

CENTRO UNIVERSITÁRIO FEI
ISAÍAS CABRAL PEREIRA
JONATHAN FELLIPE FRANCISCO BATISTA
MATHEUS SALGUEIRO SONODA
MONICA MARQUES NACIMENTO
VINÍCIUS SILVA BRAGA

**SISTEMA DE PREDIÇÃO DE RISCO DE QUEDAS PARA ÁREA HOSPITALAR
UTILIZANDO MACHINE LEARNING**

São Bernardo do Campo

2021

ISAÍAS CABRAL PEREIRA
JONATHAN FELLIPE FRANCISCO BATISTA
MATHEUS SALGUEIRO SONODA
MONICA MARQUES NACIMENTO
VINÍCIUS SILVA BRAGA

**SISTEMA DE PREDIÇÃO DE RISCO DE QUEDAS PARA ÁREA HOSPITALAR
UTILIZANDO MACHINE LEARNING**

Trabalho de conclusão de curso, apresentado
ao Centro Universitário FEI para obtenção do
título de Bacharelado em Engenharia Elétrica,
Orientado pelo Prof. Dr. Flavio Tonidandel.

São Bernardo do Campo

2021

SISTEMA DE PREDIÇÃO DE RISCO DE QUEDAS PARA ÁREA
HOSPITALAR UTILIZANDO MACHINE LEARNING / Jonathan Fellipe
Francisco Batista...[et al.]. São Bernardo do Campo, 2021.

41 f. : il.

Trabalho de Conclusão de Curso - Centro Universitário FEI.
Orientador: Prof. Dr. Flavio Tonidandel.

1. Queda. 2. Idosos. 3. Predição. 4. Clínico. 5. Marcha. I. Batista,
Jonathan Fellipe Francisco. II. Pereira, Isaías Cabral. III. Nascimento,
Monica Marques. IV. Sonoda, Matheus Salgueiro. V. Braga, Vinicius
Silva. VI. Tonidandel, Flavio, orient. VII. Título.

RESUMO

O mundo vive um crescente momento de envelhecimento populacional. Vários fatores explicam tal fenômeno, como por exemplo a queda da fecundidade proveniente da diminuição do número de nascimentos, além do aumento da expectativa de vida da população em decorrência de melhorias no âmbito da saúde e na qualidade de vida.

Por outro lado, o problema de quedas sofridas pela população idosa já é um assunto preocupante conhecido ao redor do mundo, uma vez que pequenas quedas podem gerar grandes transtornos e riscos à vida, saúde e integridade física desta camada da população. Com o agravante ainda de que no momento atual muitos idosos moram sozinhos e devido ao afastamento de seus familiares, os riscos se tornam ainda maiores.

Devido ao aumento no número de quedas, diversos dispositivos já foram propostos para detectá-las e em seguida alertar aos contatos previamente cadastrados pelo usuário. Nesse sentido, estudar os indícios de uma possível queda é de suma importância, uma vez que ela pode trazer sérias consequências para a saúde da população, podendo até mesmo ser fatal.

O objetivo deste trabalho consiste, portanto, no desenvolvimento de uma ferramenta de predição de risco de queda por meio da utilização dos algoritmos de *machine learning* árvore de decisão (DT) e rede neural, por meio dos softwares MATLAB® e WEKA.

Isto posto, foram treinados dois modelos computacionais baseados nestes algoritmos, que puderam prever o risco de quedas no idoso. Tais modelos foram embasados nas informações contidas num banco de dados previamente estabelecido e obtiveram taxas de assertividade, precisão e sensibilidade adequadas com possibilidades de melhorias para aplicação prática futura.

Palavras-chave: Queda. Idosos. Predição. Algoritmo.

ABSTRACT

The world is experiencing a growing moment of population aging, several factors explain such a phenomenon, such as the fall in fertility resulting from the decrease in the number of births, in addition to the increased life expectancy of the population due to improvements in health and quality of life.

On the other hand, the problem of falls suffered by the elderly population is already a matter of concern known around the world, since small falls can cause major problems and risks to the life, health, and physical integrity of this population group. With the aggravating factor that nowadays many elderly people live alone and due to the distance from their families, the risks become even greater.

Due to the increase in the number of falls, several devices have already been proposed to detect them and then alert the contacts previously registered by the user. In this sense, studying the signs of a possible fall is of utmost importance, since it can bring serious consequences to the population's health, and can even be fatal.

The objective of this work is, therefore, to develop a tool to predict the risk of falling by using the machine learning algorithms decision tree (DT) and neural network, through the MATLAB® and WEKA.

That said, two computational models were trained based on these algorithms, which were able to satisfactorily predict the risk of falls in the elderly. These models were based on information contained in a previously established database and obtained adequate assertiveness, precision and sensitivity rates, with possibilities of improvement for future practical application.

Keywords: Falls, Elderly, Clinical, Risks, Prediction

LISTA DE ILUSTRAÇÕES

Figura 1	– Resultado de execução do controlador fuzzy para determinação de risco de queda	23
Figura 2	– Esquemático do sistema de monitoramento proposto através da bengala . . .	23
Figura 3	– Árvore de decisão: Elementos Gerais	27
Figura 4	– Exemplo de árvore de decisão para um processo de empréstimo	27
Figura 5	– Esquema de unidade McCulloch - Pitts	30
Figura 6	– Funções de Ativação	30
Figura 7	– Rede Neural	30
Figura 8	– MLP-Multi-Layer Perceptron	33
Figura 9	– Matriz de confusão	35
Figura 10	– Banco de dados Stata	39
Figura 11	– Exemplo de <i>label</i> contido no banco de dados	39
Figura 12	– Banco de dados Excel	40
Figura 13	– Comparação da quantidade de dados de entrada antes e após balanceamento	40
Figura 14	– Interface do classification learner presente no MATLAB® versão R2021a .	41
Figura 15	– Fluxo de trabalho simplificado para obtenção dos modelos	42
Figura 16	– Importação de dados na plataforma do <i>classification learner</i>	43
Figura 17	– Árvores de decisões presentes no classification learner	43
Figura 18	– Exemplificação da exibição das acurácias de treinamento	44
Figura 19	– Acurácia definitiva (teste) das árvores para o cenário anterior	44
Figura 20	– Árvore de decisão resultante da modelagem - formato gráfico	45
Figura 21	– Interface principal - WEKA	47
Figura 22	– Importação dos dados completos - WEKA	48
Figura 23	– Balanceamento do conjunto de treinamento - WEKA	49
Figura 24	– Configuração de parâmetros para a MLP - WEKA	50
Figura 25	– Iteração na rede neural em épocas - WEKA	51
Figura 26	– Conclusão de iterações - WEKA	51
Figura 27	– Obtenção do resultado final de simulação - WEKA	52
Figura 28	– Matriz de confusão para melhor condição da árvore podada - Dados balanceados	54
Figura 29	– Árvore de decisão resultante - Dados balanceados (Nível de poda: 16) . . .	56

Figura 30 – Matriz de confusão para a rede neural MLP obtida	57
Figura 31 – Visualização gráfica de sinapses para a MLP obtida	58

LISTA DE TABELAS

Tabela 1	– Tabela comparativa de alguns sistemas presentes na literatura	25
Tabela 2	– Simulação de árvores de decisão para diferentes partições do conjunto de treinamento balanceado	46
Tabela 3	– Resultados gerais para simulação da rede neural MLP	53
Tabela 4	– Resultado gerais da árvore de decisão obtida	55
Tabela 5	– Resultados gerais para a rede neural MLP obtida através do WEKA	59

