológicas: identificação e preparação do *dataset*, desenvolvimento do modelo de aprendizado, execução de testes, análise de resultados e ajustes necessários. Foi utilizado o *dataset* com informações de atividades e monitoramento de idosos em ambientes domésticos, complementado para abranger diversos cenários de risco. Este trabalho desenvolveu um estudo aplicado de predição de quedas em idosos por meio de técnicas de *Machine Learning*. Para isso, foram construídos três cenários distintos de análise, baseados em dados clínicos dos idosos, percepções sobre o ambiente doméstico e avaliações arquitetônicas realizadas por um especialista. Após o processo de preparação dos dados (ETL) e análise exploratória, foram treinados e testados modelos de Árvore de Decisão e Redes Neurais, utilizando estratégias de *hold-out* e *cross-validation*. Os resultados permitiram comparar o desempenho de cada cenário, evidenciando que as percepções dos próprios idosos constituem o conjunto de variáveis mais adequado para identificar o risco de quedas. O estudo demonstra o potencial das Redes Neurais para predição e prevenção de acidentes domésticos.

Palavras-chave: Inteligência Artificial. *Machine Learning*. Gerontecnologia. Redes Neurais. Previsão de quedas por idosos.

LISTA DE FIGURAS

Figura 1 – Dispositivos habilitados para IA em disciplinas médicas	14
Figura 2 – Porcentagem de satisfação	15
Figura 3 – Ramificação da IA	16
Figura 4 – Fluxograma para classificar transações fraudulentas	17
Figura 5 – Passos de implementação de um algoritmo de <i>machine learning</i>	18
Figura 6 – Ramificação do <i>machine learning</i>	20
Figura 7 – Representação em diagrama de blocos do sistema nervoso.	25
Figura 8 – Modelo não linear de um neurônio, rotulado como K.	25
Figura 9 – Gráfico de fluxo de sinal de um sistema de <i>feedback</i> de ciclo único	27
Figura 10 – Redes Neurais <i>feedforward</i>	27
Figura 11 – Rede Neural Recorrente	28
Figura 12 – Método <i>Hold-out</i>	35
Figura 13 – Método <i>Cross-validation</i> (5 partições)	36
Figura 14 – Áreas de estudo da Gerontecnologia	40
Figura 15 – Hierarquia do bem-estar	41
Figura 16 – Robô HSR	46
Figura 17 – HSR auxiliando com a entrega de uma garrafa	47
Figura 18 – Robô <i>Robear</i> em funcionamento	48
Figura 19 – Pulseira <i>Carepredict</i>	49
Figura 20 – <i>Gyenno Bravo Seires</i>	50
Figura 21 – Distribuição etária dos participantes	68
Figura 22 – Matriz de correlação das variáveis do cenário 1	69
Figura 23 – Matriz de confusão da árvore de decisão com o método <i>hold-out</i>	71
Figura 24 – <i>Classification report</i> da árvore de decisão com o método <i>hold-out</i>	72
Figura 25 – Matriz de confusão da árvore de decisão com o método <i>cross-validation</i>	72
Figura 26 – <i>Classification report</i> da árvore de decisão com o método <i>cross-validation</i>	73
Figura 27 – Matriz de confusão da rede neural com <i>hold-out</i>	75
Figura 28 – <i>Classification report</i> da rede neural com <i>hold-out</i>	75
Figura 29 – Matriz de confusão da rede neural com <i>cross-validation</i>	76
Figura 30 – <i>Classification report</i> da rede neural com <i>cross-validation</i>	76
Figura 31 – Matriz de correlação das variáveis do cenário 2	79
Figura 32 – Matriz de confusão da árvore de decisão com o método <i>hold-out</i>	80
Figura 33 – <i>Classification report</i> da árvore de decisão com o método <i>hold-out</i>	80
Figura 34 – Matriz de confusão da árvore de decisão com o método <i>cross-validation</i>	81
Figura 35 – <i>Classification report</i> da árvore de decisão com o método <i>cross-validation</i>	81
Figura 36 – Matriz de confusão da rede neural com <i>hold-out</i>	83

Figura 37 – <i>Classification report</i> da rede neural com <i>hold-out</i>	83
Figura 38 – Matriz de confusão da rede neural com <i>cross-validation</i>	84
Figura 39 – <i>Classification report</i> da rede neural com <i>cross-validation</i>	84
Figura 40 – Matriz de correlação	87
Figura 41 – Matriz de confusão da árvore de decisão com o método <i>hold-out</i>	88
Figura 42 – <i>Classification report</i> da árvore de decisão com o método <i>hold-out</i>	88
Figura 43 – Matriz de confusão da árvore de decisão com o método <i>cross-validation</i>	89
Figura 44 – <i>Classification report</i> da árvore de decisão com o método <i>cross-validation</i>	89
Figura 45 – Matriz de confusão da rede neural com <i>hold-out</i>	91
Figura 46 – <i>Classification report</i> da rede neural com <i>hold-out</i>	91
Figura 47 – Matriz de confusão da rede neural com <i>cross-validation</i>	92
Figura 48 – <i>Classification report</i> da rede neural com <i>cross-validation</i>	92

LISTA DE TABELAS

Tabela 1 – Algoritmos do aprendizado supervisionado e seus usos	21
Tabela 2 – Algoritmos do aprendizado não supervisionado e seus usos	22
Tabela 3 – Algoritmos do aprendizado por reforço e seus usos	23
Tabela 4 – Algoritmos das Redes Neurais Artificiais e seus usos	31
Tabela 5 – Estrutura da Matriz de Confusão	36
Tabela 6 – Artigos analisados na revisão sistemática.	43
Tabela 7 – <i>Boxplot</i> das doenças relatadas pelos idosos	69
Tabela 8 – Tabela comparativa dos modelos no cenário 1	77
Tabela 9 – Tabela comparativa dos modelos no cenário 2	85
Tabela 10 – Tabela comparativa dos modelos no cenário 3	93

LISTA DE ABREVIATURAS E SIGLAS

IA	Inteligência Artificial
SVM	<i>Support Vector Machine</i>
KNN	<i>K-Nearest Neighbors</i>
PCA	<i>Principal Component Analysis</i>
PPO	<i>Proximal Policy Optimization</i>
VLSI	<i>Very-Large-Scale Integration</i>
CNN	<i>Convolutional Neural Network</i>
RNN	<i>Recurrent Neural Network</i>
LSTM	<i>Long Short-Term Memory</i>
GAN	<i>Generative Adversarial Network</i>
xNN	<i>Explainable Neural Network</i>
LIME	<i>Local Interpretable Model-agnostic Explanations</i>
SHAP	<i>Shapley Additive Explanations</i>
ANN	<i>Artificial Neural Networks</i>
HRI	<i>Human-Robot Interaction</i>
BERT	<i>Bidirectional Encoder Representations from Transformers</i>
GPT	<i>Generative Pre-trained Transformers</i>
HAR	<i>Human Activity Recognition</i>
HSR	<i>Human Support Robot</i>
MLP	<i>Multilayer Perceptron</i>

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Objetivos	11
1.2	Estrutura do trabalho	11
2	INTELIGÊNCIA ARTIFICIAL APLICADA À GERONTECNOLOGIA	13
2.1	O que é Inteligência Artificial?	13
2.2	O Que São os Modelos Preditivos?	15
2.3	<i>Machine Learning</i>	18
2.3.1	Abordagens do <i>Machine Learning</i>	20
2.3.2	Redes Neurais Artificiais	24
2.3.3	Preparação dos Dados	34
2.3.4	Avaliação dos Modelos	36
2.4	O que é Gerontecnologia?	39
2.5	Trabalhos Relacionados	42
2.5.1	Artigos	42
2.5.2	Robótica	45
2.5.3	Aplicativos	51
2.5.4	Considerações Finais	53
3	MÉTODO DE PESQUISA	54
3.1	Coleta de Dados	54
3.2	Preparação dos Dados	57
3.3	Escolha dos Métodos de <i>Machine Learning</i>	58
3.4	Treinamento dos Modelos	59
3.5	Avaliação dos Modelos	63
3.6	Considerações Finais	64
4	IMPLEMENTAÇÃO DOS MODELOS DE <i>MACHINE LEARNING</i>	65
4.1	Preparação do Ambiente de Desenvolvimento	65
4.2	Detalhamento dos Cenários de Teste	65
4.3	Cenário 1	66
4.3.1	Análise Exploratória	67
4.3.2	Árvore de Decisão	70
4.3.3	Rede Neural	73
4.3.4	Conclusão Sobre o Cenário 1	77
4.4	Cenário 2	78

4.4.1	Análise Exploratória	78
4.4.2	Árvore de Decisão	79
4.4.3	Rede Neural	82
4.4.4	Conclusão Sobre o Cenário 2	85
4.5	Cenário 3	86
4.5.1	Análise Exploratória	86
4.5.2	Árvore de Decisão	87
4.5.3	Rede Neural	90
4.5.4	Conclusão Sobre o Cenário 3	93
4.6	Considerações finais sobre as análises realizadas	94
5	CONCLUSÃO	95
5.1	Síntese do Trabalho	95
5.2	Contribuição do Trabalho Para a Área	95
5.3	Trabalhos Futuros	96
	REFERÊNCIAS	98
	ANEXO A – DECLARAÇÃO DO USO DE IA	104
	ANEXO B – INSTRUMENTO DE AVALIAÇÃO ERGONÔMICA DA MORADIA DO IDOSO	105

1 INTRODUÇÃO

O envelhecimento populacional é um fenômeno global que apresenta implicações significativas para a saúde, economia e sociedade. A Organização Mundial da Saúde (OMS) estima que, até 2050, a população acima de 60 anos dobrará, alcançando cerca de dois bilhões de pessoas (SAÚDE, 2021). No Brasil, o impacto é ainda mais pronunciado, com projeções do IBGE indicando que o número de idosos no país ultrapassará 60 milhões nas próximas décadas (ESTATÍSTICA, 2020). Essa transição demográfica, embora seja uma conquista do avanço científico e social, traz desafios complexos, como o aumento de doenças crônicas, a necessidade de cuidados contínuos, limitações de mobilidade e o risco de isolamento social. Esses dados evidenciam a urgência de soluções inovadoras e sustentáveis para lidar com as demandas dessa população crescente.

Nesse contexto, a Gerontecnologia surge como uma área interdisciplinar que integra princípios de gerontologia e tecnologia para desenvolver soluções voltadas à promoção de um envelhecimento ativo e saudável. Combinando avanços em engenharia, saúde e ciências sociais, a Gerontecnologia tem como foco principal criar ferramentas e dispositivos que melhorem a autonomia, saúde e participação social dos idosos. Tecnologias como sensores vestíveis, assistentes virtuais e dispositivos de monitoramento remoto já têm demonstrado impacto significativo na vida dessa população, promovendo tanto a segurança quanto a independência (GRAAFMANS; TAIPALE, 1998). No entanto, o potencial completo da Gerontecnologia está sendo ampliado pelo uso de tecnologias avançadas, especialmente a IA.

A aplicação da IA em contextos de cuidado e suporte ao idoso tem mostrado avanços promissores. Algoritmos baseados em aprendizado de máquina possibilitam o reconhecimento de padrões complexos em dados, como os gerados por sensores de movimento ou dispositivos de monitoramento de saúde. Esses sistemas podem prever quedas, identificar alterações no comportamento e alertar sobre emergências de saúde, permitindo intervenções preventivas (MEHTA, 2023a). Além disso, tecnologias como aprendizado profundo e redes neurais têm sido empregadas para personalizar diagnósticos e tratamentos, garantindo maior precisão e eficiência no atendimento médico (BANERJEE; KUMAR, 2024a). Essas aplicações são fundamentais em um cenário onde a demanda por cuidados cresce exponencialmente, enquanto os recursos humanos e financeiros permanecem limitados.

Outro campo de aplicação importante é a criação de ambientes inteligentes adaptáveis às necessidades dos idosos. Sistemas baseados em IA podem ajustar iluminação, temperatura e dispositivos de segurança automaticamente, dependendo das condições de saúde ou preferências do usuário. Essas inovações aumentam o conforto e promovem a autonomia, permitindo que os idosos vivam de forma independente por mais tempo em suas próprias casas (ZHANG; WANG; XU, 2021). No entanto, para que essas tecnologias sejam acessíveis a todos, é crucial considerar

barreiras como custos financeiros e inclusão digital, bem como desenvolver interfaces intuitivas que atendam à população idosa.

Apesar dos avanços técnicos, a integração da IA na Gerontecnologia enfrenta desafios éticos e sociais. Questões relacionadas à privacidade de dados, autonomia dos usuários e vieses em algoritmos são amplamente debatidas na literatura. Garantir que as soluções tecnológicas respeitem os direitos e necessidades dos idosos é essencial para sua aceitação e sucesso. Além disso, a inclusão dos idosos no processo de desenvolvimento dessas tecnologias é indispensável para que as soluções atendam de forma efetiva suas expectativas e demandas (DIGNUM, 2018).

Portanto, este trabalho busca explorar as aplicações da IA na Gerontecnologia, investigando como algoritmos de aprendizado de máquina podem ser utilizados para melhorar a segurança e o bem-estar dos idosos. A partir de uma abordagem exploratória, serão avaliados modelos preditivos e propostas arquiteturas práticas que utilizem dados reais para validação. Além de contribuir para o avanço acadêmico e técnico nessa área emergente, espera-se que os resultados deste estudo auxiliem no desenvolvimento de soluções práticas, eficazes e acessíveis que promovam um envelhecimento mais seguro, confortável e ativo.

1.1 OBJETIVOS

O objetivo geral deste trabalho consiste em avaliar o uso de modelos de Inteligência Artificial aplicados à Gerontecnologia, com ênfase em técnicas de *Machine Learning* como Árvores de Decisão e Redes Neurais Artificiais. Esses modelos serão desenvolvidos e testados em um estudo de caso piloto voltado à identificação de riscos de quedas no ambiente doméstico de idosos.

Os objetivos específicos deste trabalho são:

1. Identificar os algoritmos de *Machine Learning* mais utilizados para a análise de dados na área da Gerontecnologia.
2. Propor uma arquitetura de implementação baseada em um estudo de caso piloto direcionado à prevenção de quedas em ambientes domésticos.
3. Implementar modelos a partir de métodos de IA.
4. Realizar testes nos modelos desenvolvidos, considerando o contexto do estudo de caso proposto.
5. Comparar os resultados obtidos com os trabalhos precedentes.

1.2 ESTRUTURA DO TRABALHO

O presente trabalho está organizado da seguinte forma:

- No Capítulo 2, a fundamentação teórica é detalhada, introduzindo os principais conceitos de IA e modelos preditivos, além de apresentar uma visão geral sobre aprendizado de máquina e suas aplicações na Gerontecnologia. Este capítulo também inclui uma revisão sistemática da literatura sobre trabalhos relacionados, focando em robótica e aplicativos que utilizam IA para o cuidado de idosos.
- O Capítulo 3 descreve a proposta do estudo, incluindo a metodologia utilizada para a implementação de um modelo de IA no contexto da Gerontecnologia. Este capítulo apresenta também um estudo de caso piloto para demonstrar a aplicação prática das teorias discutidas no trabalho.
- No Capítulo 4, tem-se o capítulo que descreve a implementação da proposta de solução.
- O Capítulo 5 apresenta as conclusões do trabalho.

2 INTELIGÊNCIA ARTIFICIAL APLICADA À GERONTECNOLOGIA


A IA é uma área de pesquisa e desenvolvimento em amplo crescimento nos dias de hoje. Ela tem sido aplicada em vários setores da vida humana. Neste trabalho, entende-se relevante o uso da IA no apoio ao envelhecimento humano. Neste contexto, a Gerontecnologia tem por objetivo de promover melhor qualidade de vida (saúde, independência pessoal, conforto e segurança) à população mais velha, por meio do desenvolvimento de produtos e serviços, dentre os quais produtos com IA, adequados às necessidades, demandas e particularidades dessa população (Academia Brasileira de Letras, 2024). O contexto teórico da IA, bem como a área de aprendizado de máquina (*machine learning*), são apresentados neste capítulo. A fim de compreender a relação entre a área da IA aplicada à Gerontecnologia, propõe-se uma revisão da literatura.

2.1 O QUE É INTELIGÊNCIA ARTIFICIAL?

A IA é um campo multidisciplinar que busca criar tecnologias capazes de emular a inteligência humana, permitindo que máquinas realizem tarefas como resolução de problemas, compreensão de linguagem e tomada de decisões (LUGER, 2013). Ao integrar conhecimentos de disciplinas como Matemática, Biologia, Filosofia, Linguística e Economia, a IA desenvolve métodos e técnicas para solucionar problemas complexos de forma eficiente. Essa característica interdisciplinar consolida a IA como um ramo essencial da Ciência da Computação, com práticas rigorosas de testes e avaliação.

A capacidade de simular a inteligência humana tem transformado diversos setores, incluindo saúde, segurança, economia, manufatura e marketing. Na área da saúde, a IA tem sido fundamental para reduzir erros médicos e melhorar os cuidados aos pacientes (BHAGAT *et al.*, 2024). Tecnologias como *machine learning*, processamento de linguagem natural e análise preditiva têm elevado a precisão de diagnósticos, personalizado tratamentos e otimizado operações em saúde (BANERJEE; KUMAR, 2024b). A Figura 1 destaca as áreas da medicina mais impactadas por dispositivos habilitados com IA, com destaque para radiologia e cardiologia.

Figura 1 – Dispositivos habilitados para IA em disciplinas médicas



Fonte: Traduzido de <https://binariks.com/blog/artificial-intelligence-ai-healthcare-market/>

A IA tem se destacado na medicina personalizada, analisando grandes volumes de dados, como histórico médico e genético dos pacientes, para criar estratégias de tratamento individualizadas. Essa abordagem permite intervenções mais precisas e oportunas, prevenindo eventos adversos (MEHTA, 2023b). Em doenças como diabetes, câncer e problemas cardíacos, os sistemas de diagnóstico baseados em IA têm demonstrado alta eficácia ao identificar tendências e anomalias em grandes bases de dados (MISHRA *et al.*, 2024). Um estudo na Suécia com mais de 80.000 mulheres mostrou que análises de mamografias realizadas por IA detectaram 20% mais casos de câncer de mama em comparação aos métodos tradicionais de dois radiologistas (LÂNG *et al.*, 2023).

Além da saúde, a IA tem revolucionado setores como inspeção automatizada, segurança viária e vigilância de tráfego. Avanços em visão computacional, com técnicas de *machine learning* e aprendizado profundo, têm aumentado a precisão e eficiência na interpretação de dados visuais (RADOJČIĆ *et al.*, 2024). Aplicações como detecção de objetos e reconhecimento de placas de veículos têm aprimorado o monitoramento do tráfego, melhorando a gestão do fluxo e a identificação de anomalias (JESI *et al.*, 2023).

Embora essas tecnologias imitem funções cognitivas humanas, como aprendizado e percepção, elas não substituem completamente as capacidades humanas. No entanto, as máquinas conseguem analisar dados em larga escala, identificar padrões e fornecer recomendações personalizadas com base nas informações aprendidas (SHRIVASTAVA, 2024). Na área de vendas e marketing, por exemplo, a personalização de recomendações, impulsionada por IA, tem gerado maior satisfação entre os consumidores. Segundo McKinsey & Company (2024b), 71% dos clientes esperam sugestões personalizadas, enquanto 76% ficam insatisfeitos quando essas não ocorrem (Figura 2).

Figura 2 – Porcentagem de satisfação



Fonte: <https://medium.com/@emmanuelbreard/understanding-how-ai-driven-product-recommendations-work-013560ac9fcb>

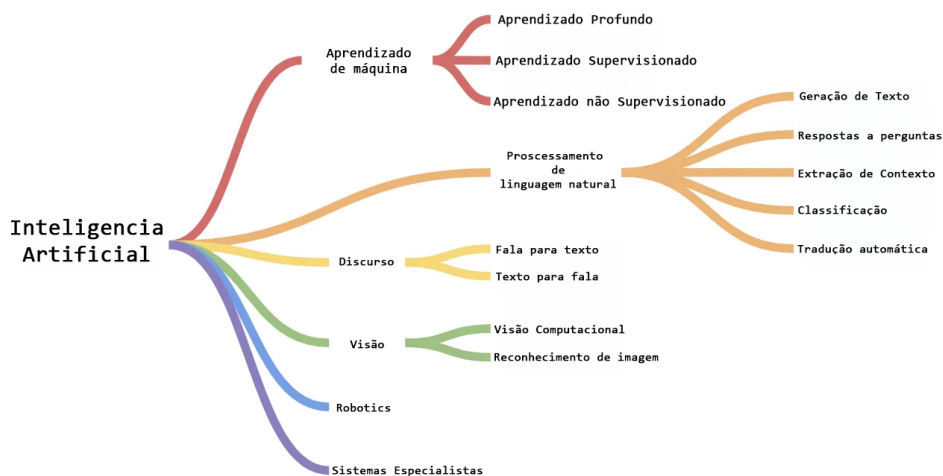
Os modelos preditivos, apoiados por IA, têm desempenhado papel crucial na personalização de experiências e na otimização de estratégias empresariais. Utilizando algoritmos avançados e *machine learning*, esses modelos analisam dados históricos para prever resultados futuros, como preferências de consumo e tendências de mercado. Essa integração permite não apenas melhorar a eficiência operacional, mas também oferecer recomendações personalizadas, como no caso da *Amazon* e da *Netflix*, onde 35% das compras e 75% das visualizações são impulsionadas por algoritmos de IA (McKinsey & Company, 2024a). Assim, a combinação de IA e modelos preditivos está redefinindo a forma como decisões estratégicas são tomadas em diferentes áreas.

2.2 O QUE SÃO OS MODELOS PREDITIVOS?

Os modelos preditivos são métodos matemáticos e estatísticos avançados que utilizam IA e dados históricos para prever resultados futuros com precisão (THOMAS; VIJAYARAGHAVAN; EMMANUEL, 2019). Essa abordagem consiste em desenvolver algoritmos que aprendem com os dados, sendo aplicável tanto em tarefas de classificação, como a detecção de *malware*, quanto em problemas de regressão, como a estimativa de níveis de ameaça (THOMAS; VIJAYARAGHAVAN; EMMANUEL, 2019).

Esses modelos são construídos com base em amostras de dados reais e utilizam técnicas estatísticas sofisticadas para identificar padrões ocultos. Aplicados em diversas áreas, como previsão do tempo, detecção de fraudes, análise de riscos financeiros, manutenção preditiva e diagnósticos médicos, eles aprimoram continuamente suas previsões, tornando-se cada vez mais precisos (IMAGING; BIOENGINEERING, 2020). A Figura 3 apresenta a estrutura da IA e como os modelos preditivos se integram em suas aplicações.

Figura 3 – Ramificação da IA



Fonte: <https://medium.com/@flowlabs/a-traffic-engineers-guide-to-machine-learning-and-artificial-intelligence-77d84f812a79>

Paralelamente, a modelagem computacional utiliza computadores para simular e analisar sistemas complexos, integrando conhecimentos de matemática, física e ciência da computação. Esses modelos incluem variáveis que representam os elementos do sistema em estudo, permitindo que sejam ajustadas individualmente ou em conjunto para observar seus impactos. Por meio dessa abordagem, é possível compreender e prever o comportamento dos sistemas (National Institute of Biomedical Imaging and Bioengineering, 2020).

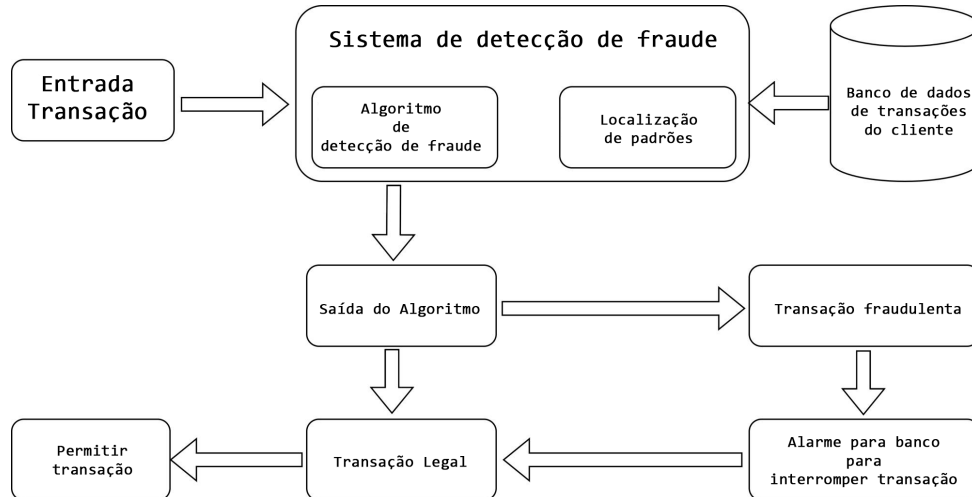
Além disso, os modelos estatísticos servem como base para muitos métodos preditivos contemporâneos. Eles permitem a análise de grandes volumes de dados e possibilitam inferências e previsões sobre comportamentos futuros. As técnicas estatísticas mais empregadas nessas questões incluem:

- **Modelos de Classificação**
- **Regressão Linear**
- **Regressão Logística**
- **Séries Temporais**

A identificação de fraudes é um campo onde os modelos de classificação são usados para a identificação e prevenção de crimes financeiros. Algoritmos de aprendizagem de máquina, tais como a Floresta Aleatória e as Árvores de Decisão, têm sido frequentemente empregados para aprimorar a precisão dos sistemas de detecção de fraudes. Esses modelos se sobressaem, com a floresta aleatória alcançando uma taxa de acerto de 99,18% na detecção de transações fraudulentas (OLALEYE; ODENIYI; ALESE, 2024). Isso evidencia o seu efeito na prevenção efetiva de

fraudes em operações financeiras. A Figura 4 mostra o fluxograma dos algoritmos para classificar as transações fraudulentas.

Figura 4 – Fluxograma para classificar transações fraudulentas



Fonte: (SARKER *et al.*, 2024)

O modelo de regressão linear é frequentemente utilizado em previsões numéricas. Eles são usados na avaliação de propriedades, proporcionando uma metodologia sistemática para, por exemplo, prever os preços dos imóveis com base em diversos atributos. Essas técnicas se destacam pela sua simplicidade e facilidade de entendimento, fazendo delas uma opção bastante apreciada entre os profissionais do ramo imobiliário. Ademais, a regressão linear engloba várias modalidades, incluindo modelos de mínimos quadrados ordinários, que provaram ser eficazes em variados cenários (TOTHÄFZAN, 2022) (HOXHA, 2023).

Os sistemas de recomendação são significativamente aprimorados pelos modelos de regressão logística, especialmente quando se trata de classificações categóricas. O modelo logístico multinomial bidirecional proposto por Wang, Bi & Qu (2020) trata as classificações como eventos mutuamente exclusivos, utilizando fatores latentes de usuários e itens para antecipar probabilidades de classificações. Este modelo não se limita a acomodar dados categóricos, mas também incorpora dados de co-variáveis, ultrapassando as técnicas convencionais de filtragem colaborativa.

Os modelos de séries temporais são bastante utilizados nas finanças, melhorando a acurácia das previsões financeiras através de várias metodologias que lidam com desafios como a não estacionariedade e a não linearidade. Isso possibilita uma previsão mais acurada dos valores dos ativos e das tendências do mercado. A avaliação multivariada de séries temporais, empregando métodos como o *GARCH* multivariado e modelos espaciais estaduais, é crucial para entender as relações interdependentes entre diversos instrumentos financeiros. Isso, por sua vez, aprimora a avaliação de riscos e a administração de portfólios (CHAN, 2001) (TSAY, 2014).

Os modelos preditivos e o *machine learning* estão intrinsicamente ligados, já que o *machine learning* fornece a base para a criação de modelos preditivos mais eficazes. Através de métodos de *machine learning*, os modelos preditivos são capazes de detectar padrões e relações em grandes quantidades de dados, possibilitando previsões mais precisas.

2.3 MACHINE LEARNING

O *machine learning* é um ramo da IA que se concentra em algoritmos que permitem que os computadores aprendam a partir da experiência. Segundo Mitchell (1997), uma máquina pode determinar se, ao adquirir experiência E, seu desempenho D melhora ao realizar uma tarefa T repetidamente. Como resultado, o *machine learning* é definido como algoritmos que podem melhorar seu desempenho em uma tarefa com base na experiência que adquiriram. Em outras palavras, *machine learning* consiste em um processo envolvendo treinamento a partir de dados e testes para validar seus resultados e determinar a porcentagem de acerto. Pode-se dizer que uma máquina aprende à medida que seus resultados melhoram com a validação e ajustes.

Sem a necessidade de programação explícita, os computadores podem identificar padrões, tomar decisões e melhorar seu desempenho com esses algoritmos (JAIN; TIWARI, 2024). A Figura 5 ilustra os principais passos do processo de *machine learning* e serve para descrever o processo.

Figura 5 – Passos de implementação de um algoritmo de *machine learning*



Fonte: <https://medium.com/dataseries/7-steps-to-machine-learning-how-to-prepare-for-an-automated-future-78c7918cb35d>

A primeira etapa consiste na coleta de dados, que é fundamental, pois o *machine learning* depende diretamente da qualidade e quantidade dos dados disponíveis. Os dados podem variar dependendo do tipo de problema a ser resolvido. Por exemplo, dados de classificação e regressão exigem conjuntos rotulados, enquanto problemas de agrupamento podem trabalhar com dados não rotulados. Sem dados relevantes, o *machine learning* não é viável, tornando essa etapa essencial para qualquer projeto (MITCHELL, 1997).

Na segunda etapa, realiza-se a exploração e preparação dos dados. Isso inclui limpar os dados brutos, corrigindo problemas como valores ausentes, dados duplicados e inconsistências. A normalização e padronização também são essenciais para assegurar que os dados estejam

adequados para os modelos matemáticos. Além disso, a visualização é uma ferramenta importante nesta etapa, pois ajuda a identificar padrões, anomalias e distribuições nos dados (WITTEN; FRANK; HALL, 2016).

A terceira etapa envolve a escolha do modelo mais apropriado para o problema em questão. Existem diversos algoritmos disponíveis, desde métodos estatísticos simples, como regressão linear, até modelos complexos, como Redes Neurais Artificiais e *Support Vector Machine* (SVM). A escolha deve considerar fatores como o objetivo do negócio, a natureza dos dados, a necessidade de interpretabilidade e o equilíbrio entre desempenho e recursos computacionais (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Na quarta etapa, inicia-se o treinamento do modelo, no qual os dados processados são usados para ajustar os parâmetros internos do modelo, permitindo que ele aprenda a mapear as entradas para as saídas esperadas. Modelos supervisionados, por exemplo, utilizam dados rotulados para verificar a diferença entre os valores reais e previstos, ajustando-se iterativamente para minimizar o erro. Por outro lado, o aprendizado não supervisionado busca identificar padrões em dados não rotulados, como agrupamentos ou reduções de dimensionalidade (GOODFELLOW; BENGIO; COURVILLE, 2016).

A quinta etapa é a validação, que consiste em avaliar o desempenho do modelo em um conjunto de dados separado do usado no treinamento. Essa prática ajuda a garantir que o modelo não esteja superajustado aos dados de treinamento, o que comprometeria sua capacidade de generalizar para novos dados. Técnicas como validação cruzada são frequentemente empregadas para esse propósito (JAMES *et al.*, 2013).

Na sexta etapa, ocorre a avaliação final do modelo. Nessa fase, um conjunto de testes é usado para medir o desempenho do modelo com métricas como precisão, *recall*, *F1-score* e erro médio quadrático, dependendo do tipo de problema. Também é importante verificar se o modelo apresenta viés ou variância excessiva, ajustando-o caso necessário para obter melhores resultados (KOHAVI; PROVOST, 1998).