LISTA DE ABREVIATURAS

CART	Classification And Regression Tree
DT	Decision Tree - Árvore de decisão
IA	Inteligência Artificial
IMU	Inertial Measurement Unit - Unidade de medição inercial
MLP	Multilayer Perceptron
RNA	Redes Neurais Artificiais
SVM	Support Vector Machine - Máquina de vetores de suporte
TUG	Timed Up and Go
TUG+	Timed Up and Go plus

SUMÁRIO

1	INTRODUÇÃO	12
1.1	OBJETIVO	13
1.2	JUSTIFICATIVA	13
1.3	ESTRUTURA DO TRABALHO	14
2	REVISÃO BIBLIOGRÁFICA	15
2.1	ESCALAS	15
2.2	PARÂMETROS PREDITORES	16
2.2.1	Avaliações clínicas	19
2.3	SISTEMAS	20
3	FUNDAMENTAÇÃO TEÓRICA	26
3.1	ÁRVORE DE DECISÃO	26
3.1.1	Algoritmo CART	28
3.2	REDES NEURAS	29
3.2.1	MLP - Multilayer Perceptron	32
3.2.2	Algoritmo <i>BackPropagation</i>	33
3.3	MÉTRICAS DE AVALIAÇÃO PARA ALGORITMOS DE CLASSIFICAÇÃO	34
3.4	MATLAB®	36
3.5	WEKA	36
4	METODOLOGIA	38
4.1	BANCO DE DADOS	38
4.2	MODELAGEM POR ÁRVORE DE DECISÃO	40
4.3	MODELAGEM POR REDE NEURAL	47
5	RESULTADOS E DISCUSSÃO	54
5.1	ÁRVORE DE DECISÃO	54
5.2	MULTILAYER PERCEPTRON - MLP	56
6	CONCLUSÃO	60
	REFERÊNCIAS	63
	APÊNDICE A – Variáveis presentes no banco de dados selecionadas para análise	67
	APÊNDICE B – Modelo textual da árvore de decisão obtida para predição do risco de queda	69

APÊNDICE C – Modelo textual da rede neural obtida para predição do	
risco de queda	71

1 INTRODUÇÃO

Segundo as projeções do Departamento de Assuntos Econômicos e Sociais das Nações (2017), a quantidade de idosos acima de 60 anos cresce, mundialmente, a uma taxa acelerada de 3% ao ano e em 2050 atingirá 25% da população global total. No Brasil, o IBGE (2018) estima que até 2060, 25,5% da população será composta por idosos (acima de 65 anos). O avanço da idade está associada a deficiência de equilíbrio, dificuldades com a mobilidade, piora na visão e na cognição, o que contribui para um aumento do risco de quedas. Globalmente, um terço das pessoas com 65 anos ou mais sofre queda pelo menos uma vez por ano. Como consequências físicas das quedas entre os idosos, pode-se citar fraturas, principalmente as de quadril, lesão cerebral traumática, danos em órgãos intratorácicos e intra-abdominais, lesões espinhais e nervosas, lesões articulares, hematomas e cortes (GASPAROTTO, 2014).

Após uma queda, o medo de cair também pode ter um impacto significativo na qualidade de vida em pessoas idosas. No Brasil, uma pesquisa feita pelo Estudo Longitudinal da Saúde dos Idosos Brasileiros (ELSI-Brasil), com 4.174 participantes de 60 anos ou mais, entre 2015 e 2016, mostrou que 25,1% haviam sofrido uma ou mais quedas, com prevalência entre as mulheres acima de 75 anos (PIMENTEL et al., 2018). O ambiente urbano apresentou associação com a ocorrência de quedas, com maior propensão ao evento entre aqueles que têm medo de cair devido a defeitos nas calçadas e medo de atravessar a rua. Dentre as condições de saúde, diabetes, artrite ou reumatismo e depressão apresentaram as maiores associações. Portanto, a fim de evitar maiores riscos ocasionados por estes acidentes, faz-se necessária a criação de medidas preventivas para amenizar os danos à saúde e o comprometimento socioeconômicos advindos desses eventos.

Por se tratar de um problema cuja tendência é de crescimento em todo o mundo, diversos sistemas na literatura já foram propostos para sua resolução, sendo o foco mais comum a monitoração e detecção da queda, sinalização e pedido de socorro a cuidadores e/ou familiares. Nestes, o sensor mais utilizado foi o acelerômetro, componente elétrico capaz de mensurar a aceleração resultante durante movimentos diários, como andar, sentar, levantar e cair. Diversas abordagens de processamento foram utilizadas no decorrer do tempo, com a utilização de ferramentas computacionais que variam desde uma árvore de decisão (DT), até algoritmos mais complexos, como máquinas de vetores de suporte (SVM), capazes de reconhecer padrões em registro de dados e classificá-los de maneira eficaz.

As propostas para identificação do evento de queda contidas nestes trabalhos obtiveram resultados com alta assertividade e sensibilidade de detecção. Além disso, foi possível o desenvolvimento de sistemas de hardware embarcados, que possibilitou a notificação de familiares e médicos por meio de uma interface de software no caso da ocorrência do evento de queda e a necessidade de auxílio ao idoso, fase conhecida como pós-queda. Entretanto, a predição da queda, isto é, o aviso de um risco alto de queda iminente ao idoso, familiares e médicos antes da efetivação do evento, ainda tem se mostrado um desafio acerca desta problemática. A proposta deste trabalho vai ao encontro desta questão, visando fornecer aos idosos um meio de possibilitar a prevenção destes eventos, de tal forma com que tenham, preferencialmente, suas ocorrências altamente reduzidas.

1.1 OBJETIVO

O objetivo deste trabalho consiste na obtenção de um sistema computacional para predição de quedas em idosos por meio do treinamento de uma rede neural e uma árvore de decisão. Este sistema será composto por diversos parâmetros oriundos de um banco de dados previamente escolhido, cujos dados serão treinados e testados nos dois artefatos computacionais de forma a realizar a predição do risco de queda.

1.2 JUSTIFICATIVA

As quedas na população idosa têm se mostrado um incidente recorrente, representando um alto risco de morte, diminuição da mobilidade e autonomia desta camada da população. Neste sentido, a prevenção da queda é uma grande aliada na mitigação da ocorrência destes incidentes.

Este desafio não é tão simples, uma vez que requer análises aprofundadas que variam de indivíduo a indivíduo. Desta forma, a Inteligência Artificial mostra-se uma grande ferramenta na resolução desta problemática, uma vez que as análises provenientes de quedas, requerem grande quantidades de dados, reconhecimento de padrões, diminuições e cálculo de erros e tomada de decisão mais altamente assertivas.

1.3 ESTRUTURA DO TRABALHO

Nas seções a seguir, serão apresentadas as principais escalas, parâmetros e sistemas estudados anteriormente na literatura, com o objetivo de situar o leitor a respeito deste estudo. Em seguida, serão expostas as metodologias propostas para treinamento da rede neural e árvore de decisão, cujos principais conceitos estarão descritos no corpo do trabalho.

2 REVISÃO BIBLIOGRÁFICA

2.1 ESCALAS

Dentro do contexto hospitalar, uma das grandes preocupações são as quedas envolvendo a população idosa, problema este de grande complexidade visto a necessidade de constante acompanhamento e cuidados. Ao ocorrer a primeira queda de um idoso, a chance de reincidência é incrementada em três vezes, o que pode ocasionar um aumento do risco de morte. Na tentativa de solucionar tais quedas, foram desenvolvidas ferramentas de triagem que utilizam escalas para analisar o risco de quedas através de parâmetros clínicos de fácil acesso.

Uma forma de analisar o risco de quedas é com o uso de escalas, que possuem a finalidade de fazer uma avaliação de cada paciente, levando em consideração fatores relacionados à ocorrência deste episódio por meio da atribuição de valores, gerando uma pontuação resultante. Para validar a escala é necessário avaliar a precisão dos seus resultados, ou seja, sua capacidade de predição dos potenciais pacientes que são suscetíveis a queda, considerando a sensibilidade, especificidade, valor preditivo positivo, valor preditivo negativo e valores preditivos totais (MCKECHNIE; PRYOR; FISHER, 2016).

Na tentativa de atingir os melhores resultados nos testes de validação, foram estudados 48 fatores correlacionados as quedas, mas como a análise de tantos fatores em um mesmo sistema se torna extremamente complexa, foram criadas mais de 30 escalas de risco de quedas (MCKECHNIE; PRYOR; FISHER, 2016), as quais utilizam diferentes aspectos de análise e pontuação. Dentre todas as escalas existentes as que mais se destacam, em questão de eficácia e frequência de utilização são as escalas Morse e STRATIFY.

A escala STRATIFY consiste em cinco perguntas independentes, cada uma associada a quedas, sendo elas se o paciente possui: apresentação de uma queda, presença de agitação, deficiência visual, necessidade frequente de ir ao banheiro e marcha prejudicada. Cada uma recebe uma pontuação de 0 ou 1 (1 ponto se a resposta for sim e 0 se ela for não), em seguida é feita a somatória dos valores atribuídos a cada pergunta e o resultado da soma das pontuações apresenta a classificação do risco de queda, sendo a somatória maior ou igual a 2 considerada como alto risco (VASSALLO et al., 2005).

Segundo Vassallo et al. (2005) em seu estudo da meta-análise de 4 pesquisas voltadas a validação da escala STRATIFY, utilizando um modelo de efeitos-aleatórios para o cruzamento dos dados, foi obtido uma sensibilidade de 67,2%, uma especificidade de 51,2%, um valor

preditivo positivo de 23,1% e um valor preditivo negativo de 86,5%, o que mostra que mesmo em uma meta-análise a escala se limita a grupos específicos e não é eficiente para a predição de alto risco de quedas em pacientes hospitalizados.

A Escala de Queda Morse consiste de seis variáveis de fácil identificação e pontuação rápida, sendo elas: histórico de quedas (apresentação de uma queda não acidental no último ano), diagnóstico secundário (que pode contribuir para uma queda), auxílio ambulatorial (bengala, cadeira de rodas ou andador), administração de terapia intravenosa, marcha (normal, fraca ou prejudicada) e estado mental (se o paciente é consciente ou não de suas limitações ao andar). Cada variável recebe uma pontuação de 0 a 30 pontos e a somatória dos pontos das 6 variáveis geram a pontuação para avaliação do risco de queda, sendo classificado como baixo risco de 0 a 24 pontos, médio risco de 25 a 44 pontos e alto risco superior a 45 pontos (MORSE et al., 1989; URBANETTO et al., 2013).

Do hospital universitário do Rio Grande do Sul foram estudados 1487 pacientes utilizando a escala de Morse brasileira para analisar o risco de queda dos indivíduos e validar a escala traduzida. De acordo com Souza Urbanetto et al. (2017) a tradução transcultural dos parâmetros clínicos originais da escala de Morse e a sua utilização nos pacientes resultou em uma sensibilidade de 95,2% e uma especificidade de 64%, resultados que demonstram o ótimo desempenho dos parâmetros originais no cenário brasileiro e a alta capacidade de predição de quedas da escala.

2.2 PARÂMETROS PREDITORES

Diversos fatores podem impactar direta ou indiretamente no risco de quedas, por isso é de suma importância o estudo dos parâmetros relacionados a ocorrência destes eventos, com a finalidade de evitá-los. Esta análise torna-se necessária, pois influencia o tipo de abordagem que será utilizada na resolução do problema. Na literatura, os parâmetros preditivos podem ser utilizados como entrada em um sistema baseado em Inteligência Artificial para terem seus possíveis padrões reconhecidos.

Os principais fatores de riscos de quedas podem ser intrínsecos, ou seja, relacionados as características individuais como idade, doenças crônicas e distúrbios de marcha, que nada mais são que doenças como artrite, pé torto ou defeitos congênitos do aparelho de locomoção. Além disso, podem ser extrínsecos, como coeficientes relacionados ao ambiente, calçadas mal

feitas, tapetes lisos, pisos molhados, riscos ao tropeçar, escadas sem corrimão, sapatos sem estabilidade ou andar descalço, uma vez que nesta faixa etária busca-se equilíbrio e estabilidade.

Naturalmente, envelhecer culmina em diversas mudanças tanto fisiológicas quanto patológicas em todos os sistemas do corpo e quanto maior a idade, maior o risco de graves danos pós-quedas. Um dos agentes de grande impacto quando relacionado ao risco de queda são os distúrbios de marcha e equilíbrio. É normal que na velhice os reflexos, força e tônus muscular diminuam, o que sensibiliza a capacidade de evitar acidentes. A dificuldade ao iniciar um novo movimento ou em controlar o tamanho dos passos torna ainda mais instável e desequilibrado os deslocamentos, acentuando o risco de queda significativamente em pacientes com patologias neurológicas de marcha como parkinsonianos, neuropáticos, hemiparéticos, espásticos, comprometimento cognitivo, entre várias outras (R. IVERS E L. CLEMSON E J. CULLEN E MF HAYES E M. TANZER E P. MITCHELL, 2007).

O déficit cognitivo deve englobar a alteração de memória associada à modificação em pelo menos outro domínio cognitivo como praxia, que é a capacidade de realizar atividades motoras, linguagem, funções executivas ou gnosia que é a capacidade de reconhecer ou identificar objetos. A dificuldade cognitiva e a demência são fatores de alto risco para quedas, pois, a estabilidade postural é uma habilidade complexa dependente da coordenação dos sistemas motor e sensorial para notar estímulos. Estes sistemas estão ligados por processos corticais de ordem superior e são necessários para o planejamento de movimentos, resolução de problemas, atenção dividida e a respostas às mudanças no ambiente (R. IVERS E L. CLEMSON E J. CULLEN E MF HAYES E M. TANZER E P. MITCHELL, 2007).

As doenças neurodegenerativas incuráveis e debilitantes, conforme exposto em A. Levalley e J. Verghese (2006), têm como consequência a degeneração progressiva ou morte dos neurônios, ocasionando alto risco da ocorrência de quedas em qualquer idade, sobretudo na velhice devido a alterações notadas em padrões de marcha e instabilidade. Estudos já mostram que a quantidade de quedas em pessoas portadoras de doença de Alzheimer e doença de Parkinson é muito maior que em pessoas sem estas patologias.