Finalmente, a sétima etapa é a implantação do modelo. Após o treinamento, validação e avaliação, o modelo é implementado em um ambiente real onde pode ser utilizado para fazer previsões. Essa etapa inclui o monitoramento contínuo do desempenho do modelo, garantindo que ele mantenha sua precisão e utilidade ao lidar com novos dados no ambiente de produção (DOMINGOS, 2012).

Ao seguir essas etapas, é possível desenvolver sistemas robustos e adaptáveis, que podem ser aplicados a uma variedade de problemas, como reconhecimento de imagem, previsão de séries temporais e detecção de fraudes. Esse processo iterativo e baseado em dados é a base para o sucesso do *machine learning* em diferentes contextos.

2.3.1 Abordagens do *Machine Learning*

Existem várias abordagens de aprendizado dentro desse campo, incluindo aprendizado por reforço, aprendizado não supervisionado e aprendizado supervisionado (Figura 6). Cada abordagem tem seu próprio método e aplicação.

Figura 6 – Ramificação do *machine learning*



Fonte: <https://beatrizmaiads.medium.com/tipos-de-aprendizado-de-mC3A1quina-3-9a9052173bc4>

Os dois principais paradigmas do *machine learning* são o aprendizado supervisionado e o aprendizado não supervisionado, cada um com objetivos diferentes. O treinamento de algoritmos em conjuntos de dados rotulados é envolvido no aprendizado supervisionado. Nesse caso, o modelo aprende a mapear entradas para saídas conhecidas, tornando-o adequado para tarefas como classificação e regressão (VANKOV; GADHOUMI, 2024) (NAGARAJ, 2023). Por outro lado, o aprendizado não supervisionado trata de dados não rotulados e se concentra na descoberta de padrões ou agrupamentos sem resultados pré-estabelecidos. Esse tipo de aprendizado é frequentemente usado para agrupamento e redução de dimensionalidade (VINCI, 2024).

O aprendizado supervisionado requer dados rotulados, permitindo que o modelo aprenda com pares de entrada-saída (SUPERVISED..., 2023). O objetivo é prever os resultados com base nos recursos de entrada e maximizar a precisão por meio do treinamento (VALKENBORG *et al.*, 2023). A rede ajusta seus parâmetros com base na diferença entre a resposta desejada e a resposta real, esse ajuste ocorre de maneira iterativa. O processo de aprendizagem supervisionada é um sistema de *feedback* fechado em *loop*. A performance do sistema é avaliada pelo erro quadrático médio, com o objetivo de reduzir esse erro. Com um algoritmo apropriado, uma série de exemplos e um período de tempo adequado, o sistema é capaz de simular com razoável precisão o mapeamento desconhecido de entrada-saída (HAYKIN, 2009). A Tabela 1 mostra exemplos de algoritmos do aprendizado supervisionado e seus usos.

Tabela 1 – Algoritmos do aprendizado supervisionado e seus usos

Arquitetura	Abordagem	Tarefas	Casos de Uso
Árvores de Decisão	Aprendizado Simbólico	Classificação	Medicina, Agricultura
Regressão Linear	Aprendizado Estatístico	Regressão	Economia, Engenharia
Redes Neurais	Aprendizado Profundo	Classificação, Regressão	Visão Computacional
<i>Naive Bayes</i>	Aprendizado Probabilístico	Classificação	Detecção de Spam
KNN	Aprendizado Estatístico	Classificação, Regressão	Comércio Eletrônico, Segmentação de Mercado

Fonte: O Autor

As Árvores de Decisão são técnicas baseadas em raciocínio simbólico amplamente utilizadas em classificação e tomada de decisões, especialmente em cenários que envolvem múltiplas alternativas. Sua aplicação é destacada em áreas como medicina e agricultura, onde a organização hierárquica das decisões facilita a análise de critérios, melhorando a clareza dos resultados. Além disso, sua transparência e interpretabilidade tornam esse método valioso em contextos que exigem explicações acessíveis e fundamentadas, promovendo maior confiança nos resultados.

A Regressão Linear, por sua vez, é uma técnica clássica de aprendizado estatístico amplamente empregada na previsão de valores contínuos. Ela modela relações entre variáveis dependentes e independentes, desempenhando um papel crucial em áreas como economia e engenharia. Muito utilizada para análise de tendências e desenvolvimento de modelos preditivos, sua simplicidade e eficiência fazem dela uma ferramenta confiável para aplicações que demandam precisão, como projeções financeiras ou análise de desempenho de sistemas.

As Redes Neurais, inspiradas na estrutura do cérebro humano, utilizam aprendizagem profunda para resolver tarefas complexas de classificação e regressão. Com aplicações notáveis em visão computacional, elas são capazes de identificar padrões intrincados, como reconhecimento de imagens e análise de dados visuais. Sua capacidade de processar grandes volumes de dados e aprender representações não lineares as torna indispensáveis em cenários que exigem soluções tecnológicas sofisticadas e de alto desempenho.

O método *Naive Bayes*, fundamentado em aprendizado probabilístico, oferece uma abordagem simples e eficaz para tarefas de classificação. Sua eficiência é particularmente evidente na filtragem de spam, onde cálculos probabilísticos distinguem com precisão mensagens desejadas de indesejadas. Sua simplicidade matemática e rápida capacidade de processamento o tornam uma ferramenta amplamente utilizada em problemas que envolvem grandes volumes de dados, como análise de texto e processamento de linguagem natural.

Por fim, *K-Nearest Neighbors* (KNN), também fundamentado em aprendizado estatístico, destaca-se em tarefas de classificação e regressão graças à sua habilidade de identificar padrões em vizinhanças próximas. Aplicado com frequência em comércio eletrônico e segmentação de mercado, o KNN pode recomendar produtos ou agrupar consumidores com base em similaridades nos dados. Sua simplicidade operacional e flexibilidade o tornam uma solução eficaz para problemas que requerem análise de proximidade e identificação de relações espaciais, atendendo a uma ampla variedade de demandas analíticas.

Por outro lado, o aprendizado não supervisionado usa dados não rotulados, o que permite que o modelo explore estruturas inerentes nos dados. O objetivo é encontrar padrões ou agrupamentos ocultos, como identificar agrupamentos em conjuntos de dados complexos (VINCI, 2024). O aprendizado não supervisionado emprega uma métrica independente de tarefa para avaliar a qualidade da representação que a rede precisa aprender. Ao ajustar-se às regularidades estatísticas dos dados de entrada, a rede adquire a habilidade de gerar representações internas que codificam atributos dos dados, resultando na formação automática de novas classes (HAYKIN, 2009). A Tabela 2 mostra exemplos de algoritmos do aprendizado não supervisionado e seus usos.

Tabela 2 – Algoritmos do aprendizado não supervisionado e seus usos

Arquitetura	Abordagem	Tarefas	Casos de Uso
<i>K-Means</i>	Agrupamento	Agrupamento	Segmentação de Mercado
Análise de Associação	Regras de Associação	Extração de Regras	Recomendações de Produtos
Análise de Componentes Principais (PCA)	Redução de Dimensionalidade	Redução de Dimensionalidade	Visualização de Dados
Algoritmo de Agrupamento Hierárquico	Agrupamento	Agrupamento	Classificação de Documentos, Biologia

Fonte: O Autor

O *K-Means* é uma técnica amplamente utilizada para agrupar dados em subconjuntos baseados na similaridade, medindo as distâncias entre os pontos de dados. Sua principal função é criar agrupamentos coesos, sendo especialmente valiosa em aplicações como segmentação de mercado, onde clientes são classificados em grupos com características semelhantes. Essa abordagem permite que estratégias de marketing sejam mais direcionadas e eficazes, atendendo às necessidades específicas de cada segmento identificado.

A Análise de Associação, por sua vez, utiliza normas associativas para identificar conexões entre elementos em grandes volumes de dados. Sua principal função é a extração de regras, sendo aplicada com destaque na recomendação de produtos. Por exemplo, ao analisar padrões de compra, o algoritmo pode identificar itens frequentemente adquiridos juntos, otimizando

sistemas de recomendação e estratégias de vendas em plataformas de *e-commerce*.

A Técnica de *Principal Component Analysis* (PCA) é uma ferramenta poderosa para reduzir a complexidade de conjuntos de dados, preservando a maior parte da variabilidade presente neles. Sua principal função é a diminuição da dimensionalidade, o que facilita a análise de dados de alta dimensão. Comumente empregada na visualização e exploração de dados complexos, a PCA permite simplificar a representação de informações sem perder aspectos relevantes, tornando-a ideal para aplicações que envolvem grandes volumes de variáveis.

O Algoritmo de Agrupamento Hierárquico é outra abordagem de agrupamento, que organiza dados em uma estrutura hierárquica de agrupamentos. Sua função é agregar dados de forma progressiva, sendo amplamente aplicado em áreas como categorização de documentos e biologia. Ao criar hierarquias claras, essa técnica simplifica a análise e a classificação, facilitando a organização e o entendimento de dados complexos em diferentes domínios.

O aprendizado por reforço é uma técnica que treina softwares para tomar decisões visando alcançar os melhores resultados possíveis. Ele imita o processo de tentativa e erro que as pessoas usam para atingir seus objetivos. Ações do software que contribuem para o objetivo são reforçadas, enquanto as ações que desviam dele são ignoradas. Enquanto processam dados, os algoritmos de aprendizado por reforço usam um paradigma de recompensa e punição. Eles aprendem com o experiência de cada ação e escolhem os melhores métodos de processamento de forma independente. Como a melhor estratégia geral pode exigir sacrifícios a curto prazo, os algoritmos também podem receber gratificação tardia. Portanto, a melhor estratégia que eles descobrem pode incluir algumas punições ou retrocessos ao longo do caminho. O aprendizado por reforço é uma ferramenta útil para ajudar a IA a fazer excelentes coisas em ambientes desconhecidos (Amazon Web Services, 2024). A Tabela 3 mostra exemplos de algoritmos do aprendizado por reforço e seus usos.

Tabela 3 – Algoritmos do aprendizado por reforço e seus usos

Arquitetura	Abordagem	Tarefas	Casos de Uso
Algoritmo de Política Gradiente	Métodos de Política	Controle de Políticas	Otimização de Processos
<i>Q-Learning</i>	Métodos de Valor	Controle de Políticas	Sistemas de Recomendação
<i>Proximal Policy Optimization</i> (PPO)	Métodos de Política	Controle de Políticas	Navegação Autônoma

Fonte: O Autor

O Algoritmo de Política Gradiente é uma técnica baseada em aprendizado por reforço que utiliza estratégias específicas para gerenciar políticas em ambientes dinâmicos e complexos. Sua principal aplicação está na otimização de processos, permitindo a adaptação e o aprimoramento de políticas de decisão ao longo do tempo. Essa abordagem é especialmente valiosa

em cenários onde decisões contínuas precisam ser refinadas para maximizar o rendimento em condições variáveis.

O *Q-Learning*, por sua vez, é um método de aprendizado por reforço que utiliza técnicas baseadas em valores para gerenciar políticas de decisão. Ele funciona aprendendo a escolher ações que maximizam recompensas futuras com base em estados observados. Frequentemente empregado em sistemas de recomendação, como plataformas de *streaming* ou *e-commerce*, *Q-Learning* aprimora a experiência do usuário ao personalizar ações de forma inteligente e eficiente.

Semelhante ao algoritmo de política gradiente, o PPO é uma técnica de aprendizado por reforço que também utiliza estratégias políticas para o controle de políticas. Sua aplicação é amplamente explorada em navegação autônoma, permitindo que veículos e *drones* aprendam a tomar decisões seguras e produtivas em tempo real. A robustez do PPO o torna uma escolha confiável para sistemas autônomos que operam em ambientes complexos e dinâmicos, onde a tomada de decisão precisa ser altamente eficiente.

Ainda no âmbito do aprendizado de máquinas, as redes neurais artificiais representam uma das técnicas mais poderosas de aprendizagem de máquinas. O aprendizado de máquinas inclui uma vasta variedade de métodos e algoritmos concebidos para permitir que sistemas aprendam e tomem decisões baseadas em dados, enquanto as redes neurais artificiais são um tipo específico de modelos que se inspiram na estrutura e funcionamento do cérebro humano.

2.3.2 Redes Neurais Artificiais

Segundo Haykin (2009) uma rede neural é um processador distribuído, formado por unidades de processamento simples, com uma inclinação natural para acumular conhecimento experiencial e representar a forma como o cérebro realiza uma tarefa ou função. Elas se assemelham da função cerebral humana principalmente em dois sentidos: A rede neural obtém conhecimento do seu ambiente através de um processo de aprendizagem e que forças de ligação entre os neurônios, conhecidas como pesos sinápticos, são empregadas para guardar o conhecimento obtido.

Segundo Arbib (2012) o sistema nervoso humano funciona como um sistema de três etapas Figura 7. O cérebro, está no centro do sistema, recebendo constantemente informações, interpretando-as e fazendo as escolhas adequadas. Na figura, são mostrados dois conjuntos de setas. As que vão da esquerda para a direita (mostradas em preto) que indicam a transmissão direta de sinais que transportam informações através do sistema. E as setas que apontam da direita para a esquerda (mostradas em azul) representam a presença de *feedback* no sistema.

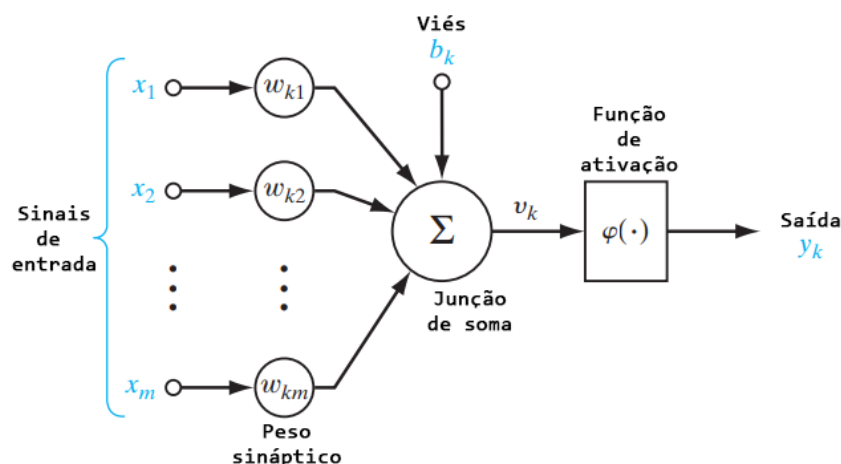
Figura 7 – Representação em diagrama de blocos do sistema nervoso.



Fonte: Arbib (2012)

Um neurônio é uma unidade de processamento de informações que é fundamental para o funcionamento de uma rede neural. A Figura 8 mostra o modelo básico de um neurônio com suas principais características. Um neurônio sendo um agrupamento de conexões, cada uma delas possuindo um peso distinto. Em particular, um sinal x_j que entra na sinapse j e se conecta ao neurônio k é multiplicado pelo peso w_{kj} . Uma adição para somar os sinais de entrada, ponderados pela peso correspondente do neurônio e uma função de ativação, também como função de compressão, sendo usada para limitar a amplitude dos sinais de saída no neurônio.

Figura 8 – Modelo não linear de um neurônio, rotulado como K.



Fonte: Haykin (2009)

O modelo neural apresentado na Figura 8 também incorpora um viés externo, indicado por b_k . O efeito do viés b_k é elevar ou reduzir a entrada líquida da função de ativação, conforme se apresenta como positivo ou negativo, respectivamente. Em termos matemáticos, podemos descrever o neurônio k , através da escrita do seguinte par de equações:

$$u_k = \sum_{j=1}^m w_{kj} \times x_j \quad (2.1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2.2)$$

onde x_1, x_2, \dots, x_m representam os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ representam os pesos sinápticos correspondentes do neurônio k ; u_k (não representado na Figura 8) representa a saída do combinador linear resultante dos sinais de entrada; b_k representa o viés; $\varphi(\cdot)$ representa a função de ativação; e y_k representa o sinal de saída do neurônio. A utilização do viés b_k leva à aplicação de uma transformação similar à saída u_k do combinador linear no modelo ilustrado na Figura 8, como ilustrado por

$$u_k + b_k \quad (2.3)$$

Dentro das redes neurais ainda temos o conceito de *feedback*, que acontece quando a saída de um componente afeta sua própria entrada, estabelecendo vias restritas para a transmissão de sinais dentro do sistema. A Figura 9 apresenta o diagrama de fluxo de um sistema de *feedback*, no qual os sinais de entrada $x_j(n)$, o sinal interno $x'_j(n)$ e o sinal de saída $y_k(n)$ representam funções da variável de tempo discreta n . Presume-se que o sistema seja linear, composto por um trajeto direto e um trajeto de retorno, representados, respectivamente, pelos "operadores" A e B. A partir da Figura 9 temos as relações entre o sinal de entrada e a saída dada pelas equações

$$y_k(n) = A[x'_j(n)] \quad (2.4)$$


e

$$x'_j(n) = x_j(n) + B[y_k(n)] \quad (2.5)$$

Os colchetes são adicionados para destacar que A e B desempenham o papel de operadores. Ao remover $x'_j(n)$ das equações 2.4 e 2.5, chegamos a uma expressão que vincula diretamente a entrada e a saída do sistema. Isso torna o cálculo do comportamento do sistema mais simples, concentrando-se somente na interação entre o sinal de entrada e o de saída temos o seguinte

$$y_k(n) = \frac{A}{1 - AB}[x_j(n)] \quad (2.6)$$

Figura 9 – Gráfico de fluxo de sinal de um sistema de *feedback* de ciclo único




Fonte: Haykin (2009)

A estrutura dos neurônios em uma rede neural tem uma ligação direta com o algoritmo de aprendizado empregado para o seu treinamento. Os algoritmos de aprendizado podem ser considerados estruturados. Temos algumas estruturas dentro de uma rede neural sendo elas:

- **Redes *Feedforward*:** No modelo de rede neural em camadas, os neurônios são dispostos em níveis. Em sua forma mais básica, existe uma camada de entrada que se conecta diretamente a uma camada de saída, criando uma rede *feedforward* de uma única camada. A computação se dá apenas na camada de saída, enquanto a camada de entrada não realiza operações. A Figura 10(a) este tipo de rede.

Nas redes neurais *feedforward* ainda temos uma rede multicamadas que engloba uma ou mais camadas ocultas, onde os neurônios, conhecidos como unidades ocultas, processam informações de maneira mais sofisticada. Esses neurônios não são perceptíveis na entrada ou saída da rede, mas possibilitam que a rede obtenha estatísticas avançadas, oferecendo uma visão abrangente através de conexões sinápticas extras e interações neurais mais elaboradas. A Figura 10(b) este tipo de rede.


Figura 10 – Redes Neurais *feedforward*



Fonte: Haykin (2009)

- **Redes Recorrentes:** Uma rede neural recorrente se diferencia de uma *feedforward* devido à presença de pelo menos um laço de *feedback*. Por exemplo, uma rede recorrente pode ser formada por uma única camada de neurônios, onde cada um deles envia seu sinal de saída para as entradas de todos os demais. A Figura 11 mostra um exemplo de uma rede neural recorrente.

Figura 11 – Rede Neural Recorrente



Fonte: <https://venelinvalkov.medium.com/making-a-predictive-keyboard-using-recurrent-neural-networks-tensorflow-for-hackers-part-v-3f238d824218>

As redes neurais adquirem sua capacidade de processamento por meio de uma estrutura distribuída e paralela, além de sua habilidade de aprender e generalizar, gerando saídas para entradas que não foram vistas durante o processo de treinamento. Essas características possibilitam a resolução aproximada de problemas complexos. Contudo, para serem eficientes, é necessário integrar as redes neurais a um sistema de engenharia, no qual problemas complexos são segmentados em tarefas simples e cada rede neural é designada a uma tarefa de acordo com suas habilidades. As redes neurais possuem os seguintes benefícios:

- **Não linearidade**
- **Mapeamento de Entrada-Saída**
- **Adaptabilidade**
- **Resposta Evidencial**
- **Informação Contextual**
- **Tolerância a Falhas**
- **Implementabilidade em VLSI**
- **Uniformidade na Análise e Design**
- **Analogia Neurobiológica**

As redes neurais apresentam diversas características que as tornam ferramentas poderosas para processamento de dados e modelagem de padrões complexos. Uma das propriedades fundamentais dessas redes é a não linearidade. Compostas por neurônios não lineares, elas exibem uma não linearidade distribuída, o que é essencial para lidar com sinais de entrada gerados por mecanismos não lineares, como os sinais de fala. Essa capacidade permite às redes neurais capturar e processar padrões que seriam inacessíveis a modelos lineares tradicionais.

Outra característica relevante é o mapeamento de entrada e saída, realizado por meio do aprendizado supervisionado. Esse processo envolve o ajuste dos pesos sinápticos com base em exemplos de treinamento etiquetados, permitindo à rede minimizar a discrepância entre as respostas esperadas e as observadas. Essa abordagem assemelha-se à inferência estatística não paramétrica, pois os limites de decisão são calculados sem a necessidade de um modelo explícito de distribuição. Assim, redes neurais e técnicas estatísticas encontram um ponto de convergência no tratamento de dados complexos.

A adaptabilidade é outra propriedade marcante das redes neurais. Elas têm a capacidade de ajustar seus pesos em resposta a mudanças no ambiente, facilitando re-treinamentos rápidos e ajustes em tempo real. Essa flexibilidade é particularmente útil em cenários dinâmicos, como controle de sistemas e classificação em ambientes variáveis. Contudo, essa adaptabilidade precisa ser equilibrada, já que respostas excessivamente rápidas podem resultar em instabilidades. O desafio entre estabilidade e plasticidade reforça a necessidade de calibração cuidadosa, garantindo que a adaptabilidade seja explorada sem comprometer a robustez do sistema.

No contexto de classificação de padrões, as redes neurais também oferecem uma resposta evidencial, ou seja, a capacidade de indicar o grau de confiança em suas decisões. Essa informação é valiosa para rejeitar padrões que não se enquadram claramente nas categorias previstas, aumentando a eficiência e a precisão na categorização. Complementarmente, a estrutura e a ativação das redes neurais permitem o processamento de informação contextual. Cada neurônio é influenciado pela atividade dos demais, o que torna a integração de informações contextuais mais fluida e natural.

Outro ponto notável é a tolerância a falhas. Redes neurais implementadas em hardware apresentam um desempenho que se deteriora de forma progressiva sob condições adversas, em vez de falharem catastróficamente. Mesmo que danos em neurônios ou conexões prejudiquem a recuperação de padrões, a degradação significativa só ocorre quando o dano é extenso. Essa característica torna as redes neurais mais resilientes, embora em alguns casos sejam necessárias ações corretivas no algoritmo de treinamento para manter essa tolerância.

A implementabilidade em *Very-Large-Scale Integration* (VLSI) é um aspecto técnico que destaca o potencial das redes neurais. Devido à sua estrutura paralela, elas são compatíveis com a tecnologia de VLSI, possibilitando processamento rápido e hierárquico de comportamentos complexos. Além disso, a uniformidade na análise e design das redes garante sua aplicação universal no processamento de informações. Essa uniformidade facilita a integração de teorias

e algoritmos de aprendizado em diferentes contextos e permite a construção de redes modulares por meio de componentes harmoniosos.

Por fim, há uma forte analogia neurobiológica na concepção das redes neurais, que são inspiradas no funcionamento do cérebro. Assim como o cérebro realiza processamento paralelo tolerante a falhas, as redes neurais replicam esse comportamento para resolver problemas complexos. Essa conexão é explorada tanto por neurobiólogos quanto por cientistas da computação, que utilizam redes neurais para entender fenômenos biológicos, como o reflexo vestibulo-ocular, e para desenvolver tecnologias como circuitos neuromórficos inspirados na retina. Essas interações mostram como o avanço no conhecimento neurobiológico pode influenciar diretamente o desenvolvimento de tecnologias eletrônicas e VLSI.

Essas características tornam as redes neurais ferramentas poderosas e versáteis, com aplicações que vão desde a modelagem de sistemas complexos até a solução de problemas práticos em áreas como controle, classificação e processamento de dados.

As redes neurais podem executar diversos tipos de funções, assim a seleção de uma regra de aprendizado específica é afetada pela tarefa a ser aprendida, cuja variedade confirma a universalidade das redes neurais. Abaixo temos alguns exemplos das tarefas que podem ser executadas pelas redes neurais.

- **Associação de Padrões**
- **Reconhecimento de Padrões**
- **Controle**
- **Formação de Feixes (*Beamforming*)**

As redes neurais têm grande potencial para aplicações que envolvem a identificação e associação de padrões, simulando processos realizados pelo cérebro humano. Um exemplo disso é a associação de padrões, que se assemelha ao funcionamento de uma memória associativa, um tipo de memória distribuída que aprende através de associações. Esse conceito pode ser dividido em dois tipos principais: a auto-associação, que permite a recuperação de padrões a partir de versões parciais e utiliza aprendizado não supervisionado, e a heteroassociação, que alinha padrões de entrada e saída por meio de aprendizado supervisionado. Essas capacidades são essenciais para a modelagem de sistemas que exigem a recuperação ou transformação de informações de forma eficiente.

O reconhecimento de padrões é outra habilidade fundamental das redes neurais, inspirada na competência humana para identificar informações sensoriais de maneira rápida e precisa. Por exemplo, os seres humanos podem reconhecer rostos, vozes e até diferenciar objetos pelo odor, mesmo em condições adversas. Da mesma forma, redes neurais são projetadas para associar sinais de entrada a categorias predefinidas, criando limites de decisão no espaço

multidimensional de classes durante a fase de treinamento. Após serem treinadas, essas redes conseguem identificar padrões inéditos, utilizando as informações assimiladas nos dados de treinamento. Essa abordagem estatística permite segmentar o espaço de decisão em áreas associadas a diferentes classes, tornando as redes eficazes na categorização de padrões complexos.

As redes neurais também se destacam no controle de sistemas, simulando o funcionamento do cérebro humano na administração de múltiplos atuadores e no gerenciamento de variações. O aprendizado desempenha um papel central nesse contexto, permitindo que as redes ajustem suas decisões de maneira adaptativa e eficiente. Essa característica torna as redes neurais adequadas para aplicações em controle dinâmico, como automação industrial, robótica e gestão de sistemas complexos.

Outra aplicação interessante é a formação de feixes (*beamforming*), utilizada em tecnologias como radares e sonares. Essa técnica busca distinguir sinais de interesse em meio ao ruído de fundo, sendo fundamental para identificar e rastrear alvos específicos em ambientes ruidosos. Apesar de ser uma tarefa desafiadora, devido à direção incerta dos sinais e à ausência de informações sobre interferências, as redes neurais podem simplificar esse processo. Por meio de métodos como o cancelador de lóbulos laterais generalizado, elas conseguem melhorar a precisão na separação de sinais e na identificação de padrões relevantes.

Essas capacidades demonstram a versatilidade das redes neurais em tarefas que demandam identificação, controle e processamento de padrões, contribuindo para avanços significativos em áreas como processamento de sinais, automação e tecnologias de detecção.

A Tabela 4 apresenta exemplos de arquiteturas de redes neurais artificiais e para que são usados.

Tabela 4 – Algoritmos das Redes Neurais Artificiais e seus usos

Arquitetura	Abordagem	Tarefas	Casos de Uso
<i>Perceptron</i>	Redes Neurais Simples	Classificação	Reconhecimento de Padrões
Redes Neurais <i>Feedforward</i>	Redes Neurais Multicamadas	Classificação, Regressão	Diagnóstico médico, Previsão de Vendas
<i>Convolutional Neural Network</i> (CNN)	Aprendizado Profundo	Classificação de Imagens	Reconhecimento Facial, Diagnóstico por imagem
<i>Recurrent Neural Network</i> (RNN)	Aprendizado Profundo	Processamento de Sequências	Análise de Sentimentos, Tradução Automática
<i>Long Short-Term Memory</i> (LSTM)	RNN com Memória a Longo Prazo	Processamento de Sequências	Previsão de Séries Temporais, Geração de Texto
<i>Generative Adversarial Network</i> (GAN)	Aprendizado Profundo	Geração de Dados	Criação de Imagens, Aumento de Dados

Fonte: O Autor

O Perceptron é a estrutura mais básica de uma rede neural, sendo uma das primeiras metodologias desenvolvidas no campo. Sua principal função é a classificação, frequentemente aplicada à identificação de padrões simples em dados. Apesar de suas limitações ao lidar com problemas que envolvem dados não separáveis linearmente, o Perceptron desempenha um papel essencial como alicerce para a criação de arquiteturas mais complexas e sofisticadas em redes neurais.

As Redes Neurais *Feedforward*, que utilizam múltiplas camadas para processar informações, são amplamente empregadas em tarefas de classificação e regressão. Sua capacidade de identificar padrões complexos em dados de entrada as torna ideais para aplicações como diagnóstico médico, previsão de vendas e outras atividades preditivas. Essas redes representam uma evolução do Perceptron ao incorporar múltiplas camadas e conexões, aumentando significativamente sua capacidade de modelar relações entre variáveis.

No campo da análise visual, as CNN se destacam como uma das abordagens mais eficazes. Projetadas para explorar a estrutura espacial dos dados, as CNNs são especialmente úteis em tarefas como reconhecimento facial, diagnóstico por imagem e outras aplicações de visão computacional. Sua arquitetura é otimizada para identificar padrões hierárquicos, como bordas e texturas, o que as torna indispensáveis em problemas envolvendo imagens.

Por outro lado, as RNN são projetadas para processar dados sequenciais, capturando dependências temporais que são cruciais em tarefas como avaliação de emoções, tradução automática e análise de séries temporais. A capacidade das RNNs de tratar sequências as torna adequadas para problemas que dependem da ordem e da continuidade dos dados de entrada, mas sua eficácia pode ser limitada em situações que exigem o processamento de dependências de longo prazo.

Para superar essas limitações, surgiram os LSTM, uma variação das RNNs que incorpora mecanismos de memória de longo prazo. Essa arquitetura resolve as dificuldades enfrentadas pelas RNNs convencionais, permitindo o aprendizado e a retenção de informações ao longo de longas sequências. Os LSTM são particularmente eficazes em tarefas como previsão de séries temporais, criação de texto e tradução automática, onde as relações entre eventos distantes são fundamentais.

Outro avanço notável no aprendizado profundo são as GAN, que combinam dois modelos em um processo de aprendizado competitivo para gerar novos dados sintéticos. As GANs têm sido amplamente utilizadas para criar imagens realistas, ampliar conjuntos de dados limitados e melhorar o desempenho de modelos preditivos. Sua capacidade de produzir dados realistas a partir de distribuições aprendidas as torna uma ferramenta poderosa em situações onde os dados reais são escassos ou difíceis de obter.

Essas arquiteturas, cada uma com suas características e aplicações específicas, exemplificam a evolução contínua do campo das redes neurais. Desde o simples Perceptron até as

sofisticadas GANs, cada abordagem contribui de forma única para expandir as possibilidades de modelagem e análise em diversos domínios.

As arquiteturas de redes neurais têm se mostrado aplicáveis a diversos problemas, oferecendo soluções eficazes em áreas como saúde, finanças e tecnologia. No entanto, essas redes enfrentam limitações significativas, especialmente devido à sua natureza de "caixa preta", o que dificulta a interpretação das relações entre as características de entrada e as saídas geradas pelo modelo. À medida que as redes neurais se tornam mais complexas, com o aumento do número de neurônios e camadas, compreender e explicar os processos internos que levam aos resultados torna-se um desafio ainda maior (SHAGUN, 2023).

De acordo com Shagun (2023), os algoritmos de *machine learning* já transformaram setores importantes, mas a dificuldade de interpretar o que ocorre por trás da "caixa preta" limita sua credibilidade e eficiência em muitas aplicações. Essa falta de transparência torna essencial o desenvolvimento de modelos explicáveis, capazes de fornecer informações claras sobre como as decisões são tomadas.

Nesse contexto, surgem as *Explainable Neural Network* (xNN), projetadas para oferecer maior clareza e compreensão dos processos internos. As xNNs introduzem mecanismos que permitem explicar as características e transformações não lineares que a rede utiliza para alcançar seus resultados. Dessa forma, é possível compreender melhor as conexões entre entradas e saídas, visualizando as funções aprendidas pela rede e elucidando os padrões que ela utiliza (SHAGUN, 2023).