O controle do equilíbrio, mostrado tão importante para a estabilidade do corpo, é menor naqueles idosos com déficits visuais, pois a visão é importante não apenas para a aquisição de informação sobre o ambiente, mas também para guiar o movimento do corpo (S. KIVEL "A, 2012). Grande parte do processamento visual relacionado ao movimento e relações espaciais utiliza as vias magnocelular e parietal posterior do cérebro e são essenciais para o controle postural. A capacidade para manter o equilíbrio e o controle postural é importante para o de-

sempenho adequado das tarefas de vida diária, bem como para levantar e sentar-se numa cadeira ou realizar uma caminhada. Por consequência, idosos com baixa acuidade visual tendem a diminuir suas atividades básicas e diárias, o que impacta diretamente em seu cotidiano.

Um outro agravante neste aspecto é a tontura e a vertigem, que são sintomas comuns dentro da população mais velha, devido ao atrito de células neurais e sensoriais, o que no geral culmina em problemas na marcha e no equilíbrio do paciente. Estudos mostram que existe uma relação entre o aumento do risco de quedas e as medições do vestíbulo-auricular. Para função adequada do vestíbulo periférico, o sistema necessita de um reflexo vestíbulo-ocular intacto, uma rede de conexões neurais entre o sistema do vestíbulo periférico e os músculos extraoculares. Sendo assim, com esta função prejudicada, pode-se impedir o equilíbrio e o controle causando uma queda (N. SHEPARD, 2011).

Algumas comorbidades, conforme demonstrado no trabalho dos autores I. Hajjar e L. Quach e R. Jones e D. Kiely e Peggy Gagnon e L. Lipsitz (2011), também podem interferir e aumentar este risco de queda, como a hipotensão ortostática que é definida como uma queda na pressão arterial em certos níveis. Pesquisas mostram que adultos mais velhos com hipotensão e hipertensão não controlada estavam em maior risco de quedas quando comparadas aqueles que não apresentam estas patologias.

Já a hipertensão arterial é o aumento anormal, por longo período, da pressão que o sangue faz ao circular pelas artérias do corpo. Estudos que compararam a marcha característica de hipertensos jovens e idosos mostraram uma pequena diferença, pois, as pessoas que não possuíam hipertensão tinham mais estabilidade, maior escala de fractal de índice de marcha e melhor controle postural. Já os pacientes com pressão arterial elevada tiveram pior desempenho nestes índices (T. HERMAN E ROSSITZA BALTA DJIEVA E T. GUREVICH E NIR GILADI, 2003).

Ainda sobre fatores de risco, observa-se que o uso de alguns medicamentos mostraram grande interferência na incidência de quedas. Pesquisas anteriores, como exposto no trabalho dos autores W. Pickett e N. Yiannakoulias e B. Rowe e D. Schopflocher e L. Svenson e D. Voaklander (2003) evidenciaram que medicamentos cardiovasculares implicaram no risco de queda elevado e dentre os medicamentos estudados estão, digoxina, antiarrítmicos e diuréticos. Psicotrópicos trazem impactos ainda maiores, uma vez que são medicamentos que agem principalmente no sistema nervoso central, onde altera a função cerebral e temporariamente mudam a percepção, o humor, o comportamento e a consciência. Estes medicamentos, incluindo antidepressivos e drogas para demência, podem aumentar significativamente o risco de quedas,

e quanto mais drogas psicotrópicas ingeridas, maior é este risco. Pesquisas ainda mostraram um risco crescente de quedas com o uso de benzodiazepínicos, antipsicóticos e antidepressivos. É necessário se atentar aos efeitos colaterais dessas drogas no sistema nervoso central, pois o mesmo traz efeitos como sedação, tontura e ataxia, o que pode aumentar significativamente o risco de quedas.

A depressão se apresenta por alterações de humor causando, no geral, grande irritação, podendo se relacionar a prejuízo cognitivo, alterações comportamentais e sintomas físicos. Neste contexto, esta condição está associada ao risco de quedas, em decorrência do efeito de medicações antidepressivas e sedativas, déficit de atenção, declínio funcional, insegurança, indiferença ao meio ambiente e reclusão.

Entender como todas essas comorbidades e medicamentos se relacionam ao risco de quedas faz-se de extrema importância para o desenvolvimento deste projeto, uma vez que possibilitará uma melhor avaliação de quais variáveis podem apresentar uma correlação direta com um risco de queda elevado.

2.2.1 Avaliações clínicas

Como ponto de auxílio ao estudo dos parâmetros preditores, pode-se estudar avaliações clínicas cabíveis que, juntamente com a análise computacional, visam aumentar a assertividade na predição de quedas.

Em estudos clínicos, podem ser avaliados os sinais encontrados na caminhada como velocidade, simetria, postura e desvios. Vários testes têm sido desenvolvidos com o objetivo de avaliar o equilíbrio e buscar estabelecer parâmetros para identificação de idosos com maior suscetibilidade de queda. A confiabilidade, reprodutibilidade ou fidedignidade de um instrumento é no que se baseia a consistência de resultados obtidos pelos pacientes em diferentes ocasiões ou com diferentes conjuntos de tarefas (BELCHIOR, 2014)

Esse tipo de avaliação visa medir num instrumento de equilíbrio, a equivalência da concordância de apenas um observador, isto é, a confiabilidade intraexaminado ou concordância de vários observadores, que é a confiabilidade interexaminador.

O teste denominado "Quatro degraus quadrados" é o teste que consiste em avaliar o tempo de movimentação do idoso enquanto ele caminha em diversas direções. Com base em estudos, o teste foi validado em idosos com uma sensibilidade de 85 % e especificidade de 88-100 % na previsão do risco de queda (DITE; TEMPLE, 2002). Outro método conhecido

é o teste de sistemas de avaliação de mini-equilíbrio de medida, embasado no desempenho de sistemas que podem estar prejudicados na velhice como biomecânica, estabilidade, respostas posturais, ajustes posturais antecipatórios, orientação sensorial, equilíbrio dinâmico durante a marcha e efeitos cognitivos (K. PRIEST E A. SALARIAN E DONALD PIERCE E F. HORAK, 2012). O teste de mini-equilíbrio tem se mostrado confiável com índice de (ICC = 0,91). Já o teste "Timed Up and Go", outro método de avaliação clínica, mais conhecido como TUG é utilizado para avaliação de mobilidade. Este teste avalia o tempo levado para se levantar de uma cadeira, andar três metros, voltar para a cadeira e sentar novamente. A pontuação deste teste acima de 13,5s indica alta probabilidade de quedas. Devido à sua simplicidade e pouco tempo para aplicação, o TUG é muito utilizado para avaliação de quadro de risco (L. RUBENSTEIN E M. TINETTI E K. BREWER E K. CAMERON E E. CAPEZUTI E DP JOHN E S. LAMB E F. MARTIN E P. ROCKEY E M. SUTHER E E. PETERSON E A. SOC E B. SOC, 2011). Estudos demonstraram uma boa confiabilidade intraexaminadores (ICC-0,95) e interexaminadores (ICC-0,98) (FIGUEIREDO RIBEIRO; GUERRA; LIMA, 2015).

Existem ainda diversos outros testes clínicos utilizados no ambiente hospitalar para detectar o risco de queda e/ou avaliar a estabilidade da marcha de um paciente, todos eles com o objetivo de encontrar os perfis mais suscetíveis a estes acidentes.

2.3 SISTEMAS

Boa parte da literatura está focada em indivíduos que já possuem histórico de quedas. Kuspinar et al. (2019) vão na contramão e descrevem uma proposta para a população que não sofreu uma primeira queda. Nesse sentido, foi relatado como é fundamental a prevenção primária de lesões em pessoas que não apresentam histórico de quedas, para isso, o método utilizado foi a análise de uma árvore de decisão juntamente com a regressão logística para obter a razão de probabilidade, de modo a avaliar ainda mais a validade do algoritmo em diferentes amostras.

Com esta finalidade, foi criado um algoritmo testado em pessoas sob cuidados domiciliares, que não caíram nos últimos 90 dias e, durante o estudo, elas foram acompanhadas durante 6 meses. O estado de queda foi a variável dependente e os níveis da árvore de decisão foram as variáveis independentes. Inicialmente foram identificados grupos cujas taxas de risco eram semelhantes e foram agrupados em 6 categorias com taxas de 5–10%, 11–15%, 16–20%, 21–25%, 26–30% e 31–35%.

Indivíduos que apresentavam marcha instável, deficiência cognitiva, mal de Parkinson e padrões de saúde instáveis estavam em maior risco de queda. Já as pessoas que não apresentavam andar instável, mas apresentavam comprometimento cognitivo, dor e desempenho reduzido com o controle de medicação, apresentavam risco moderado de queda. Por outro lado, os indivíduos sem essas características tiveram menor risco de queda. As taxas de queda foram de 5 a 9% para os pacientes do grupo 1 (baixo risco) e 34% para o grupo 6 (alto risco). As duas faixas de maior risco representaram 11,4% do total da amostra, ou seja, 10.111 pessoas apresentaram risco elevado de terem a primeira queda. Uma vez que a probabilidade de queda nesses grupos girou em torno de 25 a 34%, o número esperado de quedas somente nesses grupos seria de 2.820 pessoas.

O algoritmo de previsão proporcionou aos médicos a identificação precoce de indivíduos que correm risco de quedas e ajudou a desenvolver planos de cuidados personalizados. Uma limitação deste estudo foi que o histórico de quedas foi baseado em um período de 90 dias. Além disso, a quantidade de quedas ao fim do estudo, foi baseada principalmente em dados autorrelatados, o que pode ter resultado em subnotificação. Contudo, os avaliadores que fazem as entrevistas são treinados para obter as informações de forma mais precisa possível.

Já Schooten et al. (2016) apresentam a relação entre a vida cotidiana e a probabilidade de queda em pessoas idosas. Monitorar o dia a dia deles permite averiguar o quão sedentário o paciente é, o que pode prejudicar a aptidão, capacidade de equilíbrio e por conseguinte, propiciar o risco de queda. Enquanto uma pessoa marcha são exercidas forças em cada uma das três direções de aceleração, ou seja, ântero-posterior (AP), médio-lateral (ML) e vertical (VT).

Durante o estudo, foram obtidas significativas associações univariadas com o tempo para a primeira e segunda queda, tais como: frequência de passada e raiz quadrada média em VT e AP, autocorrelação em VT e AP, amplitude da frequência dominante em VT e ML, largura da frequência dominante em AP, índice de harmonicidade em VT e ML, razão harmônica em VT e AP, e a taxa de divergência por passada em VT e AP. Além disso, a qualidade da marcha teve uma associação negativa com risco de queda e apresentou 93%, de acordo com a autocorrelação, no período dominante em VT ($\beta = -0,72$), raiz quadrada média do sinal em ML ($\beta = 0,18$), índice de harmonicidade em ML ($\beta = 0,27$) e magnitude no período dominante no domínio da frequência em AP ($\beta = -0,20$).

Uma outra abordagem para a realização da prevenção primária de lesões em decorrência de queda é tratada no trabalho de Bizovska et al. (2018), cujo objetivo principal foi a predição do risco de queda em pacientes de 60 anos ou mais através de sua estabilidade dinâmica local,

definida como a variabilidade da frequência e comprimento da passada durante uma marcha qualquer, além do comportamento angular de parte dos membros inferiores como coxas e pés. Durante o estudo foram utilizados para aferição de dados sensores tri-axiais e exames clínicos prévios para verificação de equilíbrio.

A metodologia adotada no artigo teve duração de um ano e contou com a participação de 131 idosos com idade acima de 60 anos, que foram inseridos em circuitos de caminhada com curvas e paradas para aferição do padrão de marcha, aceleração resultante e velocidade de passo (p) em cada trecho. O estudo mostrou-se eficaz na conclusão de que é possível prever o risco de queda através do parâmetro de estabilidade dinâmica local do paciente. Não foi contemplado no estudo implementação de software para monitoramento de quedas. O estudo obteve uma taxa máxima de assertividade de 76% na predição do risco de queda.

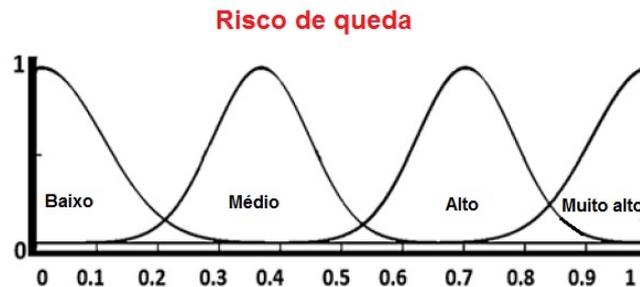
Uma outra abordagem para o estudo de predição de queda é demonstrada no trabalho de Iakovakis, Papadopoulou e Hadjileontiadis (2016), no qual o principal objetivo foi a criação de uma ferramenta de predição baseado em lógica difusa através da tecnologia sensorial de um smartwatch Microsoft Band 2. Com base nos dados do dispositivo, foram extraídos os dados de pressão arterial e a variabilidade da frequência cardíaca. Para aferição das medidas de parâmetros cardíacos, o dispositivo foi inserido no braço direito dos voluntários, enquanto as medidas de pressão arterial foram efetuadas por um esfigmomanômetro digital localizado no braço esquerdo. Já os parâmetros de tempo e de frequência foram extraídos dos voluntários em duas fases posturais: deitar em posição supinada e ficar em pé por 15 minutos (IAKOVAKIS; PAPAPOULOU; HADJILEONTIADIS, 2016).

A construção do controlador Fuzzy proposto foi efetuada no software matemático MATLAB® e promove a predição de queda com base em dados confiáveis de pacientes, resultando em um mecanismo de feedback como resultado. Foram utilizados como entrada do controlador, a queda de pressão sistólica do paciente (DSBP), a idade do usuário, estado de saúde geral e o histórico de quedas. Para a configuração do sistema proposto, 54 regras de Fuzzy foram inseridas no MATLAB®, com a supervisão de médicos e especialistas para a melhor descrição do problema e proximidade com dados reais. Ao executar o controlador, o resultado da estimativa de risco de queda é descrito pelo gráfico representado na figura 1.

Por fim, concluiu-se que o estudo abordado no artigo obteve resultados promissores quanto à modelagem preditiva do risco de queda baseado em lógica Fuzzy com uma porcentagem de acerto máxima de 77,26%. De acordo com os autores, este valor pode ser expandido para a predição dos eventos de queda através de mecanismos de feedback para possíveis detec-

ções, estabilização de equilíbrio e padrões de caminhadas usando dados oriundos de acelerômetros.