A crescente complexidade e "opacidade" dos modelos de *machine learning*, especialmente redes neurais profundas, destaca a importância das xNNs. Embora essas redes sejam extremamente eficientes em tarefas como identificação de imagens, processamento de linguagem natural e previsão, a falta de transparência em sua lógica de decisão é problemática em áreas críticas como saúde, finanças e justiça penal, onde explicabilidade e confiança são essenciais (SHAGUN, 2023).

As xNNs não apenas ajudam a entender como as entradas são transformadas em saídas, mas também permitem identificar quais atributos dos dados influenciam mais fortemente as decisões. Isso aumenta a confiabilidade dos modelos e possibilita a detecção de potenciais vieses ou falhas nas previsões, contribuindo para maior segurança e eficiência em aplicações sensíveis (MOLNAR, 2020).

Diversos métodos foram desenvolvidos para aumentar a interpretabilidade das redes neurais. A visualização em camadas, por exemplo, permite aos usuários observar como diferentes camadas da rede respondem a características de entrada específicas. Em redes convolucionais, isso pode incluir a visualização de filtros que evidenciam padrões detectados. Outras técnicas, como *Local Interpretable Model-agnostic Explanations* (LIME) e *Shapley Additive Explanations* (SHAP), ajudam a identificar a importância de cada característica na decisão fi-

nal da rede, facilitando a compreensão de quais variáveis têm maior influência nos resultados (LUNDBERG; LEE, 2017).

Outro método relevante é o uso de modelos simples como aproximações de redes complexas. Em vez de recorrer diretamente a uma rede altamente sofisticada, pode-se empregar um modelo mais básico, como regressão linear, para reproduzir seu comportamento. Isso oferece uma visão mais clara, já que modelos simples são mais fáceis de interpretar (SHAGUN, 2023).

A necessidade de xNNs é especialmente evidente em setores regulados, onde a explicabilidade não é apenas desejável, mas muitas vezes exigida por legislações. As xNNs oferecem uma série de benefícios, como:

- **Aumentar a Confiança do Usuário:** Explicações claras sobre as decisões feitas pelo modelo aumentam a confiança dos usuários nos sistemas de IA.
- **Facilitar a Compreensão e a Análise:** Desenvolvedores e pesquisadores podem entender melhor os modelos, otimizando-os para obter melhor desempenho (MOLNAR, 2020).
- **Mitigar Viéses:** A transparência sobre como o modelo toma decisões ajuda a identificar e corrigir vieses nos dados ou na modelagem (SHAGUN, 2023).

Assim, as xNNs estão transformando o futuro das redes neurais, tornando-as mais confiáveis, transparentes e adequadas para aplicações críticas, enquanto atendem à crescente demanda por explicabilidade e responsabilidade nos sistemas de IA.

2.3.3 Preparação dos Dados

Os dados precisam passar por um processo essencial de limpeza, cujo objetivo é remover valores ausentes, inconsistências e duplicatas que poderiam distorcer a análise. Valores ausentes, por exemplo, podem surgir devido a erros de entrada ou à ausência de informações durante o preenchimento de questionários. Ignorá-los pode introduzir viés no modelo, comprometendo a precisão das previsões. Esse processo de limpeza melhora a qualidade do conjunto de dados, garantindo maior confiabilidade nos resultados do modelo. Assim, assegurar que os dados estejam devidamente preparados é uma base indispensável para o sucesso de qualquer projeto de IA .


Com os dados limpos, realiza-se a análise exploratória, etapa fundamental para examinar as principais características do conjunto de informações. Essa análise permite identificar padrões, inconsistências e compreender a distribuição das variáveis, além de explorar possíveis relações entre elas (LUCIANO, 2023). Os *insights* obtidos nessa fase orientam o tratamento e a modelagem de dados, assegurando que as etapas subsequentes sejam conduzidas de maneira fundamentada e eficiente.

A normalização e a transformação de dados são etapas cruciais para garantir escalas comparáveis entre as variáveis. Frequentemente, diferentes variáveis apresentam unidades de medida ou intervalos distintos, o que pode prejudicar o aprendizado do modelo. A normalização equilibra a contribuição de cada variável, evitando que variáveis em escalas maiores dominem o modelo. Além disso, dependendo do algoritmo utilizado, pode ser necessário converter variáveis categóricas em formatos numéricos, já que a maioria dos métodos de *machine learning* opera com entradas numéricas. Essas práticas garantem um aprendizado mais eficiente e preciso (WALACH; FILZMOSER; HRON, 2018).

A divisão dos dados em conjuntos de treinamento e teste é uma prática essencial para a construção de modelos robustos. O conjunto de treinamento é usado para ajustar o modelo, enquanto o conjunto de teste avalia seu desempenho em dados novos. Essa abordagem previne o *overfitting*, situação em que o modelo aprende padrões específicos do conjunto de treinamento, mas falha em generalizar para novos dados. Essa generalização é especialmente crítica em aplicações sensíveis, como na área da saúde, onde a precisão é vital.

O método *hold-out* é simples e amplamente utilizado, separando o conjunto total em duas partes: 80% dos dados são destinados ao treinamento do modelo, enquanto os 20% restantes são reservados para a avaliação. Essa abordagem é eficiente em termos de processamento e proporciona uma medida inicial da capacidade de generalização do modelo. No entanto, os resultados podem variar dependendo da divisão inicial dos dados, o que representa uma limitação dessa técnica (RAHARDJA, 2024).

Figura 12 – Método *Hold-out*



Fonte: <https://machine-learning-tutorial-abi.readthedocs.io/en/latest/content/overview/crossvalidation.html>

No método de validação cruzada (*cross-validation*) os dados são divididos em partes iguais. Em cada iteração, uma das partes é utilizada como conjunto de teste, enquanto os outros quatro são utilizados para treinamento. Esse processo se repete de forma que cada parte sirva como conjunto de teste uma vez. A Figura 13 mostra a separação dos dados em cada iteração.

A validação cruzada permite obter uma média dos desempenhos ao longo das iterações,

o que contribui para uma estimativa mais precisa da capacidade de generalização do modelo. Esse método é especialmente útil em conjuntos de dados menores, como no caso do presente estudo, pois maximiza o uso dos dados para tanto treinamento quanto teste (KÄRKKÄINEN, 2014).

Figura 13 – Método *Cross-validation* (5 partições)



Fonte: <https://medium.com/@jaz1/holdout-vs-cross-validation-in-machine-learning-7637112d3f8f>

2.3.4 Avaliação dos Modelos

A avaliação do modelo é uma etapa crucial para garantir que ele atenda aos objetivos do projeto e forneça previsões precisas sobre a segurança dos ambientes domésticos para idosos (SIMON; ALIFERIS, 2024). A matriz de confusão é uma ferramenta essencial nesse processo, pois organiza as previsões em categorias como Verdadeiros Positivos e Falsos Negativos, permitindo identificar tanto os acertos quanto os erros do modelo. Com base na matriz de confusão, calculamos métricas como acurácia, precisão, *recall* e *F1-score*, que oferecem diferentes perspectivas sobre o desempenho do modelo, ajudando a ajustar e melhorar sua eficácia para aplicações práticas (SURESHKUMAR *et al.*, 2024).

A matriz de confusão é uma ferramenta essencial para avaliar o desempenho de um modelo de classificação, pois oferece uma visão detalhada sobre as previsões realizadas em comparação com os valores reais. Ela organiza os resultados em quatro categorias principais: Verdadeiro Positivo (VP), Falso Positivo (FP), Verdadeiro Negativo (VN) e Falso Negativo (FN). Essas categorias permitem avaliar como o modelo classifica corretamente ou incorretamente os exemplos para cada classe, auxiliando na compreensão dos erros cometidos e na eficácia das previsões em diferentes aspectos (SURESHKUMAR *et al.*, 2024).

Tabela 5 – Estrutura da Matriz de Confusão

	Previsto Positivo	Previsto Negativo
Real Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
Real Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: O Autor

- **Verdadeiro Positivo (VP):** Indica os casos em que o modelo previu corretamente como positivos. Estes são os exemplos positivos que o modelo identificou corretamente.
- **Falso Positivo (FP):** Representa os casos em que o modelo previu um resultado positivo, mas o valor real é negativo. Em outras palavras, o modelo classificou incorretamente um caso negativo como positivo.
- **Verdadeiro Negativo (VN):** Indica os casos em que o modelo previu corretamente como negativos. Estes são os exemplos negativos que o modelo classificou corretamente.
- **Falso Negativo (FN):** Representa os casos em que o modelo previu um resultado negativo, mas o valor real é positivo. Isso ocorre quando o modelo falha em identificar um exemplo positivo.

A acurácia é uma das métricas mais intuitivas e amplamente utilizadas para medir o desempenho de um modelo de classificação. Ela representa a proporção de previsões corretas (verdadeiros positivos e verdadeiros negativos) em relação ao total de previsões feitas. A acurácia é especialmente útil quando as classes estão balanceadas, ou seja, quando as quantidades de exemplos positivos e negativos são aproximadamente iguais. No entanto, em situações onde as classes são desbalanceadas (por exemplo, quando uma classe ocorre com muito mais frequência do que a outra), a acurácia pode ser uma métrica enganosa, uma vez que o modelo pode atingir alta acurácia apenas prevendo a classe majoritária (FERRER, 2022). Por exemplo, se em um conjunto de dados 95% dos casos são da classe "negativo", um modelo que sempre prevê "negativo" alcançará 95% de acurácia, mas falhará em identificar os casos positivos, que podem ser os mais críticos. Portanto, a acurácia deve ser interpretada com cautela e em conjunto com outras métricas que ofereçam *insights* mais específicos.

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + VN + FN}$$

A precisão é uma métrica que mede a proporção de previsões positivas corretas entre todas as previsões positivas feitas pelo modelo. Em outras palavras, ela mostra quantas das amostras identificadas como "positivas" pelo modelo são realmente positivas. A precisão é uma métrica crucial quando se quer evitar falsos positivos, ou seja, prever positivo em casos que realmente não pertencem à classe positiva. Isso é especialmente relevante em contextos onde o custo de um falso positivo é alto (JUNIOR *et al.*, 2022). Por exemplo, em um sistema de monitoramento de quedas para idosos, uma previsão incorreta de uma queda (falso positivo) pode ser incômoda, gerando alertas desnecessários que causam desconforto ao usuário e reduzem a confiança no sistema. Assim, ao buscar um modelo mais confiável nas previsões positivas, a precisão torna-se uma métrica essencial, ajudando a minimizar os alarmes falsos e aumentar a eficiência do sistema.

$$\text{Precisão} = \frac{VP}{VP + FP}$$

O *recall*, também conhecido como sensibilidade, mede a capacidade do modelo de identificar corretamente todos os exemplos positivos reais. Ele calcula a proporção de verdadeiros positivos em relação ao total de casos que realmente são positivos, sendo uma métrica crucial em situações onde a falha em identificar um caso positivo pode trazer consequências graves (FEARN, 2009). Em cenários de monitoramento de saúde, como detecção de condições críticas em idosos, o *recall* é fundamental porque um falso negativo (ou seja, uma condição real que o modelo falha em detectar) pode ser muito prejudicial. Com isso, a alta sensibilidade é prioritária para assegurar que o modelo não perca nenhum caso positivo importante. No entanto, um alto *recall* muitas vezes pode vir às custas de uma maior quantidade de falsos positivos, o que torna essencial um equilíbrio entre *recall* e precisão.

$$\text{Recall} = \frac{VP}{VP + FN}$$

O *F1-score* é a média harmônica entre precisão e *recall*, oferecendo uma visão equilibrada do desempenho do modelo, especialmente útil quando há uma necessidade de equilibrar a quantidade de falsos positivos e falsos negativos. Ele é particularmente relevante em contextos onde as classes estão desbalanceadas e o objetivo é alcançar um compromisso entre precisão e *recall*. O *F1-score* proporciona uma métrica única que pondera esses dois aspectos, sendo útil para situações em que tanto a confiabilidade das previsões positivas quanto a capacidade de capturar todos os casos positivos são importantes (HAND; CHRISTEN; KIRIELLE, 2021). Esse equilíbrio é essencial, por exemplo, em sistemas de monitoramento e segurança para idosos, onde se deseja maximizar a detecção de eventos críticos (alto *recall*) sem comprometer a confiabilidade dos alertas (alta precisão). O *F1-score* é preferido em tais situações, pois oferece um único valor que considera ambas as métricas, simplificando a comparação entre modelos com diferentes perfis de erro.

$$F1\text{-Score} = \frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}$$

Os resultados da avaliação do modelo devem ser utilizados para ajustar e aprimorar o treinamento. Se o desempenho do modelo não atingir os critérios estabelecidos, pode ser necessário realizar ajustes nos dados de entrada, modificar hiperparâmetros ou até mesmo experimentar diferentes algoritmos de *machine learning*. A flexibilidade para adaptar o modelo com base na avaliação é fundamental para garantir que as soluções desenvolvidas sejam eficazes e confiáveis na promoção de ambientes seguros para os idosos.

Além disso, a avaliação deve ser um processo contínuo, uma vez que novas informações e dados podem surgir ao longo do tempo. Com isso, o modelo deve ser atualizado e re-treinado

para refletir essas mudanças, assegurando que continue a ser relevante e eficaz na identificação de riscos e na criação de ambientes mais seguros.

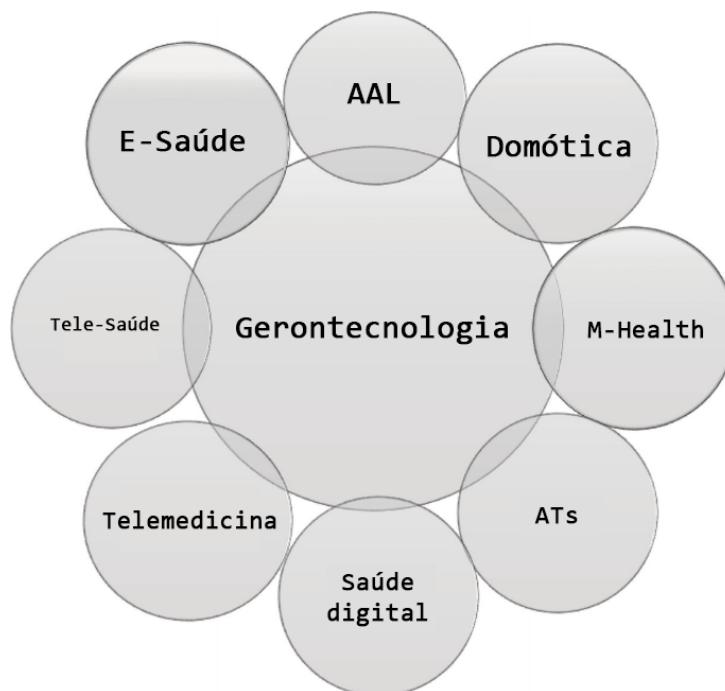
A relação entre o *machine learning* e a Gerontecnologia é estreita, pois ambas as áreas buscam desenvolver soluções inovadoras e práticas a partir do entendimento de dados e do comportamento humano. Enquanto o *machine learning* oferece ferramentas e algoritmos para analisar e interpretar grandes volumes de dados, a Gerontecnologia se beneficia diretamente dessas capacidades para criar tecnologias que atendam às necessidades da população idosa. O uso de técnicas como redes neurais e modelos explicáveis não apenas amplia a precisão e eficiência das soluções propostas, mas também garante maior confiabilidade e aceitação por parte dos usuários, um fator crítico no desenvolvimento de tecnologias assistivas voltadas para o envelhecimento saudável e autônomo.

2.4 O QUE É GERONTECNOLOGIA?

A Gerontecnologia é um campo interdisciplinar que combina os conhecimentos da gerontologia (estudo do envelhecimento) e da tecnologia, com o objetivo de desenvolver soluções inovadoras que melhorem a qualidade de vida dos idosos. Essa área busca integrar o entendimento sobre o processo de envelhecimento com a criação de produtos, serviços e sistemas que atendam às necessidades específicas dessa população, promovendo maior autonomia, saúde, interação social e bem-estar (GRAAFMANS; TAIPALE, 1998).

Ao unir saberes de engenharia, ciências sociais, medicina e outras áreas, a Gerontecnologia visa criar ambientes mais inclusivos e acessíveis, permitindo uma participação mais ativa dos idosos na sociedade (BOUMA, 1992). Além disso, suas inovações ajudam a reduzir a pressão sobre os sistemas de saúde e assistência social, ao mesmo tempo em que fornecem soluções personalizadas para as demandas individuais dessa população (CENTER, 2021). A Figura 14 apresenta as principais áreas de estudo da Gerontecnologia.

Figura 14 – Áreas de estudo da Gerontecnologia

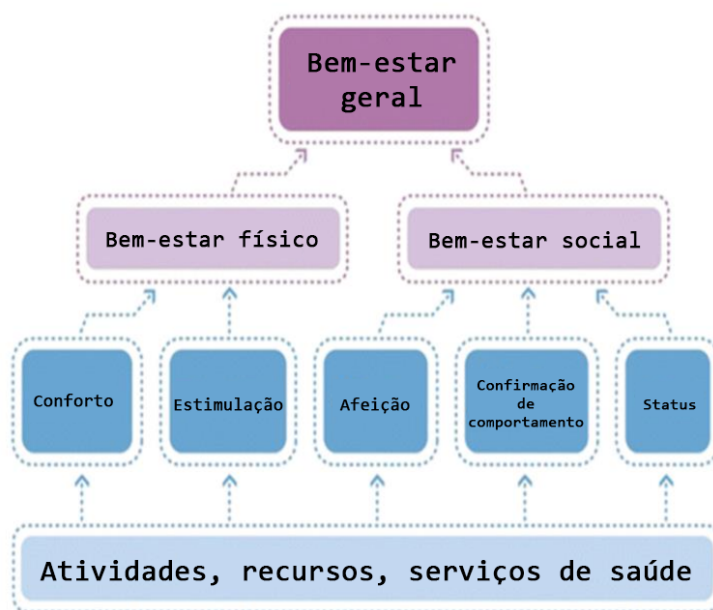


Fonte: Pilotto *et al.* (2023)

De acordo com Leung & Xu (2021), os objetivos da Gerontecnologia incluem aprimorar a qualidade de vida dos idosos por meio da integração da tecnologia. Essa área busca retardar os impactos do envelhecimento, utilizando inovações tecnológicas para prevenir ou mitigar o declínio da saúde associado à idade. Também visa combater a perda funcional, por meio de intervenções que enfrentam os desafios perceptuais e cognitivos decorrentes do envelhecimento.

Outro objetivo fundamental é tornar a tecnologia mais acessível, promovendo uma sociedade inclusiva onde tanto idosos quanto jovens possam usufruir dos avanços tecnológicos. A Gerontecnologia também oferece oportunidades para os idosos melhorarem suas habilidades de comunicação, participarem de atividades de lazer, adquirirem conhecimento e se envolverem em expressões artísticas, possibilitadas por meio de tecnologias. A Figura 15 ilustra a hierarquia do bem-estar, um conceito central nessa área.

Figura 15 – Hierarquia do bem-estar



Fonte: Cramm & Nieboer (2015)

No entanto, a Gerontecnologia enfrenta desafios significativos. A aceitação dessas tecnologias pelos idosos ainda é limitada, especialmente em função do rápido crescimento dessa população e da necessidade de compreender os fatores que influenciam essa aceitação (ATTA *et al.*, 2024). Questões éticas também emergem, como equilibrar os benefícios tecnológicos com os direitos e a dignidade dos idosos (SUNDGREN *et al.*, 2020). Além disso, cuidadores, frequentemente expostos a estresse crônico, enfrentam dificuldades na implementação dessas inovações, enquanto idosos e familiares lidam com obstáculos técnicos, preocupações com privacidade e aumento do estresse (HUANG; OTENG, 2023). Estratégias políticas amplas podem não ser suficientes para enfrentar esses desafios, demandando abordagens mais direcionadas (LEUNG; XU, 2021).

A IA tem se destacado como uma ferramenta essencial na Gerontecnologia, transformando o cuidado aos idosos. Suas aplicações incluem personalização de programas de reabilitação, monitoramento do progresso dos pacientes e antecipação de demandas específicas, resultando em atendimentos mais eficientes e personalizados (PEDERSINI; TOVANI-PALONE, 2024). Apesar dos benefícios, surgem preocupações sobre o impacto da IA no "fator humano" da medicina e da assistência à saúde, ambas profissões fortemente centradas nas interações individuais (CHEN, 2018). Assim, o uso da IA na Gerontecnologia deve buscar um equilíbrio entre inovação tecnológica e preservação da empatia e do cuidado humanizado.

2.5 TRABALHOS RELACIONADOS

A seção apresenta uma análise de trabalhos relacionados, com foco em como abordagens tecnológicas e inovadoras estão sendo aplicadas para atender às demandas específicas de uma área emergente. Essa discussão é fundamental para contextualizar o estado atual das pesquisas e identificar os avanços mais relevantes, bem como os desafios que ainda precisam ser superados. A seção também explora as diferentes perspectivas e contribuições já desenvolvidas, proporcionando uma visão abrangente do panorama atual e destacando os caminhos futuros possíveis.

2.5.1 Artigos

Para realizar a revisão sistemática deste trabalho foram pesquisados artigos científicos com um grau de reconhecimento já estabelecido na comunidade acadêmica, desta forma foi utilizado a plataforma de busca da *SciSpace* para a coleta de artigos que já se aprofundaram nesta área.

Foi utilizada a pergunta "*What are the main studies about gerontechnology (assistive technology for human aging) based on machine or deep learning?*" para a busca, também foram selecionados artigos com o ano de sua publicação entre 2021 e 2024 visando ter artigos mais recentes. Desta forma foram selecionados 6 artigos para estudo exibidos na Tabela 6. Nesta análise foi levado em consideração informações como, o tipo de algoritmo empregado em suas implementações e métricas de avaliação usadas no algoritmo.

Tabela 6 – Artigos analisados na revisão sistemática.

Referência	Objetivos	Modelos	Métodos de Avaliação
Arunachalam <i>et al.</i> (2024)	Melhorar a qualidade do atendimento prestado a idosos por meio do desenvolvimento de sistemas avançados de HRI orientados por IA.	RNN com LSTM, BERT, GPT	Precisão, Tempo de resposta, Satisfação do usuário, Relevância contextual, Nível de engajamento
Raotole <i>et al.</i> (2024)	Desenvolver uma plataforma de IA integrada que melhore a qualidade de vida de idosos que vivem de forma independente.	Modelo de pose YoLoV7, CNN, Algoritmo de Similaridade <i>Jaccard</i>	Precisão, <i>Recall</i> , <i>F1-Score</i>
Ghosh <i>et al.</i> (2024)	Desenvolver um sistema de detecção de quedas eficaz e eficiente para a população idosa.	CNN	Precisão, Análise comparativa
Deep... (2021)	Desenvolver e avaliar modelos avançados para reconhecimento de atividades humanas (HAR) e detecção de quedas, com o objetivo específico de apoiar idosos em suas vidas diárias.	CNN, ANN	Precisão, <i>F1-Score</i> , <i>Recall</i>
Gueaieb, Karray & Saddik (2023)	Desenvolver um sistema eficaz que possa monitorar as atividades de indivíduos idosos e detectar quedas usando tecnologia avançada.	CNN, LSTMs	Precisão, <i>Recall</i> , <i>F1-Score</i> , Matriz de confusão
Robinson & Nejat (2023)	Desenvolver uma estrutura de aprendizado profundo para o reconhecimento da atividade humana que possa ajudar os idosos em suas vidas diárias	Uma nova arquitetura de aprendizado profundo projetada para o reconhecimento da atividade humana.	Precisão, variância intraclasse

Fonte: O autor

O artigo de Arunachalam *et al.* (2024) explora a aplicação de IA para aprimorar o cuidado de idosos por meio de HRI. O principal objetivo é desenvolver um sistema de HRI que forneça companhia inteligente e assistência adaptativa, utilizando modelos de IA, como RNN, LSTM e modelos baseados em transformadores (*Bidirectional Encoder Representations from Transformers* (BERT) e *Generative Pre-trained Transformers* (GPT)), capazes de processar dados multimodais para respostas personalizadas. O estudo aborda desafios significativos, incluindo a necessidade de dados de alta qualidade que representem as experiências dos idosos, preocupações éticas sobre privacidade e a importância da ergonomia robótica para interações naturais. A eficácia do sistema é avaliada com métricas como precisão, tempo de resposta, satisfação do usuário, relevância contextual e nível de engajamento. Conclui-se que o uso desses sistemas pode melhorar o bem-estar e a independência dos idosos, proporcionando um cuidado individualizado e ético, com potencial para elevar a qualidade do atendimento geriátrico.

O artigo de Raotole *et al.* (2024) apresenta um sistema de IA projetado para melhorar a qualidade de vida de idosos. Inicialmente, discute os avanços do aprendizado profundo (DL) e a necessidade de uma plataforma de IA integrada para enfrentar desafios no cuidado de

idosos. O sistema *WellBe* é composto por três componentes principais: detecção de queda, que utiliza o modelo *YoLoV7 Pose* para identificar quedas em tempo real com 95,3% de precisão; reconhecimento de emoções faciais, que usa uma CNN otimizada para idosos, alcançando altas pontuações de precisão, *Recall* e *F1-Score* para emoções, como felicidade; e um *chatbot* personalizado baseado em regras e no algoritmo de similaridade *Jaccard*, que oferece assistência e companheirismo para reduzir a solidão. A integração desses componentes em uma interface de fácil uso permite uma experiência coesa para os idosos, abordando solidão, segurança e bem-estar. Em conclusão, o *WellBe* representa um avanço na tecnologia de cuidado de idosos, utilizando aprendizado profundo para criar um ambiente que promove a segurança e o bem-estar de idosos que vivem de forma independente.

O artigo de Ghosh *et al.* (2024) aborda a questão crítica das quedas entre idosos, uma das principais causas de complicações de saúde nessa faixa etária. Com o crescimento global da população idosa, cresce também a necessidade de sistemas eficazes que garantam assistência imediata e segurança. O estudo analisa métodos existentes de detecção de quedas, como sensores vestíveis, sensores montados no chão e dados de imagem de profundidade, destacando limitações relacionadas a custos e praticidade. Para superar esses desafios, os autores propõem um sistema baseado em processamento de imagem utilizando CNNs, demonstrando que o aprendizado profundo pode melhorar significativamente a precisão e a eficiência dessas soluções. O modelo proposto alcançou uma alta taxa de precisão de 97,78% na classificação de imagens relacionadas a quedas, evidenciando sua capacidade de operar em tempo real. Além disso, o sistema foi projetado para gerar alarmes automáticos que alertam cuidadores ou familiares próximos, garantindo uma resposta rápida e eficaz. O artigo destaca o potencial das CNNs na melhoria da segurança dos idosos e na otimização dos tempos de resposta, contribuindo para o avanço das soluções tecnológicas voltadas à saúde.

O artigo de Deep... (2021) foca no desenvolvimento de sistemas avançados de *Human Activity Recognition (HAR)* e detecção de quedas, com ênfase nas necessidades dos idosos. Ele ressalta a importância do HAR para monitorar funções cognitivas e físicas, ajudando na manutenção da independência, enquanto aborda o desafio crítico da detecção de quedas, propondo sistemas que aumentam a segurança e oferecem assistência oportuna. A pesquisa apresenta dois modelos principais: um sistema baseado em vídeo, que utiliza CNN para analisar *feeds* de vídeo em ambientes internos, e outro baseado em dispositivos vestíveis, que emprega sensores como acelerômetros e giroscópios para monitorar movimentos corporais. Além disso, explora o uso de ANN para aumentar a precisão e confiabilidade na detecção de quedas em tempo real. Esses modelos foram validados experimentalmente utilizando o 'conjunto de dados de detecção de quedas UR', demonstrando eficácia e robustez em termos de precisão e aplicabilidade prática. O estudo conclui que sistemas HAR baseados em aprendizado profundo podem melhorar significativamente a saúde e segurança dos idosos, oferecendo uma solução abrangente ao integrar tecnologias de vídeo e dispositivos vestíveis para monitoramento de atividades e detecção de quedas, promovendo maior independência e qualidade de vida.

O artigo Gueaieb, Karray & Saddik (2023) aborda o desafio de monitorar a saúde e a segurança da crescente população idosa, que deverá ultrapassar 1,4 bilhão até 2030. Ele destaca a necessidade de sistemas baseados em sensores capazes de reconhecer atividades humanas e detectar quedas, fornecendo alertas oportunos aos cuidadores para intervenções rápidas. Os autores propõem um modelo híbrido de aprendizado profundo que combina CNNs, para extração de características, e LSTM, para previsão e classificação de séries temporais. A solução foi testada em dois conjuntos de dados públicos, demonstrando alta precisão no reconhecimento de atividades e na detecção de quedas, superando outros estudos na área. Os resultados indicam que o modelo é uma ferramenta confiável para monitoramento de idosos, melhorando os resultados de recuperação e reabilitação por meio de notificações imediatas. Em suma, o estudo apresenta uma abordagem promissora ao integrar as capacidades espaciais das CNNs e temporais das LSTMs, promovendo avanços significativos no cuidado de idosos.

O artigo de Robinson & Nejat (2023) apresenta uma nova estrutura de aprendizado profundo voltada para aumentar a independência de idosos, reconhecendo e classificando atividades da vida diária em ambientes domésticos, com o objetivo de apoiar o envelhecimento no local por meio de robôs de assistência social. A arquitetura proposta é inovadora ao utilizar entradas multimodais para criar uma abordagem vetorial de incorporação, integrando características geométricas, de movimento e semânticas de usuários, ambientes e objetos. A fusão intermediária espacial (*Spatial Mid-Fusion*) é empregada para combinar eficientemente essas características, aumentando a precisão no reconhecimento de atividades, especialmente em ambientes domésticos complexos. Além disso, a estrutura utiliza aprendizagem por transferência para melhorar a adaptabilidade, extraindo recursos genéricos de camadas iniciais de redes profundas treinadas em grandes conjuntos de dados, permitindo a classificação de atividades da vida diária não vistas durante o treinamento. Os resultados experimentais indicam que a arquitetura proposta supera modelos unimodais e dual-modais em precisão de classificação, além de demonstrar eficácia na identificação de atividades da vida diária invisíveis e no rastreamento do desempenho dos usuários. Em suma, o estudo oferece uma solução sofisticada para promover a independência e o bem-estar de idosos em seus lares por meio de tecnologias avançadas de aprendizado profundo.

2.5.2 Robótica

A Toyota (2012) desenvolveu o protótipo do *Human Support Robot* (HSR) com o intuito de solucionar o problema de demanda de cuidados à longo prazo para os idosos e promover a autonomia em casa para indivíduos com mobilidade restrita nos braços ou nas pernas. Ele foi criado para aprimorar a qualidade de vida dos indivíduos em suas residências, hospitais e em instituições especializadas em cuidados pessoais. Além de que ele pode ser adaptado e programado para várias finalidades, incluindo assistência domiciliar e suporte em situações de emergência.

O HSR se utiliza de sensores e IA para se locomover de maneira independente e interagir com humanos de maneira segura, podendo ser controlado de forma remota, por comandos de voz ou um *tablet*, ou operando de forma autônoma. Ele também pode ser incorporado a outros aparelhos inteligentes em uma residência automatizada, simplificando a gestão dos aparelhos ligados. A Figura 16 mostra o robô HSR.

Figura 16 – Robô HSR



Fonte: (TOYOTA, 2012)

Ele possui um braço robótico flexível, que lhe permite pegar objetos, abrir portas, manusear aparelhos e se locomover de forma independente em ambientes complexos, graças aos sensores e câmeras incorporados. Além disso, o robô possui uma interface para comunicação entre humano e máquina, possibilitando interações naturais entre o usuário e o autômato. Isso pode ser realizado através de voz, comandos táteis e até mesmo aplicativos para dispositivos móveis. A Figura 17 mostra o robô HSR auxiliando uma pessoa.