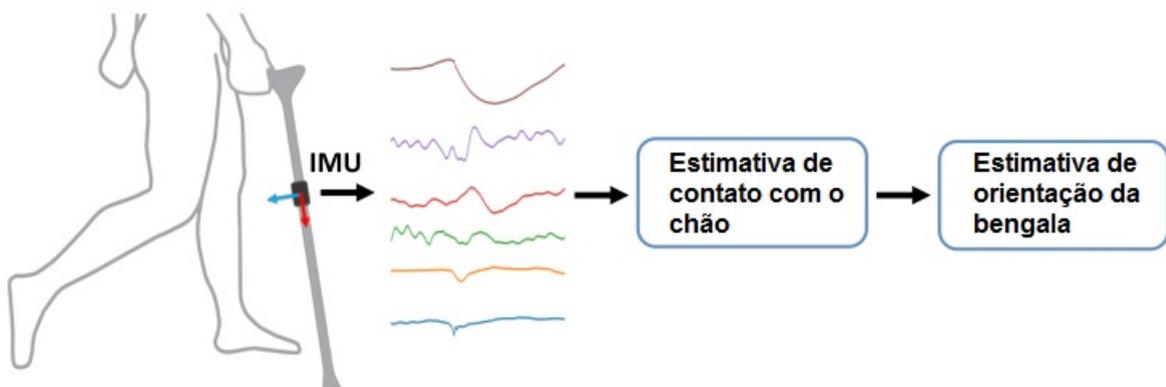
Figura 1 – Resultado de execução do controlador fuzzy para determinação de risco de queda



Fonte: Adaptada de (IAKOVAKIS; PAPADOPOULOU; HADJILEONTIADIS, 2016)

Uma outra perspectiva é exposta no trabalho de Fernandez (2020), no qual foi desenvolvido um sistema de feedback de risco de queda, operando em tempo real, através do uso de dois sensores inerciais tri-axiais, um do tipo acelerômetro e um giroscópio, ambos embutidos em uma bengala prototipada. Através dos dados oriundos dos sensores e de um sistema de captura de movimento óptico, procurou-se estimar a orientação e sentido de movimentação. Em suma, o sistema proposto no artigo se concentra no desenvolvimento de uma bengala instrumentada que estima o risco de queda em tempo real, fornecendo o feedback quando há um alto risco de queda (FERNANDEZ; AHMAD; WADA, 2020). A figura 2 exhibe o sistema proposto, sendo o IMU as unidades de medidas inerciais advindas do acelerômetro e do giroscópio.

Figura 2 – Esquemático do sistema de monitoramento proposto através da bengala



Fonte: Adaptada de (FERNANDEZ; AHMAD; WADA, 2020)

A técnica de aprendizado de máquina selecionada para auxiliar a aquisição de dados foi a implementação de uma rede neural convolucional (CNN), por apresentar resultados mais

promissores em relação as redes neurais convencionais. O modelo proposto tem como dado de entrada uma matriz 2D ($n \times 6$), onde n é a quantidade de amostras fornecidas pelo acelerômetro e giroscópio. Para a aquisição dos dados, sete movimentos foram escolhidos e executados de forma aleatória com cinco participantes jovens saudáveis. A aquisição se deu em dois experimentos cujos objetivos eram extrair a orientação e sentido de movimento da bengala projetada. O sistema proposto obteve sucesso em sua premissa, alcançando uma acurácia máxima de 95,46% na estimativa do contato da bengala com o solo e raiz quadrada do erro médio (RQEM) máxima de 0,87 na aferição do sentido de sua movimentação.

Com o intuito de desenvolver um método combinado de testes clínicos e a utilização de sensores para otimização da predição de riscos de quedas junto da comparação de resultados reais, Buisseret et al. (2020) tem como objetivo apresentar três maneiras diferentes de avaliar os riscos de queda, sendo eles, o teste clínico padrão Timed Up and Go (TUG), o teste clínico padrão aumentado usando sensores (TUG+), e um algoritmo de uma inteligência artificial baseado nos dados brutos de sensores de movimento. Mais de 63 idosos, de quatro lares de idosos na Bélgica, com idade de 65 anos ou mais foram submetidos ao teste (TUG) e aos testes de caminhada de seis minutos, equipados com dispositivo vestível de medição inercial por um período de 6 meses.

Para a aquisição dos dados de aceleração durante os testes de caminhada de seis minutos foi utilizado o sensor DYSKIMOT (HAGE et al., 2020) posicionado na região lombar dos indivíduos, por estar próximo ao centro de massa corporal, com o intuito de aumentar o poder preditivo sobre o risco de quedas em idosos. A classificação de IA escolhida para o estudo foi o Deep Learning dentre as soluções de aprendizado devido a sua capacidade de extrair recursos por si só. Para a análise dos dados foram utilizadas seis séries temporais, em que foram identificados e separados entre pacientes com alto e baixo risco de quedas, das quais foram calculados os índices de variabilidade ($SD =$ Desvio padrão e $D =$ Dimensão fractal) dos registros dos testes realizados, podendo observar que para os pacientes com alto risco de quedas o parâmetro SD_{aap} é significativamente maior e o D_{av} é significativamente menor, nota-se também que a dimensão fractal é globalmente menor para os mesmos.

O teste TUG utilizou a curva *Receiver Operating Characteristic* e mostrou um resultado de 63% na identificação do grupo de pacientes com alto risco de quedas e quando efetuado junto ao uso do acelerômetro, subiu para 87%. Foi utilizado também o teste de caminhada de 6 minutos, utilizando um acelerômetro, que é semelhante ao TUG, focado em pacientes com insuficiência cardíaca crônica e doenças pulmonares obstrutivas crônicas. Em comparação com

outros estudos que utilizam o teste TUG junto a sensores inerciais, os resultados do estudo mostram que o uso do TUG+ é uma melhor maneira de prever o risco de quedas em idosos do que utilizar apenas o teste TUG; a precisão do teste TUG de 8,2% foi ampliada para 74% dos indivíduos da amostra que foram categorizados corretamente e a inteligência artificial conseguiu uma precisão de 75% nos mesmos.

A importância de analisarmos os artigos presentes na literatura baseia-se na necessidade de estudarmos o estado da arte no que tange ao estudo das quedas nos idosos. Através das análises dos artigos acima citados além de outros não inclusos, pôde-se observar os principais algoritmos utilizados e a sua potencial eficácia quanto defrontados com a situação-problema. Com exceção do primeiro trabalho citado, descrito em Kuspinar et al. (2019), cujo objetivo não era obter uma acurácia central mas sim acurácias de acordo com grupos pré-estabelecidos, todos os sistemas acima citados obtiveram um valor exato de acurácia máxima. A tabela 1 a seguir exhibe, comparativamente, os resultados obtidos nos trabalhos mencionados nesta seção.

Tabela 1 – Tabela comparativa de alguns sistemas presentes na literatura

Autores	Método Utilizado	Acurácia máxima obtida
KUSPINAR (2019)	Algoritmo personalizado	-
SCHOOTEN (2016)	Análise probabilística	93,00%
BIZOVSKA(2018)	Aferição de estabilidade dinâmica	76,00%
IAKOVAKIS (2016)	Lógica difusa	77,26%
FERNANDEZ (2010)	Rede neural convolucional	95,46%
DYSKIMOT (2020)	Séries temporais com acelerômetros	75,00%

Fonte: Autores

Portanto, a leitura de tais artigos proporcionou uma excelente contextualização em relação a situação-problema, bem como facilitou a compreensão de possíveis caminhos que pode-se para alcançar este objetivo. É importante ressaltar que a ênfase deste trabalho é a **predição** da queda e não sua detecção propriamente dita, conforme foi efetuado nos trabalhos outrora citados.