Figura 17 – HSR auxiliando com a entrega de uma garrafa




Fonte: (TOYOTA, 2012)

O HSR vem sendo empregado em universidades e laboratórios para criar novas aplicações de IA e robótica, com o objetivo de melhorar o suporte à mobilidade e a interação com humanos. Ele também é utilizado dentro de múltiplas instalações da Toyota além de ter sido usado como um robô de entrega nos Jogos Olímpicos e Paralímpicos de Tóquio 2020.

O *Robear* é um robô criado para auxiliar na assistência a idosos no Japão, devido ao envelhecimento da população e à falta de cuidadores qualificados. Ele foi desenvolvido pelo Centro de Colaboração *RIKEN-SRK*, em colaboração com a *Sumitomo Riko Company*, e integra uma série de robôs de assistência corporal iniciada com o *RIBA*, apresentado em 2009. *Robear* foi desenvolvido para executar atividades como levantar pacientes da cama e transferi-los para cadeiras de rodas, auxiliando-os também a sentar e levantar de maneira suave e segura. A Figura 18 mostra ele em funcionamento.

Figura 18 – Robô *Robear* em funcionamento



Fonte: <https://g1.globo.com/ciencia-e-saude/noticia/2015/02/japao-desenvolve-robo-capaz-de-erguer-idosos-de-cadeira-de-rodas.html>

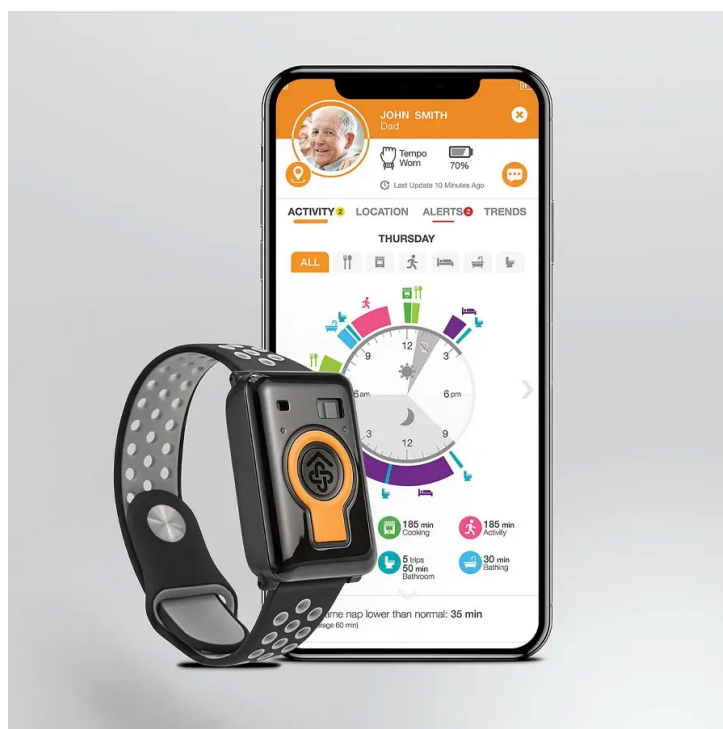
Com seus braços capazes de erguer até 80 kg, emprega sensores de toque sofisticados, como os sensores capacitivos de borracha inteligente, que possibilitam movimentos precisos e suaves. Os atuadores oferecem alta resposta nas articulações, e as pernas flexíveis auxiliam na estabilização ao levantar pacientes ou ao transitar por espaços limitados, como portas.

Ele foi projetado para ser acolhedor e não intimidador, apresentando um visual de urso de pelúcia, evitando a imagem de uma máquina fria e mecânica. A sua aparência foi projetada para oferecer conforto visual, particularmente em espaços destinados à saúde.

Desenvolvido pela CarePredict (2024), a *CarePredict* Tempo é um dispositivo que rastreia diversas facetas das atividades de uma pessoa, tais como andar, sentar, se alimentar e dormir. Ela tem sensores que monitoram movimentos, localização e ambiente para reunir informações minuciosas sobre o dia a dia do usuário.

A *CarePredict* envia os dados da Tempo para o seu sistema de IA, que emprega algoritmos de aprendizado de máquina para definir padrões nas atividades cotidianas do indivíduo. Ao acompanhar constantemente esses padrões, o sistema é capaz de identificar desvios que podem indicar potenciais problemas de saúde, tais como alterações nos costumes alimentares ou de sono, aumento do tempo passado sentado ou diminuição das atividades físicas, alterações nas interações sociais. A Figura 19 mostra a pulseira.

Figura 19 – Pulseira *Carepredict*



Fonte: <https://www.carepredict.com/product/the-carepredict-home-kit-new/>

O sistema *CarePredict* é capaz de identificar sinais iniciais de problemas de saúde, tais como:

- **Risco de queda:** Alterações repentinas na direção ou mobilidade limitada.
- **Redução cognitiva:** Redução da interação social ou alterações no comportamento.

Ao detectar esses indícios sutis de forma precoce, o sistema pode notificar cuidadores ou parentes, possibilitando uma ação rápida para prevenir um declínio mais severo ou incidentes.

Os cuidadores e parentes têm acesso a um painel de controle ou a um aplicativo, onde recebem atualizações em tempo real e dados sobre a condição de saúde do idoso. Isso possibilita que os cuidadores monitorem alterações nas tarefas cotidianas, recebam notificações quando algo atípico for identificado e adotem ações baseadas em padrões ou tendências específicas no comportamento do idoso.

Os principais benefícios incluem: Intervenção antecipada para detectar problemas de saúde antes que se agravem, aprimoramento na qualidade do cuidado, os cuidadores podem se concentrar nas pessoas que precisam de atenção imediata, e Tranquilidade para as famílias, que podem acompanhar o bem-estar de seus entes queridos em tempo real, mesmo à distância.

A *CarePredict* é frequentemente empregada em comunidades de assistência a idosos e em serviços de assistência domiciliar. Ela auxilia as instituições de assistência a aprimorar o

serviço, identificando quando e onde os residentes necessitam de mais suporte, além de auxiliar os familiares que desejam acompanhar seus entes queridos de longe.

A *Gyenno Bravo Twist*, desenvolvida pela GYENNO Technologies (2024), é um aparelho desenvolvido para auxiliar indivíduos com tremores nas mãos, particularmente aqueles afetados por doenças como Parkinson, a se alimentarem de maneira autônoma e com mais facilidade. Ela emprega uma mescla de sensores e motores estabilizadores que identificam e anulam os movimentos involuntários, assegurando que o alimento se mantenha na colher durante o procedimento de alimentação.

O sistema da *Gyenno Bravo Twist* possui sensores que rastreiam em tempo real os movimentos da mão do utilizador. Ajustando automaticamente o movimento da colher com base nas leituras dos sensores, pequenos motores internos compensam as vibrações e diminuem o derramamento de alimentos. O objetivo é proporcionar uma experiência de alimentação mais estável e tranquila, devolvendo maior autonomia ao usuário.

O dispositivo, além de simplificar a alimentação, também recolhe informações acerca da frequência e da severidade dos tremores. Esses dados são guardados e podem ser examinados para oferecer percepções sobre o avanço dos tremores ao longo do tempo. Esta funcionalidade possibilita que cuidadores e médicos monitorem de maneira mais minuciosa a progressão do estado do paciente e modifiquem o tratamento quando necessário. A Figura 20 mostra a Bravo Series.

Figura 20 – *Gyenno Bravo Seires*



Fonte: <https://balancemobility.com.au/product/gyenno-bravo-twist/>

Os principais benefícios da *Gyenno Spoon* incluem:

- Estabilização automática dos tremores, permitindo uma alimentação mais controlada.
- Aumento da autonomia, possibilitando que o usuário se alimente sozinho, sem depender de assistência constante.
- Monitoramento dos tremores, fornecendo informações valiosas para médicos e cuidadores.
- Melhoria na qualidade de vida, reduzindo o estresse e a frustração durante as refeições.

A *Gyenno Bravo Twist* é amplamente utilizada tanto por indivíduos em casa quanto em instituições de assistência, como lares para idosos e clínicas especializadas no cuidado de pacientes com Parkinson. O aparelho oferece uma solução prática e eficiente para os obstáculos que as pessoas que sofrem de tremores enfrentam, garantindo uma vida mais autônoma e confortável.

2.5.3 Aplicativos

O MyndYou (2024) é uma plataforma que emprega IA para acompanhar a saúde mental dos idosos de forma não invasiva, concentrando-se principalmente na detecção de indícios de declínio cognitivo. Ele examina as interações verbais dos usuários durante chamadas telefônicas frequentes, juntamente com seus comportamentos cotidianos, com o objetivo de detectar alterações discretas que possam sinalizar questões como perda de memória ou redução na habilidade de raciocínio.

O sistema da *MyndYou* emprega algoritmos de IA para examinar o discurso do usuário, procurando mudanças no tom, ritmo e conteúdo das conversas, que podem indicar mudanças cognitivas. Ademais, ele acompanha a regularidade das interações sociais e os padrões de tarefas cotidianas. Quando identifica alterações nesses padrões, como uma redução na comunicação ou alterações no comportamento habitual, o aplicativo emite alertas para cuidadores ou profissionais de saúde, possibilitando uma ação antecipada.

Os cuidadores têm acesso a um painel de controle que disponibiliza informações precisas sobre a saúde cognitiva do idoso, possibilitando um monitoramento constante e a elaboração de um plano de assistência personalizado. A meta é manter os idosos mentalmente ativos e autônomos, ao mesmo tempo que oferece aos cuidadores uma perspectiva mais nítida sobre a saúde cognitiva de seus familiares.

Os principais benefícios incluem:

- **Monitoramento não invasivo:** A análise é feita de maneira passiva, sem interromper a rotina do idoso.

- **Detecção precoce de declínios cognitivos:** A IA identifica mudanças sutis que poderiam passar despercebidas em interações comuns.
- **Alertas para cuidadores:** Proporciona uma oportunidade para intervenções mais rápidas, evitando o agravamento de problemas de saúde.
- **Maior independência para o idoso:** O sistema ajuda a prolongar a autonomia dos usuários, enquanto monitora sua saúde de forma discreta.

A *MyndYou* é frequentemente empregada em cenários de assistência domiciliar e por instituições de saúde para acompanhar de maneira proativa a saúde mental dos idosos, proporcionando uma abordagem inovadora para auxiliar a população idosa através da IA.

A *Memora Health* (HEALTH, 2024) é uma plataforma digital que emprega IA para auxiliar na administração da saúde de pacientes, com foco especial em idosos com doenças crônicas. Ela automatiza a supervisão do tratamento, verificando a observância das orientações médicas e a adesão aos tratamentos. Por meio de mensagens de texto, ligações automatizadas e interações com IA, a plataforma fornece lembretes para que os usuários tomem seus medicamentos, anotem seus sintomas e compareçam a consultas médicas, assegurando que cumpram as orientações médicas.

A *Memora Health* recolhe e examina informações de saúde em tempo real, proporcionando aos profissionais de saúde e médicos um acompanhamento constante do avanço dos pacientes. A IA da plataforma é programada para reconhecer padrões nos sintomas descritos e no comportamento dos pacientes, tais como esquecimentos ou possíveis problemas de saúde, possibilitando intervenções ágeis quando necessário. Ao detectar padrões, o sistema dispara notificações para a equipe médica ou para os pacientes, propondo modificações no tratamento.

Os profissionais de saúde dispõem de um painel de controle que apresenta informações pormenorizadas sobre os pacientes, facilitando a tomada de decisões conscientes e a customização dos planos terapêuticos. Ademais, o sistema contribui para diminuir a sobrecarga dos cuidadores e das equipes médicas, automatizando a supervisão e as interações diárias.

Os benefícios principais englobam:

- **Aumento na adesão ao tratamento:** Os lembretes automatizados ajudam os pacientes a seguirem suas prescrições com maior rigor.
- **Monitoramento remoto em tempo real:** A IA analisa sintomas e comportamentos para detectar problemas emergentes de saúde.
- **Redução da carga de trabalho:** Automatiza tarefas repetitivas, permitindo que os cuidadores e médicos se concentrem em situações mais críticas.

- **Intervenção precoce:** Ao identificar padrões ou sintomas de risco, a plataforma permite uma ação rápida para evitar complicações graves.

A *Memora Health* é frequentemente empregada em cenários de assistência domiciliar, em clínicas e hospitais que tratam pacientes com enfermidades crônicas, oferecendo uma estratégia eficaz e inteligente para a administração da saúde dos idosos.

2.5.4 Considerações Finais

Ao longo da análise, foi possível compreender como a IA aplicada à Gerontecnologia tem o potencial de transformar o cuidado e a segurança de populações idosas. As técnicas de *machine learning*, como redes neurais artificiais e árvores de decisão, desempenham papéis complementares no processamento de dados provenientes de dispositivos de monitoramento. Enquanto as Árvores de Decisão oferecem clareza e explicabilidade, essenciais em contextos que demandam transparência, as Redes Neurais se destacam pela precisão ao capturar relações complexas entre variáveis, mesmo apresentando desafios na sua interpretação.

A escolha das ferramentas e modelos utilizados não depende apenas de seus méritos técnicos, mas também de sua aceitação e aplicabilidade pelos usuários finais. Para soluções voltadas ao cuidado de idosos, a usabilidade e a transparência são tão importantes quanto a precisão técnica. Estudos relacionados e exemplos práticos reforçam a necessidade de criar sistemas que sejam simultaneamente eficientes e acessíveis, considerando as especificidades da população-alvo e seus cuidadores.

Outro ponto importante foi a percepção de que a integração de diferentes técnicas pode amplificar os resultados. Combinar modelos explicáveis com modelos de maior complexidade resulta em sistemas mais robustos, capazes de aliar desempenho técnico à interpretabilidade. Além disso, foi reforçada a relevância de abordar questões éticas como privacidade e acessibilidade, especialmente em soluções que envolvem a coleta de dados sensíveis de idosos.

Esses aprendizados reforçam que a aplicação da IA à Gerontecnologia não apenas possibilita avanços significativos no cuidado e monitoramento, mas também promove uma abordagem mais integrada e ativa para lidar com os desafios do envelhecimento. A experiência adquirida servirá de base para o desenvolvimento de soluções futuras, equilibrando alto desempenho com aplicabilidade prática, buscando sempre o maior impacto positivo na vida dos idosos.

3 MÉTODO DE PESQUISA

O envelhecimento da população mundial apresenta desafios significativos na saúde e no bem-estar dos idosos, tornando essencial o desenvolvimento de tecnologias que promovam a autonomia e a qualidade de vida. A Gerontecnologia, que integra conhecimentos de gerontologia, engenharia e ciências sociais, busca criar soluções adaptadas às necessidades dessa faixa etária. Nesse contexto, a aplicação de IA se destaca como uma abordagem inovadora, permitindo a personalização dos cuidados e a intervenção precoce em situações de risco por meio de sistemas que monitoram e analisam dados de saúde.

Este capítulo apresenta o método de pesquisa estruturado para garantir a implementação de um modelo de IA para a área da Gerontecnologia. Neste contexto, tem-se por objetivo desenvolver e avaliar algoritmos capazes de identificar riscos de quedas em ambientes domésticos de idosos. A proposta busca investigar como técnicas de *machine learning*, em especial Árvores de Decisão e Redes Neurais Artificiais. Este trabalho seguirá as etapas do processo de *machine learning*, proposto por Fayyad, Piatetsky-Shapiro & Smyth (1996), descritas anteriormente. As etapas previstas são as seguintes: coleta de dados, preparação dos dados, escolha do método, treinamento do modelo, bem como a avaliação do modelo. Nas seções seguintes, apresenta-se o planejamento destas etapas.

3.1 COLETA DE DADOS

Para a realização deste trabalho serão utilizados dados coletados em projetos na área da avaliação de moradias, realizado por pesquisadores da Universidade Estadual de Santa Catarina. Os dados foram obtidos pela aplicação de um questionário de avaliação ergonômica da moradia do idoso, dividido em três partes: a) ficha cadastral, b) ferramenta para avaliação da residência e, c) questionário da percepção do idoso sobre a interação com o ambiente doméstico. O questionário está detalhado no Anexo A.

O questionário foi aplicado para setenta idosos de forma presencial, permitindo a coleta de dados essenciais. Os dados permitem analisar fatores de risco, segurança e condições do ambiente doméstico dessa população, com o objetivo de adaptar suas residências para promover maior segurança e bem-estar. A primeira parte, a ficha cadastral, foi feita abrangendo quatro áreas principais: dados sociodemográficos, aspectos clínicos e hábitos de vida, dados da habitação e inventário de quedas.

A área de dados sociodemográficos visa caracterizar o perfil básico dos participantes, abrangendo aspectos como idade, sexo, estado civil, escolaridade e renda. Esses dados permitem a criação de um perfil sociodemográfico detalhado, que contextualiza a amostra estudada e facilita a interpretação dos resultados coletados. Essa análise é essencial para avaliar o impacto

das variáveis sociais e econômicas nas condições de vida dos idosos e na adequação do ambiente residencial às suas necessidades.

Alguns exemplos de perguntas da referida área são os seguintes:

- Sexo: "() 1. Feminino () 2. Masculino".
- Grau de escolaridade: "() 1. Analfabeto () 2. Fundamental incompleto () 3. Fundamental completo () 4. Médio incompleto () 5. Médio completo () 6. Superior incompleto () 7. Superior completo".
- Nível de renda familiar: "() 1. Até 2 salários mínimos () 2. De 2 a 10 salários mínimos () 3. Acima de 10 salários mínimos".

A parte de aspectos clínicos e hábitos de vida foi desenvolvida para investigar o estado de saúde dos idosos, incluindo condições médicas, uso de medicações, hábitos de sono e prática de atividades físicas. Essa coleta de informações é essencial para identificar fatores que podem impactar a mobilidade, independência e qualidade de vida dos respondentes. Nesta perspectiva, considera-se que tais variáveis influenciam diretamente na segurança e no conforto dentro do ambiente domiciliar.

Alguns exemplos de perguntas da segunda área são os seguintes:

- Problemas de sono: "() 1. Demora para iniciar o sono () 2. Dificuldades em manter o sono durante a noite (insônia) () 3. Hipersônia (sono excessivo durante o dia) () 4. Narcolepsia (fraqueza muscular súbita, alucinações, pesadelos) () 5. Não tem problemas para dormir, sono de boa qualidade".
- Prática de atividade física: "() Não pratica () Caminhadas leves () Esportes e atividades físicas moderadas () Esportes ou trabalhos físicos que exigem força e energia vigorosos, como jardinagem, carregar peso".
- Toma medicamentos atualmente?: "() 1. Não () 2. Sim".

A área de dados da habitação avalia as características físicas das residências dos idosos, abordando aspectos como: tipo de moradia, número de pavimentos, quantidade de cômodos e acessibilidade. A análise dessas informações permite identificar barreiras arquitetônicas que possam comprometer a acessibilidade e a segurança dos idosos em suas residências. Dessa forma, torna-se possível compreender se o ambiente doméstico oferece condições adequadas às necessidades da população idosa.

Alguns exemplos de perguntas da referida área são os seguintes::

- A residência é: "() 1. Própria () 2. Alugada () 3. Emprestada".

- Número de pavimentos da residência: " ____ pavimentos".
- Acesso ao quarto de dormir: "() Rampa () Escada () Não necessita, é no piso térreo e de fácil acesso".

A parte sobre inventário de quedas busca registrar o histórico de quedas dos respondentes, com informações sobre a frequência, locais e causas dessas ocorrências. Esse levantamento é fundamental para identificar áreas de risco no ambiente doméstico, assim como os principais fatores que levam a esses incidentes, com o objetivo de promover intervenções preventivas.

Alguns exemplos de perguntas da referida área são os seguintes:

- Nos últimos 12 meses, o(a) Sr(a) caiu alguma vez em sua casa?: "() 1. Não () 2. Sim. Se Sim, quantas vezes? Onde? _____".
- Motivo da queda: "() 1. Falta de atenção () 2. Dor () 3. Fraqueza nas pernas () 4. Mal-estar súbito () 5. Piso escorregadio () 6. Tropeçou em degrau ou soleira () 7. Obstáculos no piso () 8. Tropeçou em tapete () 9. Tropeçou em animais () 10. Outros: _____".
- Você se sente seguro na sua casa (em relação a riscos e acidentes)? () 1. Não () 2. Sim.

A ferramenta para avaliação da residência complementa a coleta de dados. Ela se concentra em aspectos específicos da estrutura física e das condições de acessibilidade e segurança da residência. Essa ferramenta avalia elementos, tais como soleiras, escadas, portas, janelas e iluminação noturna, com o objetivo de identificar possíveis riscos físicos e barreiras que possam prejudicar a mobilidade dos idosos. Esses dados são essenciais para determinar a adequação do ambiente às necessidades dos idosos e propor melhorias estruturais quando necessário.

Alguns exemplos de perguntas sobre a avaliação das residências são os seguintes:

- Soleiras: "As soleiras das portas apresentam desníveis inferiores a 2,5 cm para evitar tropeços?".
- Corrimãos nas escadas: "As escadas possuem corrimãos seguros em ambos os lados, conforme as normas NBR 9050 e NBR 9077?".
- Iluminação noturna: "Existe luz noturna em todos os trajetos entre o quarto do idoso e o banheiro?".

Por fim, o questionário da percepção do idoso sobre a interação com o ambiente doméstico foi elaborado para captar a percepção dos idosos sobre a interação com o seu ambiente doméstico, explorando os facilitadores e as barreiras percebidas em suas atividades diárias. Questões relacionadas ao conforto, segurança e acessibilidade percebida, além de aspectos emocionais e de independência, são abordadas nessa seção. Essas informações ajudam a entender

como os idosos percebem seu espaço e quais ajustes poderiam ser feitos para tornar o ambiente mais seguro e acolhedor.

Alguns exemplos de perguntas sobre a percepção do idoso são os seguintes::

- Deslocamento: "Subir ou descer uma escada (pode ser interna, entre os andares da casa, ou externa, mas deve ter no mínimo 5 degraus) podendo segurar no corrimão. () Totalmente Incapaz () Com muita dificuldade () Com dificuldade () Com pouca dificuldade () Totalmente capaz"
- Atividades gerais: "Fazer trabalhos manuais domésticos ou pequenos reparos (Ex.: lavar louças, regar plantas, trocar uma lâmpada). () Totalmente Incapaz () Com muita dificuldade () Com dificuldade () Com pouca dificuldade () Totalmente capaz"

Todos os dados descritos são necessários para que ocorra uma análise da percepção dos idosos sobre a interação com o ambiente doméstico. Eles abrangem diversas dimensões, tais como: capacidade de locomoção, acessibilidade dos espaços e interação com diferentes elementos do lar. Por meio destes dados buscou-se obter subsídios para realizar uma análise detalhada das necessidades e preferências dos idosos, o que é vital para a seleção do modelo mais adequado.

3.2 PREPARAÇÃO DOS DADOS

Após a coleta, os dados devem ser analisados e submetidos a procedimentos de preparação envolvendo limpeza, análise exploratória e transformação. Essa preparação visa assegurar a consistência e a confiabilidade do conjunto de informações, possibilitando que os modelos operem em condições adequadas de aprendizado. Além disso, a etapa de pré-processamento garante que possíveis limitações da base, como valores ausentes ou escalas heterogêneas entre variáveis, não comprometam a construção dos modelos. Dessa forma, busca-se reduzir vieses e ruídos que poderiam afetar diretamente a qualidade dos resultados.

A análise exploratória desempenha um papel complementar, permitindo identificar padrões e tendências iniciais que podem orientar ajustes posteriores. Essa etapa também possibilita uma avaliação preliminar sobre a adequação das variáveis ao problema estudado, apontando a necessidade de transformações adicionais. A utilização dessa abordagem fortalece a compreensão do conjunto de dados, contribuindo para decisões mais fundamentadas durante a fase de modelagem.

Após, os dados devem ser divididos em subconjuntos de treinamento e teste. Neste estudo, foram adotadas duas estratégias: a técnica *hold-out* (80–20) e a validação cruzada com cinco partições. A primeira oferece uma avaliação inicial do desempenho, enquanto a segunda contribui para reduzir a variabilidade associada a uma única divisão, fornecendo estimativas

mais robustas da capacidade de generalização. Essa combinação é especialmente importante no presente trabalho, considerando o tamanho limitado da base de dados e a relevância de se obter métricas confiáveis para comparação entre diferentes modelos.

A aplicação da validação cruzada com múltiplas partições torna-se ainda mais relevante por permitir o aproveitamento de todos os dados disponíveis em diferentes iterações. Isso é particularmente vantajoso em contextos com amostras reduzidas, como ocorre neste estudo, pois maximiza a utilização dos dados tanto para treinamento quanto para teste. Ao adotar esse procedimento, espera-se mitigar a influência de divisões específicas e obter uma visão mais estável e realista do desempenho dos classificadores.

3.3 ESCOLHA DOS MÉTODOS DE *MACHINE LEARNING*

Os métodos de *machine learning* têm fundamentos matemáticos distintos, que podem ser mais ou menos eficazes, dependendo da natureza dos dados e dos objetivos do projeto. Normalmente, modelos de classificação, como árvores de decisão, ou de regressão logística, podem ser particularmente úteis para classificar ou prever valores.

Além disso, a complexidade do modelo deve ser considerada em relação à quantidade e qualidade dos dados disponíveis. Modelos mais simples podem ser suficientes para fornecer *insights* práticos e podem facilitar a interpretação das recomendações para o design seguro dos cômodos. Ao mesmo tempo, a escolha do modelo deve garantir que as previsões sejam precisas e aplicáveis às condições reais dos lares dos idosos.

A escolha dos métodos para este estudo consideraram tanto a necessidade de interpretabilidade dos resultados quanto a acurácia desejada para a previsão de padrões de risco e segurança no ambiente doméstico dos idosos. Portanto, serão utilizados dois métodos principais: Árvores de Decisão e Redes Neurais. Cada um desses métodos tem base matemática distinta (raciocínio simbólico versus conexionista), oferecendo portanto, condições diversificadas para realizar-se testes.

As Árvores de Decisão foram selecionadas devido à sua estrutura altamente interpretável e explicável, que é fácil de entender e visualizar. Elas consistem em uma série de decisões sequenciais organizadas em uma estrutura de árvore, onde cada nó representará uma condição (ou regra) aplicada aos dados, e os ramos representarão os resultados dessa condição. A partir dessa estrutura, o modelo pode classificar ou prever um resultado com base nas decisões aplicadas a cada entrada de dados.

Uma das principais vantagens das Árvores de Decisão está na sua capacidade de fornecer explicabilidade. Como cada decisão na árvore corresponderá a uma regra aplicada ao conjunto de dados, é possível para um ser humano seguir o caminho de cada decisão e entender o motivo pelo qual o modelo chegou a determinado resultado. Isso torna as Árvores de Decisão particularmente úteis em contextos onde a compreensão dos critérios de classificação ou previ-

são é crucial, como neste estudo, que visa avaliar os fatores de risco de acidentes no ambiente doméstico.

No entanto, as Árvores de Decisão tendem a apresentar uma baixa acurácia em comparação com outros métodos mais complexos, especialmente quando se trata de conjuntos de dados grandes ou com variáveis complexas. A estrutura simples das árvores pode tornar o modelo propenso ao *overfitting* (ajuste excessivo aos dados de treinamento), o que prejudicará sua capacidade de generalização. Por isso, embora sejam altamente compreensíveis, as Árvores de Decisão poderão ser limitadas em termos de precisão preditiva quando comparadas a modelos mais avançados.

As Redes Neurais também serão empregadas como método, devido à sua eficácia em capturar relações complexas nos dados, geralmente resultando em alta acurácia nas previsões. Compostas por múltiplas camadas de neurônios artificiais interconectados, as Redes Neurais funcionarão de maneira semelhante ao cérebro humano, utilizando camadas de entrada, ocultas e de saída para identificar padrões intrincados nos dados.

A estrutura das Redes Neurais permitiu que o modelo aprenda representações abstratas dos dados à medida que avança pelas camadas ocultas, o que será vantajoso para maximizar a precisão dos modelos, especialmente em problemas complexos com grande volume de dados. No entanto, um ponto crítico das Redes Neurais será sua natureza de "caixa preta", o que significa que, embora o modelo forneça previsões precisas, o processo interno de tomada de decisão será difícil de interpretar. Ao contrário das Árvores de Decisão, onde cada passo do processo é explícito, as Redes Neurais envolverão um conjunto de operações complexas, tornando difícil rastrear a contribuição de cada variável para a previsão final. Essa falta de transparência poderá ser uma limitação em cenários onde a compreensão do modelo é essencial para validar os resultados, especialmente em estudos voltados à segurança e ao bem-estar.

A escolha entre Árvores de Decisão e Redes Neurais neste estudo foi guiada pela necessidade de equilíbrio entre explicabilidade e acurácia. As Árvores de Decisão foram escolhidas pelo seu valor explicativo, permitindo interpretar claramente os fatores de risco identificados e comunicar os resultados de forma direta. Já as Redes Neurais foram selecionadas para obter um modelo complementar com alta acurácia, possibilitando captar padrões complexos nos dados que poderiam ser perdidos com o modelo de Árvore de Decisão. Dessa forma, o estudo buscou tanto a transparência quanto a precisão preditiva, considerando a aplicação de ambos os métodos na análise dos dados.

3.4 TREINAMENTO DOS MODELOS

O treinamento do modelo é uma etapa crucial no desenvolvimento de sistemas de IA, especialmente quando se busca criar ambientes domésticos mais seguros para idosos. Esta fase utiliza os dados coletados através do questionário para ensinar o modelo a identificar padrões e

relações que possam indicar condições de risco e potencial para acidentes nos cômodos.

Durante o treinamento, o modelo aplica algoritmos de *machine learning* para ajustar seus parâmetros internos, buscando minimizar a diferença entre suas previsões e os resultados reais. Funções de perda são utilizadas para quantificar o erro do modelo, e técnicas de otimização, como o gradiente descendente, são empregadas para ajustar os pesos do modelo de forma iterativa. A escolha do algoritmo é crítica e deve ser baseada nos objetivos do projeto e na natureza dos dados.

A validação do modelo deve ocorrer de forma contínua durante o treinamento. Técnicas como validação cruzada podem ser implementadas para avaliar o desempenho do modelo em diferentes subconjuntos de dados, ajudando a evitar problemas como o *overfitting*, onde o modelo se ajusta excessivamente aos dados de treinamento e falha em generalizar para novos dados.

O *Scikit-Learn* é uma biblioteca amplamente utilizada em projetos de *machine learning*, oferecendo ferramentas robustas e eficientes para lidar com diversas tarefas, como classificação, regressão, agrupamento e redução de dimensionalidade. Sua integração com bibliotecas fundamentais como *NumPy*, *SciPy* e *Matplotlib* garante alto desempenho computacional, enquanto sua interface amigável facilita o uso por desenvolvedores e pesquisadores, independentemente do nível de experiência. Além de incluir uma ampla gama de algoritmos, o *Scikit-Learn* também fornece ferramentas para pré-processamento de dados, avaliação de modelos e criação de pipelines automatizados, permitindo fluxos de trabalho mais ágeis e consistentes. Dentre os componentes disponíveis, destacam-se classes e funções como *DecisionTreeClassifier*, *MLPClassifier*, *confusion_matrix* e *classification_report*, que oferecem soluções específicas para diferentes etapas do *machine learning*. Cada um desses elementos contribui de maneira única para a construção, validação e análise de modelos preditivos, proporcionando flexibilidade e precisão em projetos de análise de dados.