3 FUNDAMENTAÇÃO TEÓRICA

As seções a seguir têm como principal intuito a explicação dos principais conceitos teóricos relacionados ao estudo da detecção e predição de quedas, no que tange à dispositivos e algoritmos computacionais mais abrangentes nos trabalhos presentes na literatura.

3.1 ÁRVORE DE DECISÃO

Um dos algoritmos computacionais utilizados na classificação de riscos de queda devido a sua complexidade reduzida, fácil interpretabilidade e implementação simples é a árvore de decisão (DT). Este algoritmo é um dos mais utilizados no mundo e permite interpretação visual simplificada para o mapeamento de possibilidades numa tomada de decisão. O correto treinamento de uma árvore de decisão na resolução de problemas, pode alcançar assertividades muito altas, mesmo comparada a algoritmos mais complexos, o que faz sua implementação ser acessível e ter inúmeras aplicações.

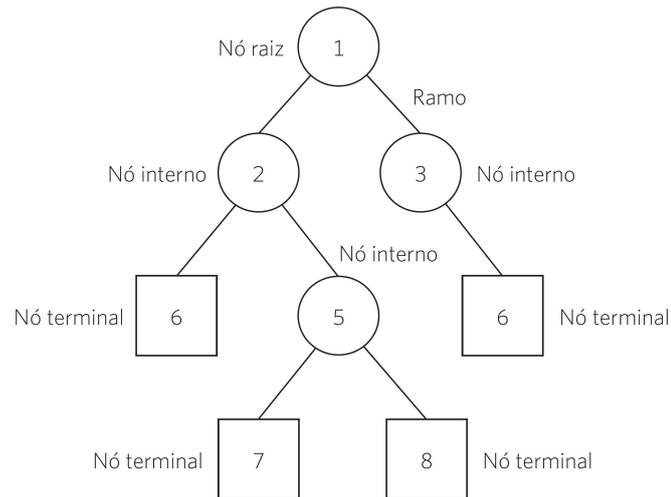
Baseada na abordagem de *dividir e conquistar*, a árvore de decisão consiste na divisão de um conjunto de dados pré-estabelecidos, conhecido como conjunto de treinamento, em sucessivos subconjuntos até que todos, ou em grande parte do conjunto original, possam ser finalmente classificados com uma condição final, denominada **decisão** (que intitula este algoritmo) (QUINLAN, 1993).

A grande vantagem da árvore de decisão (DT) consiste na sua classificação balizada apenas nos parâmetros mais importantes contidos em um conjunto de treinamento, portanto, para que um conjunto prévio de observações possa vir a tornar-se uma árvore de decisão, faz-se necessária a definição dos parâmetros mais importantes a serem considerados para a elaboração do artefato que não retratam, necessariamente, todas as variáveis envolvidas no conjunto de treinamento. Ou seja, variáveis podem tornar-se desnecessárias ou pouco impactantes na decisão final, possibilitando seu descarte. (GAMA; BRAZDIL, 1995).

As árvores de decisões são compostas por **nós** (representados de forma mais comumente por círculos, elipses ou quadrados) interconectados por segmentos de reta denominados **ramos**. Os ramos representam as condições ou alternativas, numéricas, abstratas ou binárias de transição entre os nós. Toda árvore de decisão começa em um nó denominado nó raiz. Dentro de cada nó existente, existe uma condição que foi alcançada. Nós de decisão geralmente são representados por quadrados e constituem-se como o ponto de partida e/ou chegada da árvore

de decisão, enquanto os demais nós, representados circularmente, representando um estágio intermediário de classificação. Cada caminho possível de uma árvore de decisão representa, por fim, uma regra de classificação extraída do conjunto de treinamento (MOORE, 1987). A figura 3 exibe os elementos gerais de uma árvore de decisão.

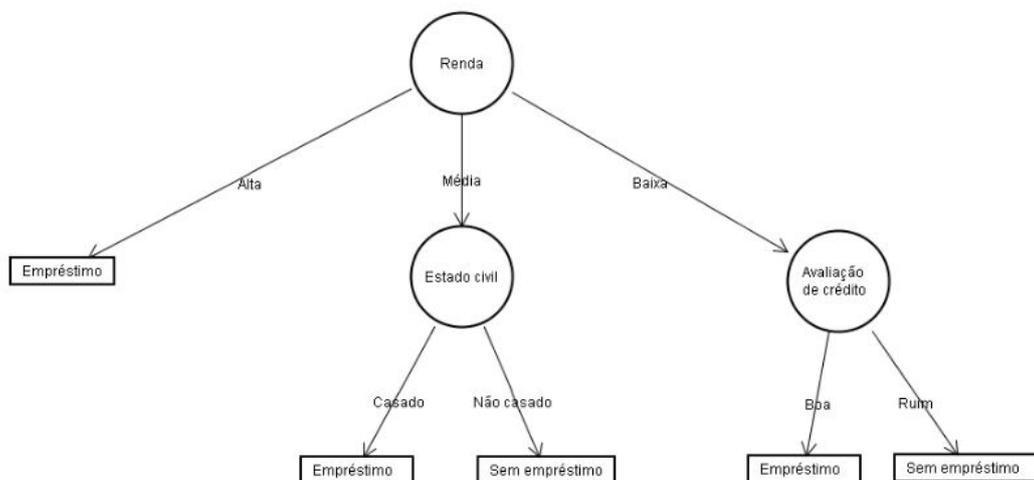
Figura 3 – Árvore de decisão: Elementos Gerais



Fonte: (MEDEIROS et al., 2014)

Para efeito de exemplificação, a árvore de decisão presente na figura 4 representa a tomada de decisão de alguma instituição bancária para fornecimento de empréstimo a um determinado cliente, no qual a renda, estado civil e avaliação de crédito são utilizados pelo algoritmo, enquanto "empréstimo" e "não empréstimo" são os nós de decisão.

Figura 4 – Exemplo de árvore de decisão para um processo de empréstimo



Fonte: (JÚNIOR, 2017)

Existem diversas maneiras de se construir uma DT, no qual o mesmo conjunto de treinamento pode gerar diferentes estruturas de árvores de decisão. Ou seja, para que uma árvore de decisão seja construída, diferentes algoritmos podem ser utilizados. Entretanto, de forma geral não é possível determinar quais algoritmos já registrados na literatura alcançaria melhores resultados para um determinado problema, pois demandaria um alto custo computacional. Portanto, popularizou-se grandes algoritmos para a construção das árvores no decorrer do tempo, dentre os quais destaca-se e que por conseguinte será utilizado neste trabalho: O algoritmo CART (OLIVEIRA; MAILLARD, 2015).

3.1.1 Algoritmo CART

Existem diversos algoritmos para se projetar uma árvore de decisão. Um dos mais célebres e mais utilizado está o algoritmo **CART** (*Classification And Regression Tree*), exposto originalmente em Breiman et al. (1984). Este algoritmo tem como principal característica a divisão binária dos nós, isto é, cada nó estabelecido gera sucessivamente dois nós de ramificação. A partir do nó raiz, cada divisão é baseada no **índice de Gini**, que em suma representa a relação probabilística de cada nó pertencer a uma das classificações finais quanto escolhido de forma aleatória, mensurando por conseguinte a impureza do conjunto de treinamento original (BITTENCOURT; CLARKE, 2003).