O *DecisionTreeClassifier* é uma classe projetada para resolver problemas de classificação por meio de árvores de decisão. Esse método baseia-se na divisão recursiva dos dados em subconjuntos menores, utilizando critérios como o índice de *Gini* ou o ganho de informação para determinar as divisões. A estrutura resultante é uma árvore hierárquica, onde cada nó representa uma decisão baseada em um atributo, e as folhas correspondem às classes previstas. As árvores de decisão são populares devido à sua simplicidade e interpretabilidade, permitindo que até mesmo usuários leigos compreendam como as decisões foram tomadas. Além disso, ele oferece recursos avançados, como controle da profundidade máxima da árvore e do número mínimo de amostras para divisão de um nó, ajudando a evitar problemas como o sobreajuste. Essa classe também calcula automaticamente a importância de cada variável, o que é útil para entender os fatores que mais influenciam as previsões. Por sua versatilidade, ele é frequentemente usado em uma ampla gama de aplicações.

O *MLPClassifier* é uma implementação de redes neurais artificiais no *Scikit-Learn*, ba-

seada no modelo *Multilayer Perceptron* (MLP). Ele utiliza a retropropagação para ajustar os pesos das conexões neuronais e resolver problemas de classificação complexos que exigem a identificação de padrões não lineares nos dados. Ele permite a configuração da arquitetura da rede, definindo o número de camadas ocultas e a quantidade de neurônios em cada camada. Além disso, oferece diversas funções de ativação, como *ReLU*, sigmoide e tangente hiperbólica, que introduzem não linearidade no modelo. Os algoritmos de otimização disponíveis, como *Adam* e *SGD*, garantem eficiência no treinamento, mesmo para redes profundas. O *MLPClassifier* é amplamente utilizado em tarefas como reconhecimento de imagens, análise de sentimentos e previsão de séries temporais, destacando-se pela sua flexibilidade e capacidade de modelar relações complexas nos dados.

A função *confusion_matrix* é uma ferramenta fundamental para avaliar o desempenho de modelos de classificação. Ela gera uma matriz que compara os valores reais com as previsões feitas pelo modelo, indicando o número de verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos. Essa análise detalhada ajuda a identificar os padrões de erro do modelo, permitindo ajustes para melhorar sua performance. A matriz de confusão é particularmente útil em situações de dados desbalanceados, pois fornece *insights* mais detalhados do que métricas simples como a precisão. Além disso, sua representação visual por meio de mapas de calor facilita a compreensão e comunicação dos resultados, sendo amplamente empregada em áreas como detecção de fraudes, diagnóstico médico e sistemas de recomendação.

A função *classification_report* complementa a matriz de confusão, fornecendo um resumo detalhado das métricas de avaliação de um modelo de classificação. O relatório inclui métricas como precisão, *recall* e *F1-score* para cada classe, além de apresentar o suporte, que é o número de instâncias reais em cada classe. Essas métricas ajudam a avaliar a capacidade do modelo de identificar corretamente as classes, especialmente em problemas de dados desbalanceados. A precisão indica a proporção de previsões corretas em relação ao total de previsões, enquanto o *recall* mede a proporção de instâncias positivas identificadas corretamente. O *F1-score* combina essas duas métricas em uma única medida, útil em cenários onde ambas são igualmente importantes. Ele é uma ferramenta poderosa para avaliar o desempenho global de um modelo e identificar áreas que precisam de melhoria, sendo amplamente utilizada em pesquisas e aplicações práticas.

O *Pandas* é uma das bibliotecas mais poderosas e amplamente utilizadas na análise de dados em *Python*. Ele foi projetado para manipular e analisar grandes volumes de dados estruturados de forma eficiente e intuitiva. Baseado no *NumPy*, o *Pandas* oferece estruturas de dados flexíveis e ferramentas abrangentes que facilitam a manipulação, limpeza e visualização de informações. Seu objetivo é permitir que desenvolvedores e cientistas de dados trabalhem de forma eficaz com dados tabulares e séries temporais, duas das formas mais comuns de organização de informações.

O *Pandas* oferece estruturas de dados flexíveis que permitem lidar com informações or-

organizadas de maneira tabular ou linear, sendo amplamente utilizado para representar conjuntos de dados em formato bidimensional ou unidimensional. Essas estruturas permitem manipular e acessar os dados de forma eficiente, possibilitando análises mais detalhadas e organizadas.

A biblioteca se destaca por sua capacidade de importar e exportar dados em diversos formatos amplamente utilizados, como planilhas, arquivos de texto e bancos de dados. Isso facilita a integração com outras ferramentas e sistemas, tornando-a uma solução poderosa para fluxos de trabalho que envolvem grandes volumes de informações. Além disso, o Pandas é conhecido por suas ferramentas de manipulação de dados, permitindo acessar, filtrar, reorganizar e ajustar informações de forma prática. Com essas funcionalidades, é possível trabalhar com subconjuntos de dados específicos, reorganizar sua estrutura e realizar operações complexas para extrair *insights*.

O tratamento de dados incompletos ou inconsistentes é outra funcionalidade central do Pandas, que simplifica a identificação e a correção de problemas comuns em conjuntos de dados. A biblioteca também possibilita renomear elementos e reorganizar a estrutura dos dados para adequá-los às necessidades da análise.

Na análise e transformação de dados, o Pandas oferece ferramentas que permitem realizar cálculos e estatísticas de forma integrada, além de possibilitar o agrupamento e a reorganização de informações. Isso viabiliza a criação de resumos analíticos e a apresentação de resultados de maneira mais estruturada.

A versatilidade e a eficiência do Pandas tornam-no indispensável para análise e manipulação de dados. Ele é amplamente utilizado em diferentes áreas, permitindo que cientistas de dados e outros profissionais lidem com grandes volumes de informações de maneira organizada e produtiva, otimizando o processo de extração de *insights*.

O *Matplotlib* é uma biblioteca amplamente utilizada para criar gráficos e visualizações de dados em *Python*, sendo fundamental para a análise e comunicação de informações de forma visual. Sua flexibilidade e capacidade de personalização permitem a criação de gráficos estáticos, interativos e até animados, atendendo às demandas de diferentes áreas, como ciência de dados, pesquisa acadêmica e engenharia. Desde a sua criação em 2003, a biblioteca tornou-se uma referência no ecossistema *Python* devido à sua robustez e integração com outras ferramentas.

Com ele, é possível gerar uma ampla variedade de gráficos, desde simples linhas e barras até representações mais complexas, como gráficos tridimensionais e mapas de calor. Uma de suas principais vantagens é o alto grau de personalização que oferece, permitindo o ajuste de praticamente todos os aspectos de um gráfico, como cores, títulos, rótulos, escalas e legendas. Essa característica faz com que o *Matplotlib* seja amplamente utilizado em aplicações que exigem visualizações profissionais e detalhadas. Além disso, a biblioteca é ideal para criar gráficos comparativos ou relacionados por meio de *subplots*, o que facilita a análise de múltiplos

conjuntos de dados em uma única figura. Para aplicações mais avançadas, o suporte a gráficos tridimensionais permite explorar dados em perspectivas diferentes, o que é especialmente útil em projetos que envolvem dados espaciais ou variáveis dependentes de múltiplas dimensões.

Outro ponto forte dele é sua integração com outras bibliotecas populares do ecossistema *Python*, como *NumPy*, *Pandas* e *Seaborn*. Isso permite que dados processados nessas ferramentas sejam facilmente visualizados, criando um fluxo de trabalho eficiente para a análise e apresentação de informações. Além disso, a biblioteca também suporta a criação de gráficos interativos e animações, tornando-a ideal para representar mudanças ao longo do tempo ou responder a ações do usuário.

O *Matplotlib* facilita a exportação de gráficos em diversos formatos, como PNG, PDF e SVG, o que o torna uma escolha confiável para gerar visualizações destinadas a relatórios profissionais e publicações científicas. Sua versatilidade e robustez garantem que ele seja amplamente adotado por profissionais que buscam transformar dados em representações visuais impactantes e compreensíveis. Por todas essas características, ele é uma ferramenta indispensável para análise e comunicação visual de dados.

3.5 AVALIAÇÃO DOS MODELOS

Após o treinamento, a avaliação do modelo deve ser conduzida de forma sistemática para verificar se os objetivos propostos foram atingidos. Para isso, deve ser utilizada a matriz de confusão como ferramenta central, a partir da qual serão extraídas métricas previamente discutidas no referencial teórico, como acurácia, precisão, *recall* e *F1-score*. O emprego dessas métricas, em conjunto, permite analisar diferentes dimensões do desempenho dos classificadores, possibilitando comparações consistentes entre técnicas interpretáveis e métodos de maior complexidade.

Mais do que oferecer valores isolados, a matriz de confusão possibilita compreender os erros cometidos pelo modelo, como a ocorrência de falsos positivos e falsos negativos. Essa interpretação é essencial no contexto deste estudo, pois permite identificar de que maneira cada tipo de erro pode impactar a aplicação prática em ambientes domésticos voltados para idosos. A partir dessa análise, espera-se ser possível propor ajustes que priorizem a redução de riscos mais críticos.

A utilização conjunta das métricas busca superar limitações associadas ao uso isolado de cada uma. Enquanto a acurácia fornece uma visão geral do desempenho, métricas como precisão e *recall* permitem investigar o equilíbrio entre confiabilidade e abrangência nas previsões. Já o *F1-score* será adotado como indicador de síntese, facilitando a comparação entre diferentes modelos e auxiliando na escolha do classificador mais adequado às necessidades do projeto. Essa abordagem garante que a avaliação não se restrinja a um único critério, mas considere múltiplas perspectivas relevantes.

Os resultados obtidos na fase de avaliação deve ser empregados de forma iterativa para o aprimoramento do modelo. Caso o desempenho não atinja os critérios estabelecidos, poderão ser realizados ajustes no pré-processamento, nos hiperparâmetros ou até mesmo a substituição do algoritmo. Essa flexibilidade metodológica visa assegurar que o modelo final seja robusto, confiável e adequado à realidade do problema abordado.

Por fim, a avaliação deve ser tratada como um processo contínuo, acompanhando a evolução do conjunto de dados ao longo do tempo. À medida que novas informações forem incorporadas, o modelo será reavaliado e re-treinado, garantindo sua adaptação a mudanças e preservando sua eficácia. Essa estratégia busca assegurar que a solução proposta se mantenha relevante e efetiva na promoção de ambientes domésticos mais seguros para idosos.

3.6 CONSIDERAÇÕES FINAIS

A análise dos modelos envolverá dois principais métodos: Árvores de Decisão e Redes Neurais. As Árvores de Decisão destacam-se pela transparência e facilidade de interpretação, essenciais em contextos onde a explicabilidade é uma prioridade, como no caso de projetos voltados para a segurança. No entanto, sua precisão pode ser limitada em conjuntos de dados complexos. Já as Redes Neurais, embora ofereçam alta acurácia e a capacidade de capturar padrões complexos, apresentam o desafio da interpretabilidade reduzida, sendo mais adequadas para problemas que exigem precisão preditiva elevada. As lições aprendidas, após essa análise, devem evidenciar a importância de equilibrar explicabilidade e precisão, dependendo do objetivo do estudo.

A finalização desta etapa de detalhamento do método de pesquisa permite afirmar que a definição conceitual e operacional do estudo está concluída. Nesta fase, foram estruturados os cenários de análise, definidos os procedimentos de tratamento dos dados, estabelecidos os critérios de preparação das variáveis e selecionadas as técnicas de modelagem que serão empregadas nos experimentos. Todo esse planejamento fornece a base necessária para que a etapa de aplicação seja conduzida de forma coerente, organizada e metodologicamente consistente.

Com o método delineado, observa-se que a execução dos modelos é tecnicamente viável e que os dados disponíveis, após a organização em cenários, apresentam condições adequadas para os testes previstos. Entretanto, a implementação dos algoritmos depende de um ambiente computacional estruturado que suporte as demandas de pré-processamento, treinamento e validação dos modelos.

Dessa forma, antes de iniciar a aplicação dos métodos, torna-se essencial preparar o ambiente de desenvolvimento, definindo as plataformas que serão utilizadas, as bibliotecas necessárias e os recursos computacionais adequados. Essa etapa garante que a transição do planejamento metodológico para a execução prática ocorra de maneira alinhada aos objetivos da pesquisa.

4 IMPLEMENTAÇÃO DOS MODELOS DE *MACHINE LEARNING*

4.1 PREPARAÇÃO DO AMBIENTE DE DESENVOLVIMENTO

Para o desenvolvimento dos modelos de machine learning e a execução das etapas de análise exploratória, foi necessário estabelecer um ambiente de trabalho capaz de suportar processamento iterativo, testes sucessivos e registro organizado dos resultados. Como a construção dos modelos envolveu diferentes cenários, variações de atributos e múltiplas configurações de hiperparâmetros, a utilização de notebooks interativos mostrou-se fundamental para garantir agilidade e reprodutibilidade.

Nesse contexto, adotou-se o ambiente *Google Colab* como ferramenta principal de desenvolvimento. O *Colab* foi selecionado por oferecer suporte gratuito à execução em nuvem, compatibilidade nativa com as bibliotecas utilizadas (*Pandas*, *NumPy*, *Matplotlib* e *Scikit-learn*), além de permitir facilmente a importação e manipulação dos arquivos de dados armazenados no *Google Drive*.

Por se tratar de um conjunto de dados com diversas variáveis distribuídas em diferentes contextos, informações dos idosos, percepções do ambiente e avaliação técnica, não seria viável trabalhar todos os atributos em um único modelo. Portanto, definiu-se, em conjunto com os especialistas, a divisão dos dados em três cenários principais, um conjunto de dados reúne informações demográficas, clínicas e comportamentais dos idosos, um que contém as percepções dos idosos sobre o ambiente doméstico em que vivem e um com uma avaliação técnica do ambiente doméstico realizada por um(a) arquiteto(a).

4.2 DETALHAMENTO DOS CENÁRIOS DE TESTE

Para a realização das análises e construção dos modelos de machine learning, foram disponibilizados três conjuntos de dados distintos, cada um representando uma perspectiva complementar sobre o risco de quedas em ambientes domésticos. Os datasets utilizados foram:

- Perfil dos idosos: contendo informações pessoais, clínicas e sociodemográficas.
- Percepção dos idosos sobre o ambiente doméstico: com respostas sobre segurança, conforto, mobilidade e condições do lar.
- Avaliação técnica do ambiente feita por um arquiteto(a): reunindo observações profissionais sobre acessibilidade, iluminação, ergonomia, circulação e riscos estruturais.

A partir desses dados, e com apoio de um especialista da área, foram definidos três cenários de teste, cada um correspondente a um desses conjuntos. O objetivo foi analisar indi-

vidualmente como cada tipo de informação contribui para a construção de modelos preditivos relacionados a quedas.

O primeiro cenário reuniu os atributos relacionados à saúde, idade, comorbidades, uso de medicamentos, condições sensoriais e características demográficas. Ele buscou identificar se fatores clínicos e pessoais apresentam influência significativa no risco de quedas.

No segundo cenário foram utilizadas variáveis que representam como o próprio idoso enxerga seu ambiente doméstico. As respostas abordam sensação de segurança, existência de obstáculos, facilidade de locomoção, qualidade da iluminação, organização do espaço e presença de elementos que facilitam ou dificultam a rotina diária.

O terceiro cenário reuniu informações estruturais e arquitetônicas analisadas por um profissional. Esses dados incluem presença de desníveis, adequação do mobiliário, circulação, condição dos pisos, existência de barras de apoio e demais elementos relacionados à segurança física do ambiente.

As seções seguintes detalham o desenvolvimento dos modelos de machine learning aplicados a cada cenário, incluindo as etapas de preparação dos dados, análise exploratória e avaliação do desempenho das Árvores de Decisão e Redes Neurais.

4.3 CENÁRIO 1

O primeiro cenário de análise teve como foco o dataset dos idosos, considerado o núcleo principal deste estudo. Esse conjunto de dados reúne informações demográficas, clínicas e comportamentais obtidas por meio de fichas cadastrais e entrevistas estruturadas. O objetivo foi compreender como características individuais como idade, sexo, condições de saúde, hábitos de vida e estrutura de moradia estão relacionadas à ocorrência de quedas e acidentes domésticos.

Este cenário representa a dimensão humana do fenômeno. Enquanto outros conjuntos de dados analisam o ambiente físico e a descrição dos acidentes, o presente cenário busca investigar o elemento biológico e comportamental que pode tornar o idoso mais vulnerável, mesmo em locais considerados seguros. Compreender esses fatores é essencial para fundamentar soluções de monitoramento, prevenção e intervenção baseadas em inteligência artificial e tecnologias assistivas.

Durante o processo de preparação dos dados, foi realizada uma sequência de etapas de ETL, que teve como meta principal transformar o conjunto original de informações heterogêneas em uma base padronizada, estruturada e apta para modelagem estatística e computacional. As principais etapas realizadas foram:

- Extração e consolidação: os dados foram obtidos a partir de planilhas preenchidas manualmente, convertidas para o formato CSV.

- Limpeza e filtragem: colunas sem respostas foram removidas e valores ausentes substituídos por zero, garantindo consistência para operações matemáticas.
- Transformação de variáveis categóricas: respostas textuais (“Sim”, “Não”) foram convertidas para valores binários (1 e 0), e colunas categóricas como Sexo, Área de residência e Tipo de moradia foram convertidas para dummies por meio da técnica *one-hot encoding*.
- Criação de variáveis derivadas: duas colunas adicionais foram incluídas: *caiu* e *nao caiu*, que sintetizam o histórico de quedas dos participantes. A primeira assume valor 1 se o idoso relatou qualquer tipo de queda, enquanto a segunda vale 1 quando nenhuma queda foi registrada.

Essas transformações resultaram em uma base estruturada, composta exclusivamente por variáveis numéricas, ideal para a aplicação de técnicas de machine learning.

Após a execução completa do processo de ETL o conjunto final de dados ficou composto por 110 instâncias (linhas) e 37 variáveis (colunas), todas em formato numérico, o que eliminou a necessidade de pré-processamentos adicionais durante a modelagem.

As variáveis que permaneceram no dataset incluem atributos demográficos (idade, sexo), características do ambiente familiar (área de residência, número de pavimentos), hábitos e condições comportamentais, além das principais comorbidades reportadas pelos participantes, como hipertensão arterial, diabetes mellitus, depressão, doenças cardíacas e limitações sensoriais. Todas as variáveis categóricas originais foram convertidas para códigos representados por inteiros (0 e 1), mantendo consistência para cálculos estatísticos e para os modelos supervisionados. Nos casos em que a categoria possuía mais de duas possibilidades, foi aplicada a técnica de *one-hot encoding* para gerar colunas binárias equivalentes.

Além disso, foram criadas duas variáveis derivadas fundamentais para a modelagem:

- “caiu”: indicando se o idoso relatou ao menos um episódio de queda, com 69 instancias;
- “não caiu”: indicando ausência total de quedas registradas, com 41 instancias.

Essas variáveis foram criadas com o objetivo de transformar os múltiplos tipos de queda em uma estrutura de saída binária, mais adequada aos modelos utilizados no estudo.

Com essa estrutura final, o dataset ficou apropriado para a aplicação dos modelos utilizados neste trabalho. A organização das variáveis, a consistência dos valores e a definição de uma saída binária garantem condições adequadas para a aplicação dos algoritmos.

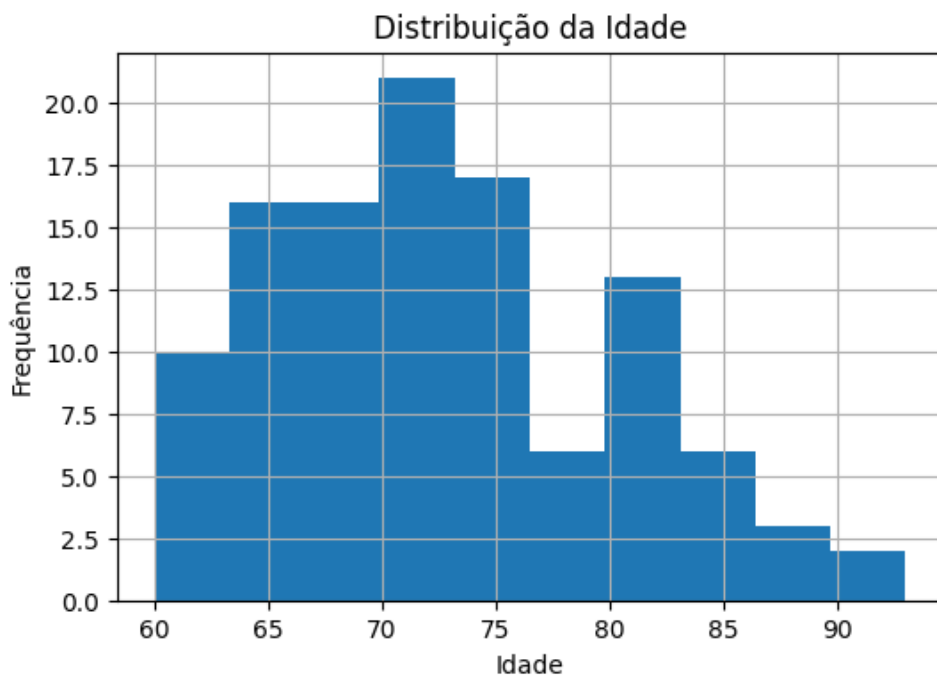
4.3.1 Análise Exploratória

A análise exploratória foi uma etapa para compreender a estrutura e as relações internas do dataset dos idosos antes da modelagem preditiva. Por meio dela, foi possível identificar

padrões, avaliar distribuições, observar tendências e levantar hipóteses sobre os fatores que influenciam diretamente a ocorrência de quedas.

A primeira etapa consistiu na análise da distribuição etária dos participantes. O histograma da variável Idade mostrou uma concentração significativa de idosos entre 70 e 80 anos, com um número reduzido de participantes abaixo dos 65 e acima dos 85 anos. A Figura 21 mostra a distribuição da idade dos participantes da pesquisa.

Figura 21 – Distribuição etária dos participantes

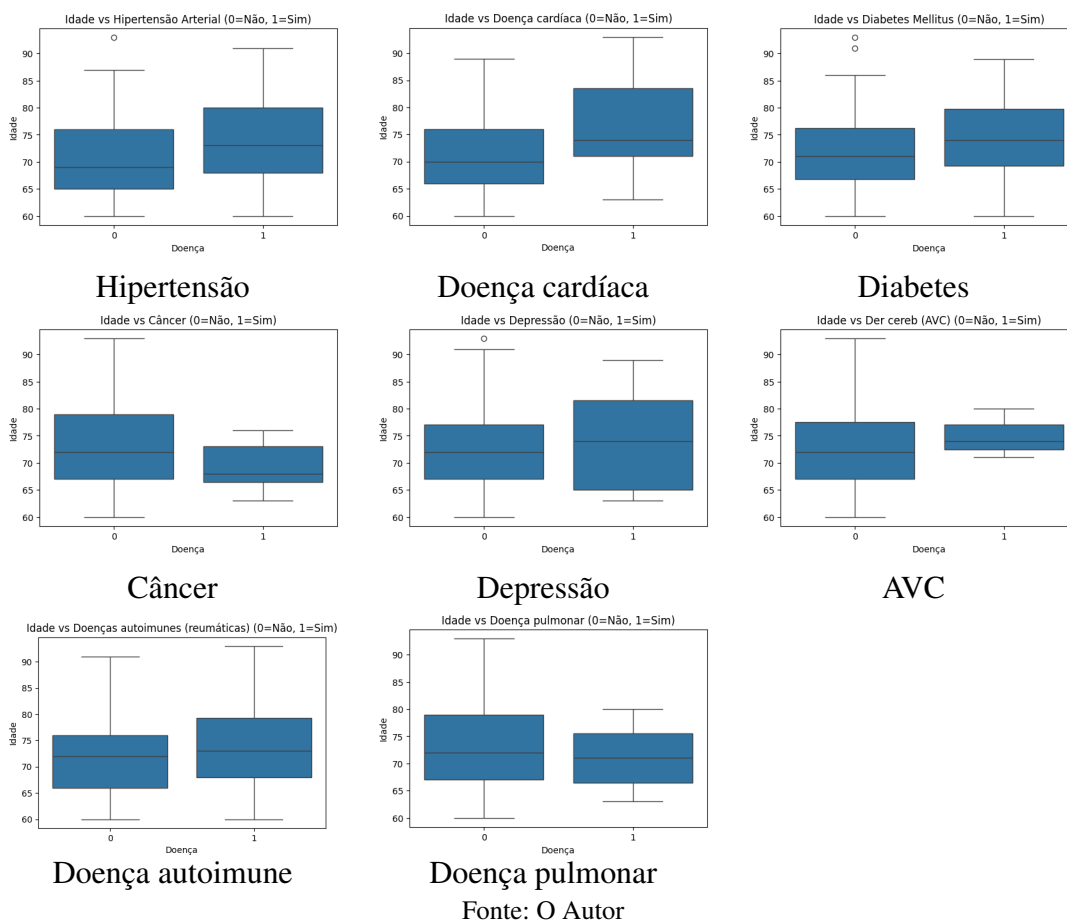


Fonte: O Autor

Na sequência, foram analisadas as variáveis clínicas, com foco nas doenças mais frequentemente relatadas pelos participantes. Para essa etapa, foram utilizados *boxplots*, que representam graficamente a distribuição e a variação das respostas (0 = ausência, 1 = presença) para cada condição de saúde. Embora cada variável seja binária, o uso de *boxplots* permite comparar a dispersão e a frequência relativa entre diferentes doenças, facilitando a visualização de quais condições são mais comuns.

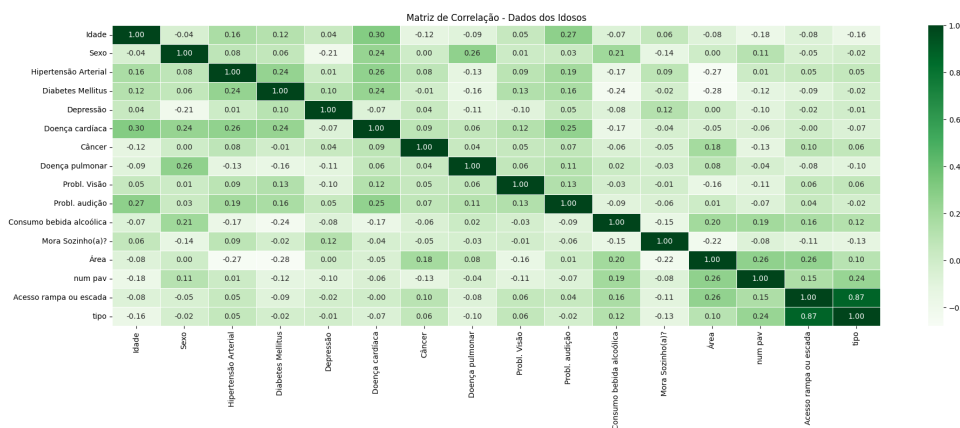
Nos gráficos, observou-se que as doenças Hipertensão Arterial e Problemas de Visão apresentaram medianas próximas a 1, indicando que mais da metade dos idosos relatou possuir essas condições. Já variáveis como Câncer e Doenças Autoimunes apresentaram medianas próximas a 0 e ausência de dispersão, o que sugere que poucos participantes relataram essas doenças. A Tabela 7 mostra os *boxplots* das doenças.

Tabela 7 – *Boxplot* das doenças relatadas pelos idosos



Posteriormente, foi calculada a matriz de correlação entre as variáveis numéricas, incluindo idade, condições de saúde e características físicas do domicílio. O mapa de calor gerado mostra as correlações entre as variáveis de entrada. A Figura 22 mostra a matriz de correlação das variáveis de entrada.

Figura 22 – Matriz de correlação das variáveis do cenário 1



Fonte: O Autor

Por fim, foram criadas as variáveis denominadas “caiu” e “não caiu”, com o objetivo de representar de forma clara a ocorrência ou ausência de quedas (atributo classificador ou alvo). Essa transformação foi necessária, visto que as variáveis que indicavam a queda eram muito esparsas e parte dos participantes não havia relatado queda. Desta forma, simplificou-se o problema para uma classificação binária, sendo que a classe do modelo indicaria a ocorrência prévia de queda ou não.

4.3.2 Árvore de Decisão

Após a etapa de análise exploratória, foi implementado um modelo de Aprendizado Supervisionado utilizando o algoritmo Árvore de Decisão, com o objetivo de prever a probabilidade de ocorrência de quedas a partir das características clínicas, demográficas e estruturais das residências dos idosos.

O modelo foi treinado utilizando como variáveis de entrada, atributos relacionados à idade, sexo, presença de doenças crônicas, condições sensoriais e características estruturais do ambiente doméstico.

Para aprimorar o desempenho e encontrar a melhor configuração possível, foi empregado o método *GridSearchCV*, que realiza uma varredura sistemática entre diferentes combinações de hiperparâmetros. O objetivo dessa técnica é determinar quais valores produzem o modelo com maior desempenho.

Os principais hiperparâmetros testados foram:

- *criterion*: função usada para medir a qualidade das divisões, variando entre gini e entropy;
- *max_depth*: profundidade máxima da árvore, testada entre 3 e 10 níveis;
- *min_samples_split*: número mínimo de amostras exigido para dividir um nó interno, variando entre 2 e 5;
- *min_samples_leaf*: número mínimo de amostras em cada folha final, testado entre 1 e 3.

O método *GridSearchCV* foi configurado com *cross-validation* de cinco partições, garantindo que cada subconjunto dos dados fosse utilizado tanto para treinamento quanto para teste, reduzindo o risco de *overfitting*. A métrica de avaliação utilizada foi a acurácia, que mede a proporção de previsões corretas entre as amostras analisadas.

Ao término da busca, o modelo ótimo foi encontrado com os parâmetros:


- *criterion* = 'entropy';
- *max_depth* = 4;

- *max_features* = 6;
- *min_samples_split* = 8;
- *min_samples_leaf* = 2;

Esses valores equilibraram bem a capacidade de interpretabilidade da árvore, evitando que o modelo se tornasse excessivamente complexo.

O modelo otimizado apresentou acurácia de 72.72% na divisão *hold-out* (80% treino / 20% teste), e 63.64% na *cross-validation*. Embora esses valores não representem uma separação perfeita entre as classes, eles são considerados satisfatórios para um conjunto de dados pequeno, como o utilizado neste estudo. A Figura 23 mostra a matriz de confusão da árvore de decisão com o método *hold-out* enquanto a Figura 24 mostra o *classification report* do mesmo.

Figura 23 – Matriz de confusão da árvore de decisão com o método *hold-out*



Fonte: O Autor


Figura 24 – *Classification report* da árvore de decisão com o método *hold-out*

	precision	recall	f1-score	support
0	0.75	0.38	0.50	8
1	0.72	0.93	0.81	14
micro avg	0.73	0.73	0.73	22
macro avg	0.74	0.65	0.66	22
weighted avg	0.73	0.73	0.70	22
samples avg	0.73	0.73	0.73	22

Fonte: O Autor

A matriz de confusão mostrou que o modelo apresentou um equilíbrio entre as previsões corretas de “caiu” e “não caiu”, com ligeira tendência a classificar corretamente a classe majoritária (idosos que não sofreram quedas). A Figura 25 mostra a matriz de confusão da árvore de decisão com o método *cross-validation* enquanto a Figura 26 mostra o *classification report* do mesmo.

Figura 25 – Matriz de confusão da árvore de decisão com o método *cross-validation*



Fonte: O Autor

Figura 26 – *Classification report* da árvore de decisão com o método *cross-validation*

	precision	recall	f1-score	support
0	0.56	0.24	0.34	41
1	0.67	0.87	0.75	69
micro avg	0.65	0.64	0.64	110
macro avg	0.61	0.56	0.55	110
weighted avg	0.63	0.64	0.60	110
samples avg	0.64	0.64	0.64	110

Fonte: O Autor

A Árvore de Decisão apresentou desempenho limitado devido à baixa capacidade preditiva das variáveis clínicas quando utilizadas isoladamente. A análise da árvore evidencia divisões pouco informativas, resultantes da fraca correlação entre os atributos e o evento “caiu”. O modelo demonstrou boa acurácia geral, porém baixo recall para a classe minoritária, indicando tendência a classificar os idosos como “não caiu”. Esses resultados mostram que dados clínicos, isoladamente, não são suficientes para identificar padrões consistentes de risco de quedas, reforçando a necessidade de integrar aspectos ambientais e perceptivos nos cenários seguintes.

4.3.3 Rede Neural

Após a etapa de modelagem com a árvore de decisão, foi implementado um segundo modelo preditivo utilizando a classe que implementa uma rede neural perceptron multicamadas (*MLPClassifier*), pertencente à biblioteca Scikit-Learn ⁽¹⁾. O objetivo principal dessa etapa foi explorar uma abordagem não linear e compará-la aos resultados obtidos pelo método da árvore de decisão.

O conjunto de dados do cenário 1 foi utilizado para o treinamento da rede neural. As variáveis de saída foram mantidas como “caiu” e “não caiu”, ambas binárias e complementares, representando a ocorrência ou ausência de quedas relatadas pelos participantes.

Foram realizados vários testes a fim de se observar o comportamento das arquiteturas de redes neurais sobre os dados. Por exemplo, testou-se o desempenho do algoritmo variando-se os seguintes hiperparâmetros: números de camadas, números de neurônios por camadas, algoritmo de otimização dos pesos (*solver*), número de iterações, função de ativação (*activation*) e taxa de aprendizado (*learning_rate*). Após testes, conclui-se que os melhores resultados foram obtidos com os seguintes hiperparâmetros :

- *hidden_layer_sizes* = (18, 18);


¹ https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPClassifier.html

- *alpha* = 0.0001;
- *activation* = 'tanh';
- *learning_rate* = 'constant';
- *solver* = 'adam';
- *max_iter* = 3000;

Na primeira abordagem, foi utilizada a estratégia *hold-out*, separando 80% dos dados para treinamento e 20% para teste. O modelo foi ajustado com base no conjunto de treinamento e, posteriormente, avaliado no conjunto de teste, gerando as métricas de desempenho. O método *classification report* revelou desempenho equilibrado entre precisão e *recall* nas duas classes a acurácia obtida no conjunto de teste foi de aproximadamente 68,18%, demonstrando que o modelo teve dificuldade em classificar as instâncias de forma satisfatória.

A matriz de confusão correspondente à predição do conjunto de teste mostrou que a rede neural acertou a maior parte das amostras da classe “não caiu”. No entanto, o modelo não apresentou bom desempenho na identificação da classe “caiu”, o que evidencia sua incapacidade de detectar padrões associados aos fatores de risco para quedas. A Figura 27 mostra a matriz de confusão da rede neural com o método *hold-out* enquanto a Figura 28 mostra o *classification report* do mesmo.

Figura 27 – Matriz de confusão da rede neural com *hold-out*



Fonte: O Autor

Figura 28 – *Classification report* da rede neural com *hold-out*

	precision	recall	f1-score	support
0	0.75	0.38	0.50	8
1	0.71	0.86	0.77	14
micro avg	0.71	0.68	0.70	22
macro avg	0.73	0.62	0.64	22
weighted avg	0.72	0.68	0.67	22
samples avg	0.68	0.68	0.68	22


Fonte: O Autor

Após a análise inicial, foi conduzida uma segunda etapa utilizando *cross-validation* com dez partições, com o intuito de reduzir a dependência dos resultados em relação a uma única divisão dos dados e avaliar a estabilidade do modelo em diferentes subconjuntos. Nesse método, o modelo é treinado e testado sucessivamente em diferentes combinações de dados, e a média das métricas fornece uma estimativa mais confiável da capacidade de generalização.

A matriz de confusão obtida demonstrou comportamento similar ao cenário *hold-out*, o que evidencia sua incapacidade de detectar padrões associados aos fatores de risco para que-

das. A Figura 29 mostra a matriz de confusão da rede neural com o método *cross-validation* enquanto a Figura 30 mostra o *classification report* do mesmo.

Figura 29 – Matriz de confusão da rede neural com *cross-validation*



Fonte: O Autor

Figura 30 – *Classification report* da rede neural com *cross-validation*

	precision	recall	f1-score	support
0	0.48	0.49	0.48	41
1	0.69	0.68	0.69	69
micro avg	0.61	0.61	0.61	110
macro avg	0.58	0.58	0.58	110
weighted avg	0.61	0.61	0.61	110
samples avg	0.60	0.61	0.61	110

Fonte: O Autor

Os resultados obtidos pela rede neural no Cenário 1 deixam claro que dados clínicos e demográficos, isoladamente, não são suficientes para compor um modelo preditivo eficiente para quedas. O desempenho limitado, especialmente no reconhecimento da classe "caiu", evidencia que o risco de queda é um fenômeno multifatorial que depende tanto de condições individuais quanto de fatores ambientais e perceptivos.

4.3.4 Conclusão Sobre o Cenário 1

A Tabela 8 apresenta uma comparação entre os modelos de Árvore de Decisão e Rede Neural, avaliados tanto na estratégia de *hold-out* quanto em *cross-validation*. Para cada modelo, são destacados a precisão e o *recall* da classe “caiu”, além da acurácia global. Esses indicadores permitem avaliar não apenas o percentual de acertos totais, mas, principalmente, a capacidade dos modelos em identificar corretamente os idosos que já sofreram algum tipo de queda.

Tabela 8 – Tabela comparativa dos modelos no cenário 1

Modelo	Precisão da classe caiu	<i>Recall</i> da classe caiu	Acurácia
Árvore de decisão <i>hold-out</i>	0,75	0,38	72,73%
Árvore de decisão <i>cross-validation</i>	0,56	0,24	63,64%
Rede Neural <i>hold-out</i>	0,75	0,38	68,18%
Rede Neural <i>cross-validation</i>	0,48	0,49	60%

Fonte: O Autor

A tabela de conclusão do Cenário 1 sintetiza os resultados obtidos pelos dois modelos aplicados, considerando tanto o método *hold-out* quanto a *cross-validation*. Essa tabela permite visualizar de maneira comparativa os principais indicadores dos modelos, especialmente a acurácia global e o desempenho na classe “caiu”, que é a classe de maior interesse neste estudo.

Ao analisar os valores apresentados, observa-se que, embora as acurácias gerais dos modelos tenham ficado em níveis moderados, os resultados relacionados à identificação da classe “caiu” foram fracos em todas as abordagens. Tanto a precisão quanto o *recall* dessa classe foram baixos, indicando que os modelos tiveram dificuldade em distinguir adequadamente os idosos que tinham histórico de queda. Essa limitação se reflete diretamente no alto número de falsos negativos, ou seja, casos em que o modelo prevê que o idoso não caiu, quando ele de fato caiu.

Esses resultados evidenciam uma questão central do Cenário 1: as variáveis clínicas e demográficas, utilizadas de forma isolada, não oferecem informação suficiente para que os modelos reconheçam padrões robustos associados ao risco de quedas. Embora idade, presença de doenças crônicas ou limitações sensoriais sejam relevantes para o entendimento geral da saúde do idoso, elas não refletem o ambiente no qual a queda ocorre nem como o idoso percebe e lida com esse ambiente.

Diante desses resultados, conclui-se que o Cenário 1, isoladamente, não constitui um bom conjunto de variáveis para a predição de quedas. Embora traga informações importantes sobre o perfil dos idosos, esse conjunto de dados não é suficiente para sustentar uma inferência confiável.

4.4 CENÁRIO 2

O Cenário 2 teve como objetivo analisar as percepções dos idosos sobre o ambiente doméstico, buscando compreender como eles avaliam fatores de conforto, segurança e acessibilidade em seus lares. Os dados utilizados nesta etapa foram obtidos a partir do questionário “Descrição de Acidentes Domésticos sob a Perspectiva do Usuário”, que reuniu respostas relacionadas à estrutura física das residências e à sensação de segurança percebida pelos participantes.

As respostas abrangeram tanto aspectos estruturais como degraus, rampas, tipo de piso e iluminação, quanto aspectos subjetivos, como facilidade de locomoção, organização dos espaços e percepção de risco. Esses dados permitiram investigar como os idosos interpretam o ambiente em que vivem e de que forma essa percepção pode se relacionar ao risco de quedas, discutido anteriormente no Cenário 1.

Após o processo completo de ETL, o conjunto de dados do Cenário 2 foi estruturado em um formato consistente e adequado para aplicação dos modelos de machine learning. O dataset final passou a conter 110 instâncias (linhas) e 191 variáveis (colunas), todas padronizadas em formato numérico, o que eliminou a necessidade de tratamentos adicionais durante as etapas de modelagem. As variáveis de saída continuaram as mesmas do cenário 1 com o mesmo número de instâncias por classe.

As variáveis que permaneceram incluem variáveis com múltiplas categorias, onde foi aplicada a técnica de *one-hot encoding*, resultando em colunas adicionais que representam cada categoria como uma variável independente.

Com essa estrutura final, o dataset ficou apropriado para a aplicação dos modelos utilizados neste trabalho. A organização das variáveis, a consistência dos valores e a definição de uma saída binária garantem condições adequadas para a aplicação dos algoritmos.


4.4.1 Análise Exploratória

A análise exploratória deste cenário teve como objetivo identificar padrões nas percepções dos idosos sobre seus ambientes domésticos e avaliar possíveis relações entre as variáveis coletadas. Os dados foram analisados considerando dimensões como segurança, conforto, iluminação, acessibilidade e praticidade no dia a dia.

De forma geral, verificou-se que a maioria dos idosos relatou percepções positivas sobre suas residências, embora alguns participantes tenham destacado dificuldades específicas, como pisos escorregadios, desníveis e degraus sem apoio. Esses elementos podem contribuir para a sensação de insegurança e impactar a autonomia de mobilidade.

A matriz de correlação construída a partir das respostas revelou relações consistentes entre variáveis, indicando que os participantes tendem a avaliar de forma conjunta aspectos

Figura 32 – Matriz de confusão da árvore de decisão com o método *hold-out*



Fonte: O Autor

Figura 33 – *Classification report* da árvore de decisão com o método *hold-out*

	precision	recall	f1-score	support
0	0.57	0.50	0.53	8
1	0.73	0.79	0.76	14
micro avg	0.68	0.68	0.68	22
macro avg	0.65	0.64	0.65	22
weighted avg	0.67	0.68	0.68	22
samples avg	0.68	0.68	0.68	22


Fonte: O Autor

No *hold-out*, a Árvore de Decisão mostrou desempenho melhor que o Cenário 1, especialmente na sensibilidade à classe “caiu”. Isso indica que variáveis perceptivas estão mais relacionadas ao risco de queda do que dados puramente clínicos.

Contudo, o recall ainda não é alto, revelando que o modelo tem dificuldades em captar todos os padrões relevantes. Isso ocorre porque, apesar da boa relação com o risco, percepções são subjetivas, variam entre indivíduos e possuem ruído natural.

Na segunda etapa, foi aplicada *cross-validation* com 5 partições, de modo que cada subconjunto do conjunto de dados fosse utilizado como teste uma vez. A acurácia foi um pouco menor que no método *hold-out*, chegando a 60,90%. A Figura 34 mostra a matriz de confusão da árvore de decisão com o método *cross-validation* enquanto a Figura 35 mostra o *classification report* do mesmo.

Figura 34 – Matriz de confusão da árvore de decisão com o método *cross-validation*



Fonte: O Autor

Figura 35 – *Classification report* da árvore de decisão com o método *cross-validation*

	precision	recall	f1-score	support
0	0.53	0.20	0.29	41
1	0.66	0.86	0.75	69
micro avg	0.64	0.61	0.63	110
macro avg	0.60	0.53	0.52	110
weighted avg	0.61	0.61	0.57	110
samples avg	0.61	0.61	0.61	110

Fonte: O Autor

No *cross-validation*, a Árvore manteve um desempenho consistente, mas sem saltos

significativos. Isso mostra que o comportamento do modelo não depende da divisão aleatória do dataset um indicador de estabilidade.

A acurácia geral é moderada e o recall da classe “caiu” ainda é limitado, mostrando que os padrões perceptivos são úteis mas não suficientes.


4.4.3 Rede Neural

Com o objetivo de investigar relações não lineares entre as percepções, foi aplicada uma rede neural artificial, utilizando a biblioteca Scikit-Learn. Foram utilizados os seguintes parâmetros principais que resultaram nos melhores resultados:

- *hidden_layer_sizes* = (95);
- *alpha* = 0.0001;
- *activation* = 'tanh';
- *learning_rate* = 'constant';
- *solver* = 'adam';
- *max_iter* = 3000;

Na divisão 80%/20%, a rede neural apresentou acurácia de 63,63%, com equilíbrio entre classes na matriz de confusão. A Figura 36 mostra a matriz de confusão da rede neural com o método *hold-out* enquanto a Figura 37 mostra o *classification report* do mesmo.

Figura 36 – Matriz de confusão da rede neural com *hold-out*



Fonte: O Autor

Figura 37 – *Classification report* da rede neural com *hold-out*

	precision	recall	f1-score	support
0	0.50	0.50	0.50	8
1	0.71	0.71	0.71	14
micro avg	0.64	0.64	0.64	22
macro avg	0.61	0.61	0.61	22
weighted avg	0.64	0.64	0.64	22
samples avg	0.64	0.64	0.64	22

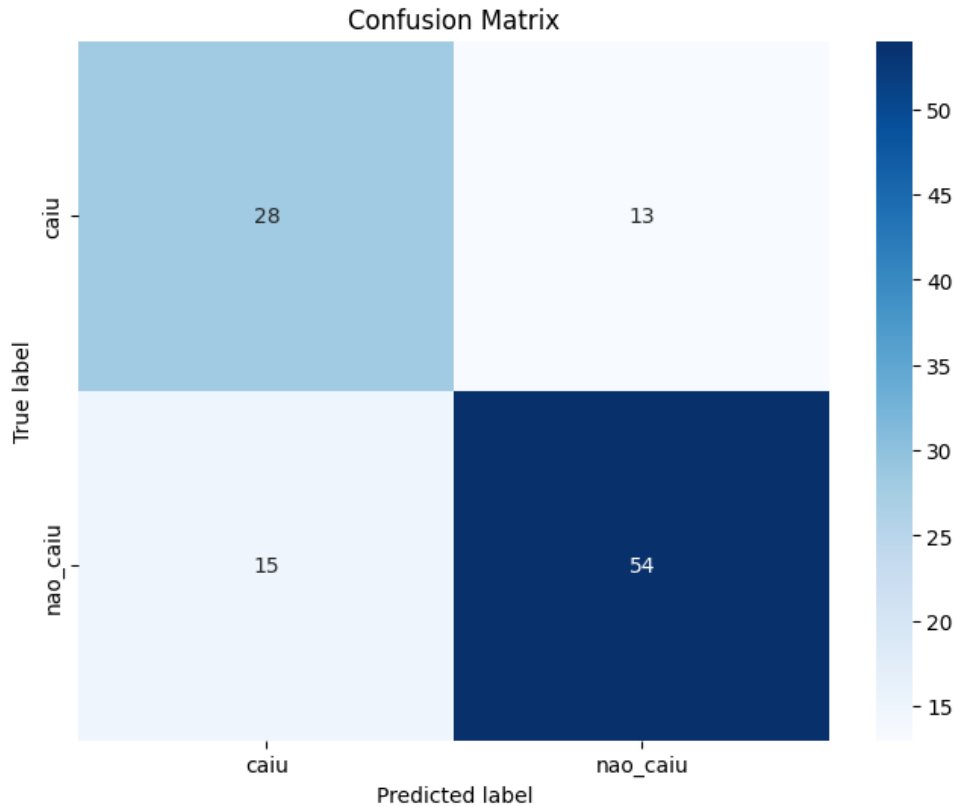
Fonte: O Autor

No teste *hold-out*, a acurácia obtida pela Rede Neural foi moderada, mas já superior ao modelo clínico do Cenário 1. Entretanto, mesmo com esse avanço, o recall da classe “caiu” permaneceu limitado. Isso indica que, embora a rede tenha começado a identificar padrões de risco, ela ainda não foi capaz de capturar de forma consistente todos os fatores subjetivos que motivam uma queda.

Na *cross-validation* com 5 partições, a acurácia foi de aproximadamente 74,54%, essa melhoria indica que o modelo conseguiu desempenhar melhor quando avaliado em diferentes

subconjuntos. A Figura 38 mostra a matriz de confusão da rede neural com o método *cross-validation* enquanto a Figura 39 mostra o *classification report* do mesmo.

Figura 38 – Matriz de confusão da rede neural com *cross-validation*



Fonte: O Autor

Figura 39 – *Classification report* da rede neural com *cross-validation*

	precision	recall	f1-score	support
0	0.65	0.68	0.67	41
1	0.81	0.81	0.81	69
micro avg	0.75	0.76	0.76	110
macro avg	0.73	0.75	0.74	110
weighted avg	0.75	0.76	0.76	110
samples avg	0.75	0.76	0.76	110

Fonte: O Autor

No *cross-validation*, a Rede Neural apresentou desempenho superior ao observado no hold-out, tanto em acurácia quanto em estabilidade geral. O uso da *cross-validation* permitiu uma exploração mais ampla das diferentes partições do conjunto de dados. Isso resultou em uma melhora perceptível, sugerindo que a rede neural se beneficia de processar múltiplas perspectivas do mesmo conjunto de atributos subjetivos.

A rede neural demonstrou desempenho superior ao observado no Cenário 1, tanto no hold-out quanto na cross-validation, mostrando que as percepções individuais fornecem informações mais diretamente ligadas ao cotidiano e ao ambiente doméstico. Essas percepções capturam nuances que não estão presentes nas variáveis clínicas, como dificuldades de locomoção percebidas, iluminação percebida como insuficiente ou obstáculos que são notados apenas pelo próprio idoso.

4.4.4 Conclusão Sobre o Cenário 2

A Tabela 9 apresenta a comparação entre os modelos de Árvore de Decisão e Rede Neural, avaliados nas estratégias de *hold-out* e *cross-validation*. Assim como no Cenário 1, são destacadas as métricas de precisão e *recall* da classe “caiu”, além da acurácia geral. Esses indicadores são essenciais para verificar a capacidade dos modelos de identificar corretamente os idosos que já sofreram quedas, reduzindo o número de falsos negativos.

Tabela 9 – Tabela comparativa dos modelos no cenário 2

Modelo	Precisão da classe caiu	<i>Recall</i> da classe caiu	Acurácia
Árvore de decisão <i>hold-out</i>	0,57	0,50	68,18%
Árvore de decisão <i>cross-validation</i>	0,53	0,20	60,90%
Rede Neural <i>hold-out</i>	0,50	0,50	63,63%
Rede Neural <i>cross-validation</i>	0,65	0,68	74,54%

Fonte: O Autor

Ao observar os valores presentes na tabela, nota-se que o desempenho geral dos modelos foi superior ao obtido no Cenário 1, especialmente em termos de acurácia global. Isso indica que as percepções dos idosos oferecem informações mais diretamente relacionadas ao risco de queda do que variáveis estritamente clínicas ou demográficas. A percepção pessoal tende a capturar nuances que não são facilmente observadas por terceiros, como dificuldade de enxergar pequenos desníveis, insegurança em determinados cômodos ou sensação de instabilidade ao caminhar.

Apesar dessa melhora, a tabela também evidencia que o desempenho na classe “caiu” ainda apresenta limitações. Embora tenha ocorrido um avanço em relação ao Cenário 1, modelos de ambos os tipos continuam apresentando dificuldades em identificar corretamente os idosos que já sofreram quedas. O *recall* da classe “caiu” permanece moderado a baixo, evidenciando a persistência de falsos negativos. Esse tipo de erro é especialmente crítico na prevenção e reforça que, embora haja ganho informacional neste cenário, os padrões disponíveis ainda não são completamente robustos.

Na maioria dos casos, o *cross-validation* produziu resultados ligeiramente superiores, sugerindo que os modelos conseguem aproveitar melhor o conjunto perceptivo quando expostos

a múltiplas partições. Essa estabilidade reforça o potencial informativo das percepções subjetivas, indicando que elas constituem um tipo de dado valioso, mesmo que apresentem naturalmente alguma variabilidade entre diferentes indivíduos.

Assim, conclui-se que o Cenário 2 constitui um conjunto de variáveis para a predição de quedas com melhor desempenho em relação ao Cenário 1 na identificação correta dos idosos que já sofreram quedas.

4.5 CENÁRIO 3

O Cenário 3 analisa a avaliação técnica do ambiente doméstico realizada por um(a) arquiteto(a), a partir do questionário “Descrição do Ambiente”. Diferentemente dos cenários anteriores que observaram o ponto de vista do idoso e registros de quedas, aqui o foco recai sobre características objetivas do espaço: acessos, circulação, desníveis, pisos, corrimãos, barras de apoio, iluminação, largura de portas, presença de obstáculos e demais atributos que afetam segurança e usabilidade.

Após a execução das etapas de ETL, o conjunto de dados do Cenário 3 foi reorganizado e padronizado para garantir consistência e adequação às técnicas de modelagem supervisionada. O dataset final passou a conter 110 instâncias (linhas) e 210 variáveis (colunas), todas convertidas para valores numéricos, o que eliminou a necessidade de transformações adicionais durante as etapas de treinamento dos modelos.

As variáveis presentes neste cenário incluem elementos estruturais e funcionais do ambiente, tais como presença de desníveis, pisos escorregadios, adequação da iluminação, existência de barras de apoio, largura e qualidade das áreas de circulação, disposição do mobiliário, acessibilidade nos cômodos, rampas, corrimãos e demais características avaliadas de forma objetiva pelo profissional responsável. Como diversas dessas variáveis eram originalmente categóricas, todas foram transformadas em valores binários, garantindo uniformidade e compatibilidade com os algoritmos utilizados.

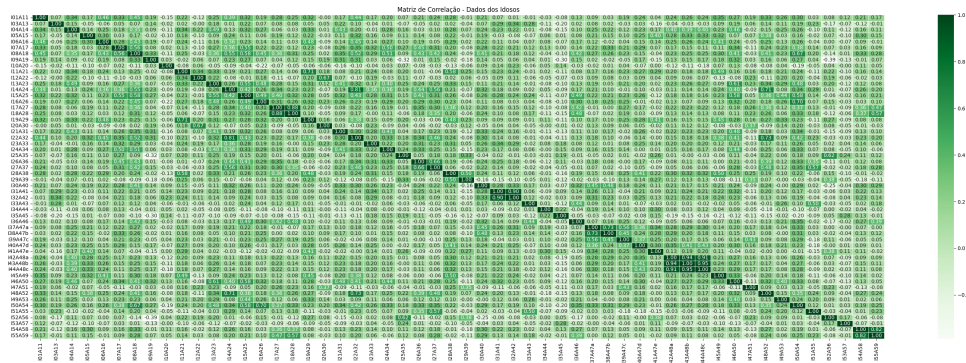
Com essa estrutura final, o dataset ficou apropriado para a aplicação dos modelos utilizados neste trabalho. A organização das variáveis, a consistência dos valores e a definição de uma saída binária garantem condições adequadas para a aplicação dos algoritmos.

4.5.1 Análise Exploratória

A análise exploratória visou inspecionar a estrutura das variáveis técnicas do ambiente e suas relações internas. Foram verificadas frequências por item, consistência de preenchimento, e construída uma matriz de correlação para identificar co-ocorrências entre requisitos arquitetônicos. Em geral, itens que expressam acessibilidade e circulação tendem a aparecer correlacionados entre si (por exemplo, presença de corrimão, barras de apoio e largura adequada de passagem), refletindo a natureza sistêmica da adequação espacial: quando um requisito é

atendido, frequentemente outros também o são. A Figura 40 mostra a matriz de correlação das variáveis de entrada.

Figura 40 – Matriz de correlação



Fonte: O Autor


4.5.2 Árvore de Decisão

Foi treinada uma árvore de decisão para classificar os ambientes a partir dos atributos técnicos avaliados pelo(a) arquiteto(a). Foi mantido o mesmo procedimento do Cenário 1: preparação dos dados, divisão dos conjuntos e busca com o *GridSearchCV* para buscar os melhores hiperparâmetros e assim o modelo ótimo foi encontrado com os seguintes parâmetros:

- *criterion* = 'gini';
- *max_depth* = 5;
- *max_features* = 5;
- *min_samples_split* = 2;
- *min_samples_leaf* = 3;

No particionamento 80% treino e 20% teste, a árvore apresentou acurácia em torno de 54,55%. O desempenho modesto é compatível com a heterogeneidade dos ambientes avaliados e com a granularidade dos itens técnicos. Ainda assim, a árvore permanece útil pela interpretabilidade, permitindo visualizar quais itens mais influenciam a classificação. A Figura 41 mostra a matriz de confusão da árvore de decisão com o método *hold-out* enquanto a Figura 42 mostra o *classification report* do mesmo.

Figura 41 – Matriz de confusão da árvore de decisão com o método *hold-out*



Fonte: O Autor

Figura 42 – *Classification report* da árvore de decisão com o método *hold-out*

	precision	recall	f1-score	support
0	0.40	0.25	0.31	8
1	0.62	0.71	0.67	14
micro avg	0.57	0.55	0.56	22
macro avg	0.51	0.48	0.49	22
weighted avg	0.54	0.55	0.54	22
samples avg	0.55	0.55	0.55	22

Fonte: O Autor


No hold-out, o modelo apresentou desempenho levemente melhor do que os cenários anteriores, especialmente quando comparado ao Cenário 1. A Árvore conseguiu identificar alguns padrões importantes no ambiente físico associados ao risco de queda — como obstáculos e condições estruturais inadequadas.

Apesar disso, o recall para a classe “caiu” ainda não atingiu níveis altos. Isso mostra que, embora as variáveis ambientais sejam muito relevantes, elas não capturam completamente

o comportamento do idoso dentro daquele espaço.

Aplicou-se também o *cross-validation 5-fold*, confirmando estabilidade de desempenho e registrando acurácia próxima de 50,0% nas saídas do notebook. A proximidade entre folds indica que o modelo não superajusta a uma única partição, mas também evidencia que os padrões discriminativos são fracos quando considerados apenas os itens técnicos isoladamente. A Figura 43 mostra a matriz de confusão da árvore de decisão com o método *cross-validation* enquanto a Figura 44 mostra o *classification report* do mesmo.

Figura 43 – Matriz de confusão da árvore de decisão com o método *cross-validation*



Fonte: O Autor

Figura 44 – *Classification report* da árvore de decisão com o método *cross-validation*

	precision	recall	f1-score	support
0	0.26	0.17	0.21	41
1	0.59	0.70	0.64	69
micro avg	0.50	0.50	0.50	110
macro avg	0.42	0.43	0.42	110
weighted avg	0.46	0.50	0.48	110
samples avg	0.50	0.50	0.50	110

Fonte: O Autor

Na *cross-validation*, o desempenho manteve o mesmo padrão observado no hold-out, acurácia moderada, recall da classe “caiu” limitado.

Isso mostra que a Árvore se comporta de maneira consistente, indicando que o cenário é estável — porém, estruturalmente limitado.


4.5.3 Rede Neural

A fim de investigar possíveis relações não lineares entre as variáveis avaliadas pelo profissional, aplicou-se o uma rede neural artificial, utilizando a biblioteca Scikit-Learn, da mesma maneira que nos cenários anteriores. Foram utilizados os seguintes parâmetros principais que resultaram nos melhores resultados:

- *hidden_layer_sizes* = (100,100);
- *alpha* = 0.0005;
- *activation* = 'tanh';
- *learning_rate* = 'adaptive';
- *solver* = 'sgd';
- *max_iter* = 3000;

Na primeira abordagem, com divisão 80%/20%, a rede obteve acurácia de aproximadamente 72,73%, desempenho semelhante ao obtido pela árvore de decisão. As matrizes de confusão e os relatórios de classificação mostraram que o modelo manteve equilíbrio entre classes, porém sem grande capacidade de distinção. A Figura 45 mostra a matriz de confusão da rede neural com o método *hold-out* enquanto a Figura 46 mostra o *classification report* do mesmo.

Figura 45 – Matriz de confusão da rede neural com *hold-out*



Fonte: O Autor

Figura 46 – *Classification report* da rede neural com *hold-out*


	precision	recall	f1-score	support
0	0.67	0.50	0.57	8
1	0.75	0.86	0.80	14
micro avg	0.73	0.73	0.73	22
macro avg	0.71	0.68	0.69	22
weighted avg	0.72	0.73	0.72	22
samples avg	0.73	0.73	0.73	22

Fonte: O Autor

No treinamento via *hold-out*, a Rede Neural Multilayer Perceptron apresentou desempenho moderado, com acurácia superior à observada nos cenários anteriores, especialmente no Cenário 1. Ainda assim, o modelo mostrou algumas limitações importantes: o recall da classe “caiu” permaneceu relativamente baixo, indicando que, mesmo com informações técnicas e objetivas, a rede não conseguiu identificar de maneira confiável os idosos que realmente sofreram quedas. Isso ocorre porque, embora as condições arquitetônicas sejam extremamente relevantes, elas não capturam fatores essenciais que influenciam a dinâmica real das quedas.

Na *cross-validation* com 5 partições, o desempenho médio foi de 60,0%, revelando redução leve de acurácia, mas com maior consistência entre as execuções. Isso indica que o modelo, embora não apresente ganho expressivo, mantém robustez quando avaliado em diferentes subconjuntos dos dados. A Figura 47 mostra a matriz de confusão da rede neural com o método *cross-validation* enquanto a Figura 48 mostra o *classification report* do mesmo.

Figura 47 – Matriz de confusão da rede neural com *cross-validation*



Fonte: O Autor

Figura 48 – *Classification report* da rede neural com *cross-validation*

	precision	recall	f1-score	support
0	0.47	0.46	0.47	41
1	0.68	0.71	0.70	69
micro avg	0.61	0.62	0.61	110
macro avg	0.58	0.59	0.58	110
weighted avg	0.60	0.62	0.61	110
samples avg	0.61	0.62	0.61	110

Fonte: O Autor

Os resultados das Redes Neurais no Cenário 3 mostram que as condições objetivas do

ambiente doméstico são, de fato, um componente importante do risco de queda, apresentando desempenho superior ao observado no Cenário 1 e parcialmente comparável ao Cenário 2. No entanto, assim como aconteceu com a Árvore de Decisão, a rede neural demonstrou que as informações arquitetônicas não são suficientes por si só para formar um modelo preditivo robusto.

Dessa forma, o Cenário 3 reforça a importância do ambiente físico na compreensão das quedas, mas também confirma que a integração entre diferentes tipos de dados é essencial para a construção de modelos mais completos e capazes de apoiar de maneira eficaz ações de prevenção em Gerontecnologia.

4.5.4 Conclusão Sobre o Cenário 3

A Tabela 10 apresenta uma comparação entre os modelos de Árvore de Decisão e Rede Neural aplicados ao Cenário 3, avaliados tanto na estratégia de *hold-out* quanto na *cross-validation*. Assim como nos cenários anteriores, a tabela destaca a precisão e o *recall* da classe “caiu”, além da acurácia geral, permitindo avaliar a capacidade dos modelos de identificar corretamente os idosos que já sofreram quedas.

Tabela 10 – Tabela comparativa dos modelos no cenário 3

Modelo	Precisão da classe caiu	<i>Recall</i> da classe caiu	Acurácia
Árvore de decisão <i>hold-out</i>	0,40	0,25	54,55%
Árvore de decisão <i>cross-validation</i>	0,26	0,17	50%
Rede Neural <i>hold-out</i>	0,67	0,50	72,73%
Rede Neural <i>cross-validation</i>	0,47	0,47	60%

Fonte: O Autor

Ao analisar os resultados da tabela, é possível observar que o desempenho dos modelos neste cenário foi moderado, situando-se entre o Cenário 1 e o Cenário 2. A acurácia global apresenta valores superiores aos observados no Cenário 1, indicando que os fatores arquitetônicos oferecem informações relevantes para o entendimento dos riscos de queda. No entanto, apesar de serem variáveis objetivas e diretamente relacionadas ao ambiente físico, os modelos ainda apresentaram dificuldades em identificar corretamente a classe “caiu”.

Assim como ocorreu nos cenários anteriores, o *recall* da classe “caiu” permaneceu limitado, resultando em um número expressivo de falsos negativos. Isso sugere que, embora o ambiente físico contribua para o risco de quedas, ele não captura sozinho toda a complexidade envolvida nesse tipo de acidente. A relação entre o idoso e o ambiente é influenciada também por fatores perceptivos, comportamentais e clínicos.

Na comparação entre *hold-out* e *cross-validation*, observa-se que os resultados foram estáveis, com pequenas variações entre as métricas. A *cross-validation*, como nos cenários anteriores, permitiu uma avaliação mais equilibrada do conjunto e apresentou resultados ligeira-

mente superiores em alguns casos, mas sem mudanças expressivas. Essa estabilidade destaca que o problema central não está na divisão dos dados, mas sim na limitação informacional do próprio cenário.

Dessa forma, conclui-se que o Cenário 3 não constitui um bom conjunto de variáveis para a predição de quedas. Embora forneça informações técnicas relevantes, seu uso exclusivo não gera desempenho suficiente para identificar corretamente os idosos que já caíram.

4.6 CONSIDERAÇÕES FINAIS SOBRE AS ANÁLISES REALIZADAS

As análises realizadas nos três cenários permitiram compreender, sob diferentes perspectivas, prever a ocorrência de quedas em ambientes domésticos. Cada conjunto de dados trouxe um tipo de informação complementar: o Cenário 1 concentrou-se no perfil clínico e demográfico dos idosos, o Cenário 2 abordou as percepções subjetivas dos idosos sobre o ambiente, e o Cenário 3 avaliou os aspectos técnicos do espaço físico, com base na análise de um arquiteto(a).

A combinação de atributos provenientes das percepções de segurança, conforto, iluminação e facilidade de locomoção mostrou-se especialmente eficaz. Essas variáveis traduzem tanto a experiência prática do idoso quanto a sua interpretação subjetiva do espaço. Em outras palavras, o modo como o idoso percebe o ambiente é um indicador preditivo mais sensível do que o ambiente medido de forma isolada.

Dessa forma, o Cenário 2 representa a melhor combinação de características para a predição de quedas entre os cenários analisados. Ele equilibra aspectos humanos e ambientais, permitindo que os algoritmos identifiquem relações sutis entre conforto, segurança percebida e propensão a acidentes. Essa constatação reforça a importância de considerar as dimensões subjetivas na análise de riscos domésticos, ampliando a aplicação da gerontecnologia para além de diagnósticos técnicos, em direção a modelos centrados na experiência do usuário idoso.

5 CONCLUSÃO

5.1 SÍNTESE DO TRABALHO

Este trabalho teve como propósito avaliar a aplicação de modelos de Inteligência Artificial na Gerontecnologia, com foco na utilização de técnicas de *machine learning* para prever quedas em ambientes domésticos de idosos. A pesquisa partiu de uma abordagem exploratória, reunindo revisão bibliográfica, coleta e preparação de dados, implementação e análise de modelos preditivos, especificamente Árvores de Decisão e Redes Neurais Artificiais, aplicados a diferentes cenários de avaliação.

Foram desenvolvidos três conjuntos de dados distintos: o Cenário 1, centrado em informações clínicas e demográficas dos idosos, o Cenário 2, baseado nas percepções dos próprios idosos sobre segurança, conforto e acessibilidade do ambiente, e o Cenário 3, composto pela análise técnica de um arquiteto(a) sobre as condições físicas das residências.

A partir da aplicação dos métodos de *hold-out* e *cross-validation*, avaliou-se o desempenho dos modelos considerando métricas como acurácia, precisão e *recall*. Os resultados evidenciaram que o Cenário 2 apresentou o melhor desempenho geral. Esse conjunto de dados demonstrou que a percepção subjetiva do idoso sobre o ambiente é um indicador relevante para prever quedas.

De modo geral, os objetivos específicos foram atingidos: identificaram-se os algoritmos mais adequados ao contexto da Gerontecnologia, implementou-se uma arquitetura experimental com dados reais, realizaram-se comparações entre métodos e cenários, e constatou-se a viabilidade de integrar IA e Gerontecnologia para prever a ocorrência de quedas em ambientes domiciliares dos idosos.

Assim, o objetivo geral foi alcançado integralmente, validando o potencial dos modelos de aprendizado supervisionado para aplicações voltadas à predição de quedas.

5.2 CONTRIBUIÇÃO DO TRABALHO PARA A ÁREA

Este estudo contribui para a área de Gerontecnologia aplicada à Inteligência Artificial ao propor uma metodologia de análise comparativa entre modelos e cenários, destacando a importância de integrar aspectos humanos e ambientais no desenvolvimento de sistemas preditivos. Os resultados reforçam que dados subjetivos, especialmente as percepções dos próprios idosos, podem oferecer melhor sensibilidade na detecção de risco de quedas do que medições puramente técnicas.

Ao evidenciar a viabilidade técnica do uso de algoritmos como Árvores de Decisão

e Redes Neurais em dados predominantemente subjetivos, este trabalho amplia o escopo metodológico tradicional encontrado na literatura, que costuma privilegiar dados coletados via sensores. Assim, contribui ao mostrar que abordagens de baixo custo e de fácil implementação também podem gerar modelos preditivos consistentes, especialmente quando estruturadas a partir da experiência direta vivenciada pelos participantes.

Além disso, ao estruturar o estudo em três cenários independentes, este trabalho oferece um método comparativo inédito, permitindo avaliar o peso relativo de:

- dados clínicos e demográficos.
- percepções subjetivas dos idosos.
- avaliações técnicas da arquitetura da residência.

Esse formato reforça a importância de incorporar diferentes perspectivas na construção de sistemas inteligentes voltados para a população idosa, especialmente em contextos de vulnerabilidade.

Por fim, ao identificar que o cenário baseado na percepção ambiental do idoso apresentou o melhor desempenho entre os modelos testados, este estudo contribui tanto para o avanço científico, ao destacar o valor preditivo de informações subjetivas, quanto para a prática profissional, sugerindo que instrumentos simples de avaliação podem ser úteis em políticas públicas, atendimentos domiciliares e soluções assistivas de baixo custo.

5.3 TRABALHOS FUTUROS

Do ponto de vista metodológico, este trabalho pode avançar rumo ao uso de algoritmos mais sofisticados, combinando diferentes técnicas de aprendizado de máquina para melhorar a precisão da classe “caiu”. A integração de dados provenientes de sensores, câmeras ou dispositivos vestíveis também pode ser uma direção promissora, aproximando a predição de quedas de soluções aplicáveis em tempo real.

Também é recomendada a exploração de outros métodos de aprendizado de máquina, como Random Forest e redes neurais mais profundas, permitindo comparar diferentes abordagens e identificar combinações mais eficazes para o problema estudado.

Além disso, abre-se caminho para o uso de sensores ambientais, dispositivos vestíveis e plataformas inteligentes para monitoramento contínuo. Esses recursos podem melhorar a detecção de riscos em tempo real e aproximar a modelagem computacional da aplicação prática.

Por fim, uma direção promissora é integrar os modelos desenvolvidos a sistemas de robótica assistiva, como robôs sociais ou de monitoramento, que podem auxiliar idosos em suas

rotinas e contribuir para a prevenção de quedas. Essa integração representa um passo importante para soluções mais completas na área de gerontecnologia.

REFERÊNCIAS

- Academia Brasileira de Letras. **Gerontecnologia**. 2024. Acesso em: 18 set. 2024. Disponível em: <<https://www.academia.org.br/nossa-lingua/nova-palavra/gerontecnologia>>.
- Amazon Web Services. **Reinforcement Learning**. 2024. Acesso em: 30 ago. 2024. Disponível em: <<https://aws.amazon.com/what-is/reinforcement-learning/#:~:text=Software%20actions%20that%20work%20towards,optimal%20outcomes%20in%20unseen%20environments>>.
- ARBIB, M. **Brains, Machines, and Mathematics**. Springer New York, 2012. ISBN 9781461247821. Disponível em: <<https://books.google.com.br/books?id=rYbTBwAAQBAJ>>.
- ARUNACHALAM, G. *et al.* Human-robot interaction in geriatric care: Rnn model for intelligent companionship and adaptive assistance. In: . [S.l.: s.n.], 2024. p. 1067–1073.
- ATTA, M. H. R. *et al.* Exploring the mediating influence of acceptance of change: A study on gerontechnology acceptance, mental well-being, and urban–rural disparities among older adults. **Geriatric Nursing**, v. 58, p. 324–335, 2024. ISSN 0197-4572. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0197457224001484>>.
- BANERJEE, A.; KUMAR, S. Artificial intelligence in healthcare. 2024.
- _____. Artificial intelligence in healthcare. 2024.
- BHAGAT, M. I. A. *et al.* Artificial intelligence in healthcare : A review. **International journal of scientific research in science, engineering and technology**, 2024.
- BOUMA, H. Gerontechnology : making technology relevant for the elderly. In: _____. **Gerontechnology**. Netherlands: IOS Press, 1992. (Studies in health technology and informatics), p. 1–5. ISBN 90-5199-072-3.
- CarePredict. **CarePredict - Smarter Senior Care**. 2024. Acesso em: 17 out. 2024. Disponível em: <<https://www.carepredict.com/>>.
- CENTER, P. R. **Older Adults and Technology Use**. 2021. Available at: <<https://www.pewresearch.org/internet/2014/04/03/older-adults-and-technology-use/>>.
- CHAN, N. H. **Time series : applications to finance**. [S.l.]: Wiley-Interscience, 2001.
- CHEN, L.-K. Artificial intelligence in medicine and healthcare. **Journal of Clinical Gerontology and Geriatrics**, Full Universe Integrated Marketing Limited, v. 9, n. 3, p. 77–78, 2018.
- CRAMM, J. M.; NIEBOER, A. P. Social cohesion and belonging predict the well-being of community-dwelling older people. **BMC Geriatrics**, Springer, v. 15, n. 1, p. 30, 2015.
- DEEP Learning-Based Big Data Analytics Model for Activity Monitoring of Elderly People. In: . [S.l.]: Lecture notes in electrical engineering, 2021. p. 589–599.
- DIGNUM, V. Responsible artificial intelligence: Designing ai for human values. **AI Society**, v. 33, n. 4, p. 1–10, 2018.

- DOMINGOS, P. A few useful things to know about machine learning. **Communications of the ACM**, ACM, v. 55, n. 10, p. 78–87, 2012. Disponível em: <<https://homes.cs.washington.edu/~pedrod/papers/cacm12.pdf>>.
- ESTATÍSTICA, I. B. de Geografia e. **Projeções da População do Brasil e das Unidades da Federação**. 2020. Disponível em: <<https://www.ibge.gov.br/>>.
- FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P. **Knowledge Discovery and Data Mining: Towards a Unifying Framework**. [s.n.], 1996. Disponível em: <<https://api.semanticscholar.org/CorpusID:5708816>>.
- FEARN, T. Sensitivity and specificity. **NIR News**, v. 20, p. 16, 2009. Disponível em: <<https://doi.org/10.1255/nirn.1132>>.
- FERRER, L. Analysis and comparison of classification metrics. **arXiv**, abs/2209.05355, 2022. Disponível em: <<https://doi.org/10.48550/arXiv.2209.05355>>.
- GHOSH, A. *et al.* Elderly fall detection using deep learning enabled internet of healthcare things. *Informa*, p. 276–288, 2024.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. Disponível em: <<https://www.deeplearningbook.org/>>.
- GRAAFMANS, J.; TAIPALE, V. Gerontechnology: A sustainable investment in the future. **Studies in Health Technology and Informatics**, v. 48, p. 3–6, 1998.
- GUEAIEB, W.; KARRAY, F.; SADDIK, A. E. A hybrid deep learning model for human activity recognition and fall detection for the elderly. In: . [S.l.: s.n.], 2023. p. 1–6.
- GYENNO Technologies. **GYENNO Spoon - Smart Stabilizing Spoon for Tremor Compensation**. 2024. Acesso em: 17 out. 2024. Disponível em: <<https://www.gyenno.com/>>.
- HAND, D. J.; CHRISTEN, P.; KIRIELLE, N. F*: an interpretable transformation of the f-measure. **Machine Learning**, v. 110, n. 3, p. 451–456, 2021. Disponível em: <<https://doi.org/10.1007/S10994-021-05964-1>>.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. 2nd. ed. Springer, 2009. Disponível em: <<https://web.stanford.edu/~hastie/ElemStatLearn/>>.
- HAYKIN, S. **Neural Networks and Learning Machines**. Pearson, 2009. (Pearson International Edition). ISBN 9780131293762. Disponível em: <<https://books.google.com.br/books?id=KCwWOAAACAAJ>>.
- HEALTH, M. **Digitize & Automate Care Programs**. 2024. Acesso em: 17 out. 2024. Disponível em: <<https://www.memorahealth.com/>>.
- HOXHA, V. Exploring the predictive power of ann and traditional regression models in real estate pricing: evidence from prishtina. 2023.
- HUANG, G.; OTENG, S. A. Gerontechnology for better elderly care and life quality: a systematic literature review. **European journal of ageing**, Springer, v. 20, n. 1, p. 27, 2023.
- IMAGING, N. I. of B.; BIOENGINEERING. **Computational Modeling**. 2020. Acesso em: 13 set. 2024, Disponível em: <<https://www.nibib.nih.gov/science-education/science-topics/computational-modeling>>.

JAIN, V.; TIWARI, S. K. Overview: machine learning. In: . [S.l.: s.n.], 2024. p. 130–144.

JAMES, G. *et al.* **An Introduction to Statistical Learning**. Springer, 2013. Disponível em: <<https://www.statlearning.com/>>.

JESI, V. E. *et al.* Advancements in sensor technology and computer vision for enhanced road safety and anomaly detection using machine learning approach. 2023.

JUNIOR, G. d. B. V. *et al.* Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. **Revista CPAQV**, v. 14, n. v14n2, p. 1, 2022. Disponível em: <<https://doi.org/10.36692/v14n2-01r>>.

KÄRKKÄINEN, T. On cross-validation for mlp model evaluation. In: **Artificial Intelligence and Soft Computing**. Springer, Berlin, Heidelberg, 2014. p. 291–300. Disponível em: <https://doi.org/10.1007/978-3-662-44415-3_30>.

KOHAVI, R.; PROVOST, F. Glossary of terms. **Machine Learning**, Springer, v. 30, n. 2-3, p. 271–274, 1998. Disponível em: <<https://link.springer.com/article/10.1023/A:1017181826899>>.

LEUNG, A. Y. M.; XU, X. Y. Gerontechnology. In: _____. **Encyclopedia of Gerontology and Population Aging**. Cham: Springer International Publishing, 2021. p. 2163–2168. ISBN 978-3-030-22009-9. Disponível em: <https://doi.org/10.1007/978-3-030-22009-9_1087>.

LUCIANO, G. Data visualization. **Disponível em: <<https://doi.org/10.59350/t0gft-0y216>>**, 2023.

LUGER, G. **Inteligência artificial**. Pearson Universidades, 2013. ISBN 9788581435503. Disponível em: <<https://books.google.com.br/books?id=gJNh0AEACAAJ>>.

LUNDBERG, S. M.; LEE, S. I. A unified approach to interpreting model predictions. In: **Advances in Neural Information Processing Systems**. [s.n.], 2017. v. 30. Disponível em: <<https://arxiv.org/abs/1705.07874>>.

LÂNG, K. *et al.* Artificial intelligence-supported screen reading versus standard double reading in the Mammography Screening with Artificial Intelligence trial (MASAI): a clinical safety analysis of a randomised, controlled, non-inferiority, single-blinded, screening accuracy study. **The Lancet Oncology**, Elsevier, v. 24, n. 8, p. 936–944, 2023. Disponível em: <[https://doi.org/10.1016/S1470-2045\(23\)00298-X](https://doi.org/10.1016/S1470-2045(23)00298-X)>.

McKinsey & Company. **How Retailers Can Keep Up with Consumers**. 2024. Accessed: 2024-08-30. Disponível em: <<https://www.mckinsey.com/industries/retail/our-insights/how-retailers-can-keep-up-with-consumers>>.

_____. **The Value of Getting Personalization Right—or Wrong—is Multiplying**. 2024. Accessed: 2024-08-30. Disponível em: <<https://www.mckinsey.com/capabilities/growth-marketing-and-sales/our-insights/the-value-of-getting-personalization-right-or-wrong-is-multiplying>>.

MEHTA, V. Artificial intelligence in medicine: Revolutionizing healthcare for improved patient outcomes. **Journal of Medical Research and Innovation**, v. 7, n. 2, p. e000292, 2023.

_____. Artificial intelligence in medicine: Revolutionizing healthcare for improved patient outcomes. **Journal of medical research and innovation**, v. 7, n. 2, p. e000292–e000292, 2023.

MISHRA, I. *et al.* Revolutionizing healthcare: The impact and growth of artificial intelligence(ai). **Deleted Journal**, v. 2, n. 07, p. 1875–1881, 2024.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997. ISBN 978-0-07-042807-2.

MOLNAR, C. Interpretable machine learning. In: **Explainable AI: Interpreting, Explaining and Visualizing Deep Learning**. Lulu.com, 2020. Disponível em: <<https://christophm.github.io/interpretable-ml-book/>>.

MyndYou. **MyndYou - Intelligent Cognitive Health Monitoring**. 2024. Acesso em: 17 out. 2024. Disponível em: <<https://www.myndyou.com/>>.

NAGARAJ, A. Supervised learning algorithms. In: . [S.l.]: BENTHAM SCIENCE PUBLISHERS, 2023. p. 23–75.

National Institute of Biomedical Imaging and Bioengineering. **Computational Modeling**. 2020. Acesso em: 13 set. 2024. Disponível em: <<https://www.nibib.nih.gov/science-education/science-topics/computational-modeling>>.

OLALEYE, V.; ODENIYI, O. A.; ALESE, B. Comparative analysis of predictive models using synthetic data for financial fraud detection. 2024.

PEDERSINI, P.; TOVANI-PALONE, M. R. Artificial intelligence in geriatric rehabilitation. **Topics in Geriatric Rehabilitation**, 2024.

PILOTTO, A. *et al.* Gerontechnology: Definitions and classification. In: _____. **Gerontechnology. A Clinical Perspective**. Cham: Springer International Publishing, 2023. p. 3–14. ISBN 978-3-031-32246-4. Disponível em: <https://doi.org/10.1007/978-3-031-32246-4_1>.

RADOJČIĆ, V. *et al.* Advancements in computer vision applications for traffic surveillance systems. **Sinergija**, 2024.

RAHARDJA, D. Statistical time-series forecast error and bias assessment using hold-out samples and a single benchmark (data-reduction) scoring metric. **Journal of Statistics and Management Systems**, v. 27, n. 3, p. 569–578, 2024. Disponível em: <<https://doi.org/10.47974/jsms-974>>.

RAOTOLE, A. *et al.* Wellbe: An intelligent elderly care and well-being monitoring system using deep learning. p. 1–6, 2024.

ROBINSON, F.; NEJAT, G. A deep learning human activity recognition framework for socially assistive robots to support reablement of older adults. In: . [S.l.: s.n.], 2023. p. 6160–6167.

SARKER, A. *et al.* Credit card fraud detection using machine learning techniques. **Journal of Computer and Communications**, v. 12, p. 1–11, 2024.

SAÚDE, O. M. da. **A Decade of Healthy Ageing: 2021-2030**. 2021. Disponível em: <<https://www.who.int/publications/i/item/9789240069052>>.

SHAGUN. The explainable neural network. **Medium**, 2023. Acessado em: 22 set. 2024. Disponível em: <<https://medium.com/@shagunm1210/the-explainable-neural-network-8f95256dcddb>>.

SHRIVASTAVA, A. Artificial intelligence (ai): Evolution, methodologies, and applications. **International Journal For Science Technology And Engineering**, International Journal for Research in Applied Science and Engineering Technology (IJRASET), v. 12, n. 4, p. 5501–5505, 2024.

SIMON, G.; ALIFERIS, C. F. Evaluation. In: **Artificial Intelligence in Medicine**. Springer International Publishing, 2024. p. 415–476. Disponível em: <https://doi.org/10.1007/978-3-031-39355-6_9>.

SUNDGREN, S. *et al.* Ethical issues related to the use of gerontechnology in older people care: A scoping review. **Nursing ethics**, SAGE Publications Sage UK: London, England, v. 27, n. 1, p. 88–103, 2020.

SUPERVISED Machine Learning a Brief Survey of Approaches. **Al-Iraqia Journal of Scientific Engineering Research**, 2023.

SURESHKUMAR, T. *et al.* Envisioning educational success through advanced analytics and intelligent performance prediction. In: **2024 International Conference on Communication and Signal Processing (ICCSP)**. IEEE, 2024. p. 1649–1654. Disponível em: <<https://doi.org/10.1109/iccsp60870.2024.10544164>>.

THOMAS, T.; VIJAYARAGHAVAN, A. P.; EMMANUEL, S. Introduction to machine learning. In: . [S.l.]: Springer, Singapore, 2019. p. 17–36.

TOTHÄFZAN, H. F. The contribution of statistical models in the field of real estate valuation. **Timisoara Journal of Economics and Business**, v. 15, n. 1, p. 111–126, 2022.

TOYOTA. **Human Support Robot (HSR)**. 2012. Acessado em: 3 de outubro de 2024. Disponível em: <<https://global.toyota/en/detail/125275>>.

TSAY, R. S. **Financial Time Series**. [S.l.]: Wiley, 2014. 1-23 p.

VALKENBORG, D. *et al.* Supervised learning. **American Journal of Orthodontics and Dentofacial Orthopedics**, v. 164 1, n. 1, p. 146–149, 2023.

VANKOV, E.; GADHOUMI, K. Supervised learning. In: . [S.l.]: Informa, 2024. p. 272–301.

VINCI, G. Unsupervised learning. In: . [S.l.]: Informa, 2024. p. 251–271.

WALACH, J.; FILZMOSER, P.; HRON, K. Data normalization and scaling: Consequences for the analysis in omics sciences. In: **Comprehensive Analytical Chemistry**. Elsevier, 2018. v. 82, p. 165–196. Disponível em: <<https://doi.org/10.1016/BS.COAC.2018.06.004>>.

WANG, Y.; BI, X.; QU, A. **A Logistic Factorization Model for Recommender Systems With Multinomial Responses**. 2020.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data Mining: Practical Machine Learning Tools and Techniques**. 4th. ed. Morgan Kaufmann, 2016. Disponível em: <https://books.google.com/books/about/Data_Mining.html?id=1SylCgAAQBAJ>.

ZHANG, W.; WANG, Y.; XU, J. Artificial intelligence internet of things for the elderly: From assisted living to health-care monitoring. **IEEE Signal Processing Magazine**, IEEE, v. 38, n. 4, p. 110–117, 2021. Disponível em: <<https://ieeexplore.ieee.org/document/9467679>>.

ANEXO A – DECLARAÇÃO DO USO DE IA

Durante a preparação deste trabalho, o autor utilizou ChatGPT versão 5.1 para corrigir erros de código e melhorar textos escritos pelo autor. Após o uso desta ferramenta, o autor revisou e editou o conteúdo em conformidade com o método científico e assume total responsabilidade pelo conteúdo da publicação.

**ANEXO B – INSTRUMENTO DE AVALIAÇÃO ERGONÔMICA DA
MORADIA DO IDOSO**

INSTRUMENTO DE AVALIAÇÃO ERGONÔMICA DA MORADIA DO IDOSO

I FICHA CADASTRAL

Avaliador: _____ Data: ___/___/___ Hora: _____
Nome do Participante: _____ Código: _____
Endereço: Rua/Av. _____ n° _____ Complemento (ap./ bloco): _____
Bairro: _____ Cidade: _____ CEP: _____ Telefone: () _____
RG: _____ e-mail: _____

DADOS SOCIODEMOGRÁFICOS

(P01) Data de nascimento: ___/___/___ Idade: _____ (anos completos).

(P02) Sexo:

() 1. Feminino () 2. Masculino

(P03) Estado Civil:

() 1. Solteiro(a) () 2. Casado(a) () 3. Divorciado(a) ou separado(a)
() 4. Viúvo(a) () 5. União Estável () 6. Outros

(P04) Grau de Escolaridade:

() 1. Analfabeto () 2. Fundamental incompleto () 3. Fundamental completo
() 4. Médio incompleto. () 5. Médio compl. () 6. Superior incompl. () 7. Superior completo

(P05) Nível de renda familiar*:

() 1. Até 2 salários mín. () 2. De 2 a 10 salários mín. () 3. Acima de 10 salários mín.
*considerando salário mínimo no valor de R\$ 1.212,00

(P06) Situação profissional do(a) idoso(a):

() 1. Ativo(a) () 2. Inativo(a) (desempregado(a)) () 3. Afastado(a)/em licença saúde
() 4. Aposentado(a) () 5. Aposentado(a) ou afastado mas segue trabalhando

(P07) Tipo de Profissão: (a que exerceu por mais tempo na vida) _____

(P08) Tempo sem trabalhar* (se atualmente está aposentado/afastado/inativo) _____ (anos completos).

*Se estiver trabalhando, responder "zero"

DADOS CLÍNICOS E HÁBITOS DE VIDA

(P09a) Tem (ou teve) alguma doença recente?

() 1. Não () 2. Sim.

(P09b) **CF- b435** Se na pergunta anterior marcou "sim", indique a(s) doença(s) que tem (ou teve) recentemente:

() 1. Hipertensão ("pressão alta") () 2. Doença cardíaca () 3. Diabetes
() 4. Câncer () 5. Depressão () 6. Derrame cerebral (AVC)
() 7. Doenças autoimunes (reumáticas) () 8. Doença pulmonar () 9. Outra. Qual*?: _____

*questionar se fez cirurgia recente, ou se esteve internado, se teve comorbidade por COVID ou outra doença, podendo ser neurológica, renal...

(P09c) **BF - b134** Tem problemas para dormir?

() 1. Demora para iniciar o sono
() 2. Tem dificuldades em manter o sono durante a noite (insônia)
() 3. Hiper-sônia (muito sono durante o dia)
() 4. Narcolepsia (fraqueza muscular súbita, alucinações, pesadelos)
() 5. Não tem problemas para dormir, sono de boa qualidade

(P09d) Indique se pratica algum tipo de atividade física dos mencionados abaixo:

() Não pratica () Caminhadas leves () Esportes e atividades físicas moderados
() Esportes ou trabalhos físicos que exigem força e energia vigorosos, como cortar a grama, jardinagem, faxina, carregar peso, lavar roupas

(P09e) **BF b455, b460** Quando faz atividades ou exercícios que exijam esforço, apresenta alguma destas sensações ou dificuldades?

() Falta de ar () Falta de resistência ao exercício, cansa rápido () pressão alta
() Fadiga ou muito cansaço () Falta de vigor ou força () palpitações

(P09e) BF b620, b630 Indique se possui as seguintes dificuldades com o sistema urinário:

- | | |
|--|--|
| <input type="checkbox"/> Reflexo, escapes de urina ao tossir ou espirrar | <input type="checkbox"/> Incontinência urinária contínua |
| <input type="checkbox"/> Sensação de bexiga cheia ou que não urinou suficiente | <input type="checkbox"/> Poliúria (excesso de urina) |
| <input type="checkbox"/> Retenção e dificuldades para urinar | <input type="checkbox"/> Urgência para urinar |

(P09f) BS -s110, s320, s430, s610, s720, s750, s770 Indique se a estrutura de alguma das partes do corpo físico citadas abaixo foi lesionada ou não está íntegra, e marque "X" no problema:

Parte do corpo	0 Sem mudanças na estrutura	1 Ausência total da estrutura	2 Ausência parcial	3 Parte adicional	4 Dimensão fora do comum	5 Descontinuidade	6 Posição desviada	7 Mudanças qualitativas na estrutura	8 Não especificado	9 Não se aplica
a) Cérebro										
a) Boca										
b) Sistema respiratório										
c) Sistema urinário										
d) Ombro										
e) Membros inferiores (pernas).										
f) Outros relacionados ao movimento										

(P09f) AP - d230, d360, d410, D415, d420, d450, d460, d465, d510, d520, d530, d550, d570, d760, d860. Marque "x" no grau de dificuldade apresentado no desempenho* e na capacidade** que o (a) idoso(a) tem em:

*Desempenho funcional: o que o indivíduo consegue fazer no seu ambiente habitual, ou seja, no contexto real em que vive.

**Capacidade física representa a habilidade de um indivíduo para executar uma tarefa ou ação em um ambiente padronizado e controlado (CIF, 2003).

Atividade	Categoria	0 Sem dificuldade	1 Pouca dificuldade	2 Dificuldade moderada	3 Dificuldade severa	4 Dificuldade total	8 Não especificado	9 Não se aplica
a) Organizar a rotina do dia a dia	Desempenho							
	Capacidade							
b) Usar técnicas e meios de comunicação (telefone ou outros)	Desempenho							
	Capacidade							
c) Mudar de posição (levantar da cadeira, deitar na cama, ajoelhar-se, agachar-se)	Desempenho							
	Capacidade							
d) Manter a posição do corpo (sentado ou de pé)	Desempenho							
	Capacidade							
e) Mover-se de uma superfície à outra escorregando ou deslizando (por ex. da cadeira para a cama) sem mudar a posição do corpo	Desempenho							
	Capacidade							
f) Caminhar (para a frente, para o lado, para trás)	Desempenho							
	Capacidade							
g) Mover-se usando equipamentos (skate, cadeira de rodas, andador, muletas, bastão...)	Desempenho							
	Capacidade							
h) Lavar a si próprio em qualquer ambiente (sem ser necessariamente sua casa)	Desempenho							
	Capacidade							
i) Cuidar de partes do corpo que exigem mais do que lavar (corte de unhas, pele, cabelos...)	Desempenho							
	Capacidade							
j) Ir ao banheiro (defecar, urinar)	Desempenho							
	Capacidade							
k) Alimentar-se (incluindo fora de casa)	Desempenho							
	Capacidade							
l) Cuidar da própria saúde e bem-estar (manter-se confortável, aquecido, com boa dieta, ir ao médico)	Desempenho							
	Capacidade							
m) Criar e manter laços familiares	Desempenho							
	Capacidade							
n) Realizar transações econômicas simples (lidar com dinheiro, compras, conta bancária)	Desempenho							
	Capacidade							

(P10a) Toma medicamentos atualmente? () 1. Não () 2. Sim.

(P10b) Se na pergunta anterior marcou “sim”, escreva quais medicamentos toma atualmente:

(P11a) Tem problemas de visão?

() 1. Não () 2. Sim

(P11b) Usa óculos?

() 1. Não () 2. Sim

(P12) Tem problemas de audição?

() 1. Não () 2. Sim

(P13a) Usa algum destes aparelho de TA?

() 1. Bengala () 2. Andador () 3. Muletas () 4. Cadeira de rodas
() 5. Outro. Qual? (Aparelho auditivo, órtese, etc) _____ () 6. Nenhum (não usa)

(P13b) Se necessita usar algum aparelho de TA, mas prefere não usar ou tirar por algum motivo, em qual local isso ocorre? *Pergunta somente para usuários de TA

() 1. Dentro de casa. Por quê? _____

() 2. Quando sai de casa. Por quê? _____

(P13c) Se você necessita usar algum aparelho de TA, mas prefere não usar, tirar, ou abandonar seu uso, indique o motivo: *Pergunta somente para usuários de TA

- () 1. Prefere usar, não tem problemas com a TA que usa
() 2. Acha que não necessita usar, pois não atingiu o objetivo que esperava
() 2. Já usou, mas obteve alta médica e não precisa mais
() 3. Necessita usar, mas ainda não recebeu, ou está demorando para receber
() 4. Não consegue usar pois não atende mais suas necessidades
() 5. Alto custo (muito cara)
() 6. Difícil de calçar/colocar/vestir/higienizar
() 7. Falta assistência/explicação de como usar, ou difícil acesso a atendimento quando tem dúvidas
() 8. Desconfortável (pesado, quente, cheiro desagradável, tamanho inadequado, rigidez inadequada)
() 9. Causa dor, alergia ou lesão (machuca)
() 10. Estética desagradável (feia, chama a atenção, sente-se alvo de preconceito quando usa)
() 11. Material de má qualidade (quebrou/deformou)
() 12. Sente-se vulnerável a acidentes, insegurança em usar
() 13. Tem dificuldades de locomoção (sem dinheiro, tempo ou pela dificuldade da locomoção em si em meios de transporte público ou privado) até o local da manutenção/revisão que impedem uma manutenção e revisão periódica
() 14. Gostaria de poder dar minha opinião sobre a escolha da TA que terei que usar, mas não me foi dada essa opção
() 15. Outro: _____

(P14a) Costuma consumir de bebida alcoólica?

() 1. Não () 2. Sim () 3. Progresso

(P14b) Costuma fumar?

() 1. Não () 2. Sim () 3. Progresso

(P15) Quantas pessoas moram nesta residência*:

*Responder incluindo o idoso na contagem de número de residentes

(P16a) Indicar quem mora com o idoso(a)*:

() 1. Mora sozinho(a) () 2. Esposo(a) () 3. Filhos

() 4. Familiares () 5. Cuidador () 7. Outros: _____

(P16b) O(A) idoso(a) possui animal de estimação (próprio, que lhe faça companhia) na residência?

() 1. Não () 2. Sim

(P17) Há quanto tempo mora nesta residência: _____ (anos completos)

DADOS DA HABITAÇÃO

(A01) A residência é:

1. Própria 2. Alugada 3. Outro (emprestada): _____

(A02) Tipo de residência:

1. Casa 2. Apartamento 3. Outro (Kitnet, Anexo, Edícula): _____

(A03) Área da residência (aproximadamente): _____ m²

(A04) Número de pavimentos da residência: _____ pavimentos.

(A05) Número de cômodos da residência: _____ cômodos.

(A06a) Número de quartos (de dormir) da residência: _____ quartos.

(A06b) Para se locomover até o quarto de dormir, o(a) idoso(a) necessita usar:

rampa escada não necessita, é no piso térreo e de fácil acesso.

(A07) Número de banheiros da residência: _____ banheiros.

(A08) Quantos banheiros são efetivamente utilizados pela pessoa idosa: _____ banheiros.

(A09) Tem mais de uma cozinha ou local para cozinhar na residência?

1. Não 2. Sim. Se sim, qual o(a) idoso(a) utiliza? _____

(A10) O acesso a residência é feito por escada externa ou rampa?

1. Não 2. Sim. Se sim, descreva: _____

INVENTÁRIO DE QUEDAS

(P18) Nos últimos 12 meses o(a) Sr(a) caiu alguma vez na sua casa (seja no interior ou no exterior da casa)?

1. Não 2. Sim. Se Sim, quantas vezes? ____ Onde? _____

(P19) Motivo da queda:

1. Falta de atenção 2. Dor 3. Fraqueza nas pernas 4. Mal estar súbito

5. Piso escorregadio 6. Tropeçou em degrau ou soleira 7. Obstáculo(s) no piso

8. Tropeçou em tapete 9. Tropeçou em animais

10. Outros (subiu no banquinho ou cadeira, local escuro, não tinha onde segurar-se, caiu da cama, etc):

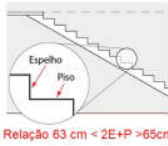

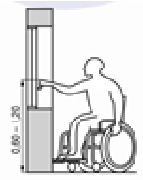
(P20) Você se sente seguro na sua casa (em relação a riscos e acidentes)?

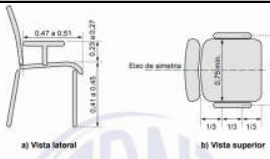

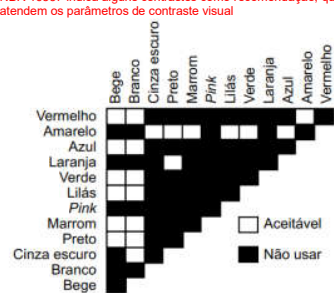
1. Não 2. Sim.

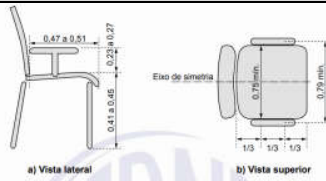

Se não, por quê?

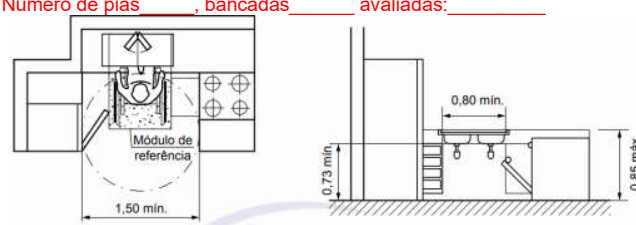

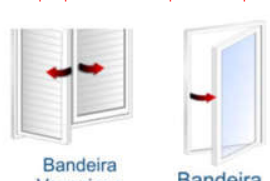
II FERRAMENTA PARA AVALIAÇÃO DA RESIDÊNCIA

(Materiais: 1. Câmera fotográfica; 2. Trena articulada, 3. Trena de infravermelho, 4. Decibelímetro, 5. Luxímetro; 6. Termômetro/higrômetro, 7. Paquímetro, 8. Prancheta e 9. Calculadora e 10. Guarda pó, crachá, caneta e TCLE).





































































































<p>Avalie se os itens a seguir atendem aos critérios estabelecidos. Comente o porquê em caso de atendimento parcial ou não atendimento.</p> <p>Observação:</p> <p>1. Se há mais de cinco itens para avaliar, escolher os piores (com a situação mais grave)</p> <p>2. Se há menos de cinco riscar os itens que sobraram.</p>	Não atende	Atende pouco	Atende razoavelmente	Atende muito	Atende totalmente
GERAL	0 %	25 %	50 %	75 %	100 %
<p>A11. Na casa, todas as soleiras das portas e as mudanças de piso (diferentes materiais) estão adequadas (apresentam desníveis inferiores a 2,5 cm, de modo que não favoreçam a ocorrência de tropeços).</p> <p>Soleira:</p> <p>1 2 3 4 5 Critério:</p> <p>() () () () () Altura da soleira \leq 2,5 cm</p> <p>Nº de soleiras avaliadas: _____</p> <p style="text-align: right;">BIZERRA et al., 2014 NETO; CARRÉRA, 2013 STAMATO, 2007</p>					
<p>A12. Na casa, todas as escadas (mais de 2 degraus é considerado como escada) têm corrimãos em ambos os lados, seguros, firmes, com boa empunhadura e que continuam nos patamares</p> <p>Escada:</p> <p>1 2 3 4 5 Critérios:</p> <p>() () () () () Deve ter corrimão em ambos os lados</p> <p>() () () () () Diâmetro da empunhadura (entre 3,0 e 4,5cm) (NBR9050)</p> <p>() () () () () Distância mínima em relação à parede: 4,0cm (NBR9077)</p> <p>() () () () () Altura do corrimão: entre 80 a 92cm (NBR9077).</p> <p>() () () () () Prolongamento do corrimão: 30cm (NBR9077).</p> <p>() () () () () Altura mínima guarda corpo: 1,10 m (NBR 14718).</p> <p>Nº de escadas avaliadas: _____</p> <p style="text-align: right;">REIS, 2014, SCHIAVETO, 2000</p>					
<p>A13. Na casa, todos as escadas (mais de 2 degraus é considerado como escada) têm os degraus robustos (firmes, fortes), não estão deteriorados ou quebrados.</p> <p>Escada:</p> <p>1 2 3 4 5 Critérios:</p> <p>() () () () () Degraus firmes e fortes (não deteriorados ou quebrados)</p> <p>() () () () () Degraus possuem revestimento antiderrapante</p> <p>() () () () () Piso (P) do degrau deve ter entre 28 e 32cm (ver figura)</p> <p>() () () () () Espelho (E) do degrau deve ter entre 16 e 18cm (ver figura).</p> <p>Nº de escadas avaliadas: _____</p> <p style="text-align: right;">LIMA; CESÁRIO, 2014; OMS, 2010; SBGG, 2008; STAMATO, 2007, NBR 9050</p> 					
<p>A14. Na casa, todas as portas têm largura adequada (\geq a 80 cm).</p> <p>Porta</p> <p>1 2 3 4 5 Critério:</p> <p>() () () () () Largura da porta \geq 80 cm</p> <p>Nº de portas avaliadas: _____</p> <p style="text-align: right;">NBR 9050, 2015; BARROS, 2000; NETO, CARRÉRA, 2013</p>					
<p>A15. Na casa, todas as portas abrem facilmente.</p> <p>Portas</p> <p>1 2 3 4 5 Critérios:</p> <p>() () () () () Maçanetas das portas devem ser do tipo alavanca (ou oval), possibilitando sua operação em um único movimento sem exigir demasiado esforço (NBR 9050). Maçaneta tipo bola não atende.</p> <p>() () () () () Altura do chão até a maçaneta (entre 0,90 m a 1,10 m).</p> <p>() () () () () Se tiver puxador horizontal, deve estar à altura 0,40m.</p> <p>() () () () () Os puxadores devem ter comprimento igual à metade da largura da porta, e estarem instalados a uma distância de 10 cm da face onde se encontra a maçaneta (NBR 9050)</p> <p>Nº de portas avaliadas: _____</p> <p style="text-align: right;">NBR 9050, 2015; BARROS, 2000</p> 					
<p>A16. Na casa, todas as janelas são fáceis de abrir e fechar.</p> <p>Janelas</p> <p>1 2 3 4 5 Critérios:</p> <p>() () () () () Cada folha ou módulo de janela deve poder ser operado com um único movimento, utilizando apenas uma das mãos, e os comandos devem ter a altura adequada (ver figura)</p> <p>Nº de janelas avaliadas: _____</p> <p style="text-align: right;">NBR 9050, 2015; BARROS, 2000</p> 					









































SALA (cont)	0 %	25 %	50 %	75 %	100 %
<p>A25. Na sala, todas as cadeiras e móveis para sentar são adequadas para as pessoas sentarem e levantarem de forma segura e fácil.</p> <p>Móveis para sentar-se</p> <p>1 2 3 4 5 Critérios:</p> <p>() () () () () Sem rodinhas</p> <p>() () () () () Com encosto</p> <p>() () () () () Estrutura firme (estrutura não balança quando se senta)</p> <p>() () () () () Altura adequada para cadeiras = 45 ± 2 cm (se estiver mais alto ou mais baixo é inadequado)</p> <p>Número de cadeiras avaliadas: _____</p>  <p>Figura 27 – Dimensões para assentos de pessoas obesas BARROS, 2000 FABRÍCIO; RODRIGUES; COSTA JUNIOR, 2004 LOPES et al., 2007 LIMA; CESÁRIO, 2014; REIS, 2014 NBR 9050:2020</p>					
<p>A26. Na sala, todos os móveis são resistentes, com cantos arredondados e sem partes de vidro que possam causar acidentes.</p> <p>Móveis:</p> <p>1 2 3 4 5 Critérios:</p> <p>() () () () () móveis sem cantos vivos, ou partes de vidro que possam causar acidentes</p> <p>BARROS, 2000 LOPES et al., 2007 STAMATO, 2007, NBR 9050:2020</p>					
<p>A27. Na sala, há pelo menos uma janela que permita uma iluminação natural adequada (conforme a NBR 15575:2013):</p> <p>Janelas</p> <p>1 2 3 4 5 Critérios:</p> <p>() () () () () Sem pontos de obstrução de luz ou que impeçam a passagem de luz</p> <p>() () () () () Sem excesso de luz ou que provoquem ofuscamento</p> <p>() () () () () Estrutura firme</p> <p>Nº de janelas avaliadas: _____</p> <p>NBR 15575:2013 BARROS, 2000 NETO; CARRÉRA, 2013 WHO, 2005 OMS, 2010 REIS, 2014 SCHIAVETO, 2008 STAMATO, 2007. NBR 15575:2013</p>					
<p>A28. Na sala, a localização, o tipo e o tamanho das janelas são adequados para favorecer uma ventilação natural*. *Obs. Códigos de obras brasileiros apresentam exigências para iluminação natural que estão relacionadas com as áreas de aberturas mínimas em função da área de piso de cada ambiente. Código de Obras do Distrito Federal exige área de abertura de 1/8 da área de piso para ambientes de permanência prolongada</p> <p>Janelas</p> <p>1 2 3 4 5 Critérios (situação ideal):</p> <p>() () () () () Localização no centro da parede oposta à porta</p> <p>() () () () () Permite 100% abertura (ver figura)</p> <p>() () () () () Área igual ou superior a 1/8 da área do piso.</p> <p>Área Janela 1 (m²) / Área Piso (m²) = _____ / _____ = _____</p> <p>Área Janela 2 (m²) / Área Piso (m²) = _____ / _____ = _____</p> <p>Área Janela 3 (m²) / Área Piso (m²) = _____ / _____ = _____</p> <p>NBR 15575:2013 BARROS, 2000 NETO; CARRÉRA, 2013 WHO, 2005 OMS, 2010 REIS, 2014 SCHIAVETO, 2008 STAMATO, 2007. Fernandes, J. T. (2009). Código de Obras e Edificações do DF: inserção de conceitos bioclimáticos, conforto térmico e ef. energética.</p> 					
<p>QUARTO (utilizado pelo idoso) medida: _____ * _____ = _____ m²</p>	0 %	25 %	50 %	75 %	100 %
<p>A29. No quarto, não há piso irregular ou escorregadio (encerado) que possa causar tropeços ou escorregões.</p> <p>Piso do quarto Critério:</p> <p>(). Se o piso for totalmente regular, sem nenhum tipo de desnível ou peças soltas que possam causar tropeços, e se não for escorregadio (testar)</p> <p>ARAÚJO et al., 2008; BIZERRA et al., 2014; CORREIA et al., 2003; CRUZ et al., 2012; FABRÍCIO; RODRIGUES; COSTA JUNIOR, 2004; PAULA, 2010; PERRACINI, 2005; SCHIAVETO, 2008; WHO, 2005. ABNT 15575-2013</p>					
<p>A30. No quarto, não há piso muito brilhante ou com padrão que possa causar desconforto ou confusão visual (analisar a superfície a uma altura aprox. 25 cm sob vários ângulos a olho nu).</p> <p>Piso do quarto Critério:</p> <p>() Se o piso for totalmente sem alteração de cor, brilho ou reflexo na luz artificial ou do dia).</p> <p>MILANI, 2014 NETO; CARRÉRA, 2013 STAMATO, 2007. ABNT 15575-2013</p>					
<p>A31. No quarto, há uma boa relação entre a área de circulação no cômodo e os móveis existentes no local, proporcionando um caminho fácil e desobstruído através do ambiente (não há desordem, cabos, fios, brinquedos e outras coisas para tropeçar).</p> <p>Quarto: Critério</p> <p>() Há espaço ≥ 50 cm para circulação mínima entre o mobiliário e/ou paredes</p> <p>ARAÚJO et al., 2008 BARROS, 2000 CRUZ et al., 2012 LIMA; CESÁRIO, 2014 LOPES et al., 2007 NETO; CARRÉRA, 2013 STAMATO, 2007 VILLAROUÇO; MONT'ALVÃO, 2011. ABNT NBR 15575-1:2013</p>					
<p>A32. No quarto, as cores de todas as paredes e do piso são claras e há um bom contraste entre eles facilitando a diferenciação (inclusive com os móveis).</p> <p>Quarto: Cor paredes (incluindo portas e janelas) vs piso: _____ vs _____ = () aceitável</p>  <p>Figura 10 – Contrastes recomendados BARROS, 2000 VILLAROUÇO; MONT'ALVÃO, 2011 ABNT NBR 9050:2020) (ABNT NBR 16537:2016</p>					
























































QUARTO (cont)	0 %	25 %	50 %	75 %	100 %
<p>A33. No quarto, a cama e todas as cadeiras e móveis para sentar são adequadas para as pessoas sentarem (ou deitarem, no caso da cama) e levantarem de forma segura e fácil.</p> <p>Móveis para sentar-se</p> <p>1 2 3 4 5 Critérios:</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Sem rodinhas</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Com encosto</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Estrutura firme</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Altura adequada = 45 ± 2 cm e altura e adequada da cama 46 cm.</p> <p>Nº de cadeiras avaliadas: _____</p> <div style="text-align: right;">  <p>Figura 27 – Dimensões para assentos de pessoas obesas</p> </div> <p>BARROS, 2000 FABRÍCIO; RODRIGUES; COSTA JUNIOR, 2004 LOPES et al., 2007 LIMA; CESÁRIO, 2014 REIS, 2014, NBR 9050:2020</p>					
<p>A34. No quarto, todos os móveis são resistentes, com cantos arredondados e sem partes de vidro que possam causar acidentes.</p> <p>Móveis:</p> <p>1 2 3 4 5 Critérios:</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> móveis sem cantos vivos, ou partes de vidro que possam causar acidentes</p> <p>BARROS, 2000 LOPES et al., 2007 STAMATO, 2007, NBR 9050:2020</p>					
<p>A35. No quarto, todas as gavetas e prateleiras (inclusive cabideiros dos armários/roupeiros) estão a uma altura entre 0,30 e 1,80 m do piso.</p> <p>Todas as Gavetas (marcar X se o critério foi atendido por <u>todas as gavetas</u>)</p> <p><input type="checkbox"/> altura entre 0,30 e 1,80m do piso.</p> <p>Nº de gavetas avaliadas: _____</p> <p>Todas as prateleiras, cabideiros e armários (marcar X se o critério foi atendido por <u>todos</u>):</p> <p><input type="checkbox"/> altura entre 0,30 e 1,80m do piso.</p> <p>Nº de prateleiras avaliadas: _____</p> <p>LIMA; CESÁRIO, 2014 REIS, 2014 SBGG, 2008 SCHIAVETO, 2008 STAMATO, 2007; NBR 9050:2020</p>					
<p>A36. No quarto, há pelo menos uma janela que permita uma iluminação natural adequada (conforme a NBR 15575:2013).</p> <p>Janelas</p> <p>1 2 3 4 5 Critérios:</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Sem pontos de obstrução de luz ou que impeçam a passagem de luz</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Sem excesso de luz ou que provoquem ofuscamento</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Estrutura firme</p> <p>Nº de janelas avaliado: _____</p> <p>NBR 15575:2013 BARROS, 2000 NETO; CARRÉRA, 2013 WHO, 2005 OMS, 2010 REIS, 2014 SCHIAVETO, 2008 STAMATO, 2007, NBR 15575:2013</p>					
<p>A37. No quarto, a localização, o tipo e o tamanho das janelas favorecem boa ventilação*.</p> <p>*Obs. Códigos de obras brasileiros apresentam exigências para iluminação natural que estão relacionadas com as áreas de aberturas mínimas em função da área de piso de cada ambiente. Código de Obras do Distrito Federal exige área de abertura de 1/8 da área de piso para ambientes de permanência prolongada.</p> <p>Janelas</p> <p>1 2 3 4 5 Critérios (situação ideal):</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Localização no centro da parede oposta à porta</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Permite 100% abertura (ver figura)</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Área igual ou superior a 1/8 da área do piso.</p> <p>Área Janela 1 (m²) / Área Piso (m²) = _____ / _____ = _____</p> <p>Área Janela 2 (m²) / Área Piso (m²) = _____ / _____ = _____</p> <p>Área Janela 3 (m²) / Área Piso (m²) = _____ / _____ = _____</p> <p>NBR 15575:2013 BARROS, 2000 NETO; CARRÉRA, 2013 WHO, 2005 OMS, 2010 REIS, 2014 SCHIAVETO, 2008 STAMATO, 2007, Fernandes, J. T. (2009). Código de Obras e Edificações do DF: inserção de conceitos bioclimáticos, conforto térmico e ef. Energética</p> <div style="text-align: right;">  </div>					
<p>BANHEIRO (utilizado pelo idoso) _____ * _____ = _____ m²</p>	0%	25 %	50 %	75 %	100 %
<p>A38. No banheiro, não há piso irregular ou escorregadio que possa causar tropeços ou escorregões.</p> <p>Piso: Critério:</p> <p><input type="checkbox"/> Se o piso for totalmente regular, sem nenhum tipo de desnível ou peças soltas que possam causar tropeços, e se não for escorregadio (testar)</p> <p>ARAÚJO et al., 2008 BIZERRA et al., 2014 CORRÉIA et al., 2003 CRUZ et al., 2012 FABRÍCIO; RODRIGUES; COSTA JUNIOR, 2004 PAULA, 2010 PERRACINI, 2005 SCHIAVETO, 2008 WHO, 2005; NBR 9050:2020, ABNT 15575-2013</p>					
<p>A39. No banheiro, não há piso muito brilhante ou com padrão que possa causar desconforto ou confusão visual (analisar a superfície a uma altura aprox. 25 cm sob vários ângulos a olho nu)</p> <p>Banheiro Critério:</p> <p><input type="checkbox"/> Piso totalmente sem alteração de cor, brilho ou reflexo na luz artificial ou do dia).</p> <p>MILANI, 2014 NETO; CARRÉRA, 2013 STAMATO, 2007, ABNT 15575-2013</p>					
<p>A40. No banheiro, há uma boa relação entre a área de circulação no cômodo e os móveis e louças sanitárias, proporcionando um caminho fácil e desobstruído através do ambiente (não há desordem, tapete, cabos, fios, roupas e outras coisas para tropeçar).</p> <p>Banheiro: Critério</p> <p><input type="checkbox"/> Área de circulação ≥ 40cm na parte frontal ao lavatório, vaso e bidê</p> <p>ARAÚJO et al., 2008 BARROS, 2000 CRUZ et al., 2012 LIMA; CESÁRIO, 2014 LOPES et al., 2007 NETO; CARRÉRA, 2013 STAMATO, 2007 VILLAROUÇO; MONTALVÃO, 2011, ABNT NBR 15575-1:201</p>					
<p>A41. No banheiro, há pelo menos uma janela que permita uma iluminação natural adequada (conforme a NBR 15575:2013).</p> <p>Janelas</p> <p>1 2 3 4 5 Critérios:</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Sem pontos de obstrução de luz ou que impeçam a passagem de luz</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Sem excesso de luz ou que provoquem ofuscamento</p> <p><input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Estrutura firme</p> <p>Nº de janelas avaliado: _____</p> <p>NBR 15575:2013 BARROS, 2000 NETO; CARRÉRA, 2013 WHO, 2005 OMS, 2010 REIS, 2014 SCHIAVETO, 2008 STAMATO, 2007, NBR 15575:2013</p>					

COZINHA (cont)	0 %	25 %	50 %	75 %	100 %
<p>A55. Na cozinha, todas as pias, bancadas e superfícies de trabalho estão na altura adequada</p> <p>Cozinha: Critério: <input type="checkbox"/> Todas as pias e bancadas com altura de 80 ± 2 cm do piso. . Número de pias _____, bancadas _____ avaliadas: _____</p>  <p>a) Vista superior b) Vista frontal</p> <p>Figura 148 – Cozinha – Área de aproximação e medidas para uso</p> <p>LIMA; CESÁRIO, 2014 REIS, 2014 SCHIAVETO, 2008 NBR 9050:2020 As pias devem possuir altura de no máximo 0,85 m, com altura livre inferior de no mínimo 0,73 m.</p>					
<p>A56. Na cozinha, todas as gavetas e prateleiras (inclusive as dos armários) estão entre 30 e 180 cm do piso.</p> <p>Todas as Gavetas (marcar X se o critério foi atendido por todas as gavetas) <input type="checkbox"/> altura entre 0,30 e 1,80m do piso. Nº de gavetas avaliadas: _____</p> <p>Todas as prateleiras, cabideiros e armários (marcar X se o critério foi atendido por todos): <input type="checkbox"/> altura entre 0,30 e 1,80m do piso. Nº de prateleiras avaliadas: _____</p> <p>LIMA; CESÁRIO, 2014 REIS, 2014 SBGG, 2008 SCHIAVETO, 2008 STAMATO, 2007; NBR 9050:2020</p>					
<p>A57. Na cozinha todas as torneiras e registros são fáceis de manipular (tipo cruzeta ou similar, ou de alavanca</p> <p>Banheiro: Critério: <input type="checkbox"/> Todas as torneiras e registros são do tipo cruce fácil de manipular</p>  <p>REIS, 2014, NBR9050:2020</p>					
<p>A58. Na cozinha, há pelo menos uma janela que permita uma iluminação natural adequada (conforme a NBR 15575:2013).</p> <p>Janelas 1 2 3 4 5 Critérios: <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Sem pontos de obstrução de luz ou que impeçam a passagem de luz <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Sem excesso de luz ou que provoquem ofuscamento <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Estrutura firme Nº o de janelas avaliado: _____ NBR 15575:2013 BARROS, 2000 NETO; CARRÉRA,2013 WHO, 2005 OMS, 2010 REIS, 2014 SCHIAVETO, 2008 STAMATO, 2007. NBR 15575:2013</p>					
<p>A59. Na cozinha, a localização, o tipo e o tamanho das janelas favorecem boa ventilação. ** Obs. Códigos de obras brasileiros apresentam exigências para iluminação natural que estão relacionadas com as áreas de aberturas mínimas em função da área de piso de cada ambiente. Código de Obras do Distrito Federal exige área de abertura de 1/8 da área de piso para ambientes de permanência prolongada</p>  <p>Janelas 1 2 3 4 5 Critérios (situação ideal): <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Localização no centro da parede oposta à porta <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Permite 100% abertura (ver figura) <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Área igual ou superior a 1/8 da área do piso. Área Janela 1 (m²) / Área Piso (m²) = _____ / _____ = _____ Área Janela 2 (m²) / Área Piso (m²) = _____ / _____ = _____ Área Janela 3 (m²) / Área Piso (m²) = _____ / _____ = _____</p> <p>NBR 15575:2013 BARROS, 2000 NETO; CARRÉRA,2013 WHO, 2005 OMS, 2010 REIS, 2014 SCHIAVETO, 2008 STAMATO, 2007. Fernandes, J. T. (2009). Código de Obras e Edificações do DF: inserção de conceitos bioclimáticos, conforto térmico e eficiência energética.</p>					

III QUESTIONÁRIO DA PERCEPÇÃO DO IDOSO SOBRE A INTERAÇÃO COM O AMBIENTE DOMÉSTICO

<p>No ambiente de sua casa (interno ou externo) indique o quanto você é capaz de:</p> <p>Observação: “Totalmente incapaz”: o indivíduo não consegue executar a tarefa sem auxílio, “Totalmente capaz”: o indivíduo é capaz de executar a tarefa de forma totalmente independente</p>	Totalmente Incapaz	Com muita dificuldade	Com dificuldade	Com pouca dificuldade	Totalmente capaz
DESLOCAR-SE					
P20. Andar pela casa em lugar plano. Comentário:					
P21. Subir ou descer uma escada (pode ser interna, entre os andares da casa, ou externa, mas deve ter no mínimo 5 degraus) podendo segurar no corrimão. Comentário:					
P22. Subir ou descer uma rampa ou escada (da casa) carregando pacotes ou sacolas que o(a) impeçam de segurar no corrimão. Comentário:					
P23. Andar em um piso da casa que esteja molhado, escorregadio ou muito brilhante (piso encerado que dê a sensação que está molhado). Comentário:					
P24. Entrar ou sair de locais da casa que tenham um pequeno desnível (como o box do banheiro, sacada) Comentário:					
P25. Passar facilmente pelas portas da casa e entrar nos ambientes. Comentário:					
ALCANÇAR OBJETOS					
P26. Abaixar-se para pegar um objeto na parte inferior de um armário. Comentário:					
P27. Pegar um objeto (como um vidro de conserva ou um pacote de açúcar de 1 kg) numa prateleira na altura dos olhos. Comentário:					
P28. Ficar na ponta dos pés para pegar algum objeto acima da cabeça. Comentário:					
P29. Subir numa cadeira, banquinho ou escada para pegar algo dentro ou fora da casa. Comentário:					
LEVANTAR-SE					
P30. Levantar-se e deitar-se de uma cama. Comentário:					
P31. Erguer-se e sentar-se em uma cadeira, banquinho, sofá ou outro móvel de sentar-se. Comentário:					
P32. Sentar-se e levantar-se do vaso sanitário (no seu banheiro). Comentário:					
HIGIENIZAR-SE E VESTIR-SE					
P33. Tomar banho (no seu chuveiro ou banheira). Comentário:					
P34. Lavar o cabelo durante o banho. Comentário:					
P35. De pé, secar o corpo após o banho. Comentário:					
P36. Escovar os dentes, pentear o cabelo em pé em frente à pia ou espelho do seu banheiro. Comentário:					
P37. Vestir-se, por completo (inclusive procurando as roupas nos armários e gavetas, podendo apenas necessitar de ajuda para afivelar ou amarrar os sapatos). Comentário:					
PREENSÃO MANUAL					
P38. Abrir e fechar as portas de sua casa Comentário:					
P39. Abrir e fechar as janelas de sua casa Comentário:					
P40. Abrir e fechar torneiras e registros em sua casa Comentário:					

<p>No ambiente de sua casa (interno ou externo) indique o quanto você é capaz de:</p> <p>Observação: “Totalmente incapaz”: o indivíduo não consegue executar a tarefa sem auxílio, “Totalmente capaz”: o indivíduo é capaz de executar a tarefa de forma totalmente independente</p>	Totalmente Incapaz	Com muita dificuldade	Com dificuldade	Com pouca dificuldade	Totalmente capaz
PREENSÃO MANUAL (cont)					
P41. Abrir e fechar armários e gavetas em sua casa Comentário:					
P42. Segurar no corrimão de escadas em sua casa Comentário:					
P43. Retirar objetos quentes do forno e colocar sobre o fogão, a mesa ou a bancada da pia. Comentário:					
ATIVIDADES GERAIS					
P44. Preparar um café com leite ou uma refeição simples. Comentário:					
P45. Fazer trabalhos manuais domésticos ou pequenos reparos (Ex.: lavar louças, regar plantas, trocar uma lâmpada). Comentário:					
P46. Fazer atividades domésticas como varrer ou aspirar o chão. Comentário:					
P47. Lavar e torcer a roupa (ou pano de chão). Comentário:					
P48. Fazer atividades do dia a dia em casa sem se machucar ou se acidentar com móveis que tenham cantos vivos ou partes de vidro. Comentário:					

PERCEPÇÃO DE CONFORTO E ACESSIBILIDADE					
Diga o quanto o sr.(a) concorda com estas afirmações sobre a sua residência	Discordo totalmente	Concordo pouco	concordo nem discordo	Concordo muito	Concordo totalmente
S01. Todos os cômodos são amplos o suficiente para você. Comentário:					
S02. A circulação em todos os cômodos é fácil para você (não existe um excesso de móveis ou objetos que possam causar acidentes como tapetes soltos, cabos, fios, brinquedos, animais e outras coisas para tropeçar). Comentário:					
S03. Você sente que sua casa é muito fria ou úmida. Comentário:					
S04. Você sente que sua casa é muito quente e abafada. Comentário:					
S05. Para você, sua casa tem uma boa iluminação natural, durante o dia. Comentário:					
S06. A cor das paredes, dos pisos ou dos móveis lhe incomodam ou causam algum tipo de problema (dificuldade de diferenciar objetos). Comentário:					
S07. O barulho na sua casa (interno ou externo/vizinhança) lhe incomoda muito. Comentário:					
S08. É fácil para você ir do quarto ao banheiro à noite porque há iluminação em todo o trajeto. Comentário:					
S09. É fácil para você ir do quarto ao banheiro à noite porque o caminho é livre de obstáculos. Comentário:					
S10. É fácil para você acender e apagar as luzes de todos os cômodos de sua casa. Comentário:					
S11. A iluminação em todos os cômodos é boa e permite você fazer atividades à noite como ler, cozinhar, jogar cartas etc. Comentário:					
S12. Você sente necessidade de fazer alguma reforma ou adaptação em sua casa para facilitar o seu dia a dia. Comentário:	