Um conjunto de dados com um índice de Gini de 0,5 , por exemplo, representa variável classificatória final perfeitamente distribuída em relação ao número total de instâncias, enquanto índices mais próximos de 0 ou 1 (valor máximo), representam desequilíbrio no conjunto de treinamento, sendo necessário portanto o seu balanceamento para evitar-se o *overfitting* (BREIMAN et al., 1984). Portanto, quanto mais puro o nó, melhor a sua predição de classificação. No algoritmo CART a árvore é construída de maneira recursiva, ou seja, os valores de impureza obtidos para os nós ascendentes impactam diretamente no valor adquirido pelos nós descendentes, recalculando portanto o índice de Gini para cada ramificação estabelecida (CABETE; CARDOSO, 2006).

Desta forma, a construção da árvore parte do geral e a cada nível abaixo, o resultado será particularizado, o tornando, por conseguinte, mais preciso. Cada divisão é realizada com o objetivo de maximizar o índice de Gini para cada variável, permitindo com que os ramos conduzam para a classificação correta presente nos nós-folha (TANG; ZHANG, 2020). O cálculo do índice é efetuado a cada subdivisão e regras de paragem são necessárias para que o modelo da

árvore seja finalizado, que geralmente são número máximo de nós, número mínimo de observações, decréscimo mínimo e máximo do índice de Gini, dentre outros (CABETE; CARDOSO, 2006).

Pela sua natureza probabilística, o algoritmo CART é considerado um dos principais algoritmos para construção da árvore de decisão, pela sua grande capacidade preditiva, capaz de detectar relacionamento entre variáveis do conjunto de treinamento que não são facilmente relacionáveis. Além disso, as árvores geradas por este algoritmo são facilmente legíveis e interpretáveis devido a sua característica binária. Por estas razões, este procedimento pode ser encontrado em diversos meios do conhecimento, tais como economia, medicina, sociologia e afins (FONSECA, 1994).

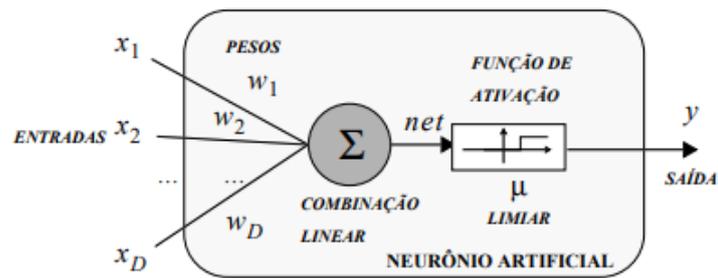
3.2 REDES NEURAIAS

O estudo da rede neural artificial (RNA) possibilita a classificação de conjuntos de treinamentos mais randômicos e com grande quantidade de entradas. No contexto da predição e detecção de quedas, as RNAs se mostraram um algoritmo de grande eficácia na classificação e identificação de riscos. Além disso, existem diversos modelos para implementação e testes, que podem ser treinados e aperfeiçoados para uma acurácia maior. Outrossim, o estudo das RNAs permitem não somente a classificação de dados, como também o reconhecimento de padrões de marcha e queda, que possibilitam o seu uso na etapa de predição de riscos.

Os modelos de neurônios artificiais foram desenvolvidos baseados no funcionamento dos neurônios biológicos. Diversos modelos foram propostos na literatura, mas o mais empregado hoje é o modelo de McCulloch-Pitts. Este modelo, desenvolvido em 1943, descreve um neurônio que têm atividades compostas pela soma de n entradas ponderadas por seus respectivos pesos (HAYKIN, 2000). Esta atividade alimenta uma função não-linear f que produz um sinal que será enviado aos demais neurônios como representado na figura 5.

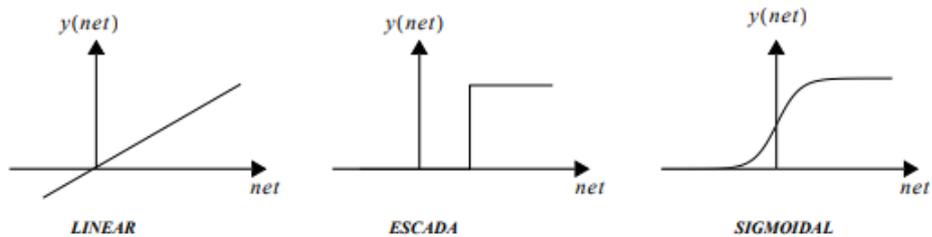
As formas mais utilizadas desta função de ativação são as de escada, linear e função sigmóide representadas na figura 6.

Figura 5 – Esquema de unidade McCulloch - Pitts



Fonte: (RAUBER, 2005)

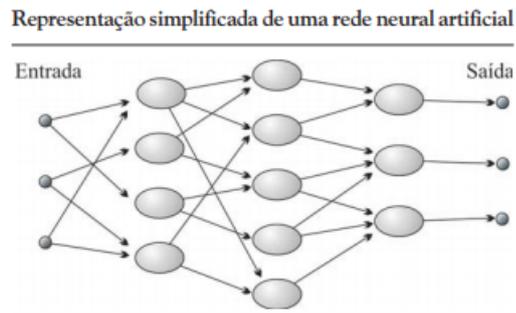
Figura 6 – Funções de Ativação



Fonte: (RAUBER, 2005)

Vários neurônios em paralelo ou em série formam a arquitetura de uma rede neural. As redes neurais são sistemas artificiais inspirados no cérebro humano, que têm como objetivo replicar, nas máquinas, a maneira como as pessoas aprendem. Elas permitem que máquinas consigam entender, aprender padrões e adaptar-se a mudanças. Desta forma as RNAs são criadas a partir de algoritmos projetados para uma determinada finalidade. Uma representação simplificada de uma rede neural artificial (RNA) está ilustrada na figura 7, (FERNEDA, 2006).

Figura 7 – Rede Neural



Fonte: (FERNEDA, 2006)

Uma das principais vantagens das RNAs é a capacidade de aprender por meio de exemplos e produzir saídas adequadas de acordo com o problema.

Para implementar uma RNA de acordo com sua topologia é importante definir algumas variáveis como: número de nós na camada de entrada, número de camadas ocultas, número de neurônios nas camadas ocultas e camada de saída. Um modelo básico de RNA possui os seguintes elementos, (FLECK, 2016):

- a) **Bias:** Representam as entradas, são os valores aplicados externamente a cada um dos neurônios.
- b) **Conjunto de sinapses:** São as conexões, cada qual com seu respectivo peso sináptico, existentes entre os neurônios das RNAs.
- c) **Integrador:** É o responsável pela soma dos sinais de entrada da RNA, ponderados por seus pesos sinápticos.
- d) **Função de ativação:** É a função responsável por restringir a amplitude do valor de saída de um neurônio. Ela representa o efeito que a entrada e o estado atual exercem na definição do próximo estado.

As RNAs se diferenciam pela arquitetura e pesos de conexões. A arquitetura é definida com base no tipo de problema em que vai ser utilizada, no número de camadas, número de nós em cada camada e pelo tipo de conexão entre os nós.

Estas redes utilizam um algoritmo de aprendizagem para ajustar o peso de suas conexões e existem três formas básicas para este aprendizado: aprendizado supervisionado, não supervisionado e híbrido. Neste trabalho de conclusão de curso será utilizado o aprendizado supervisionado. No aprendizado supervisionado, a rede neural recebe um conjunto de entradas padronizadas e seus correspondentes padrões de saída, onde ocorrem ajustes nos pesos sinápticos até que o erro entre os padrões de saída gerados pela rede tenham um valor desejado. No aprendizado não-supervisionado, a rede neural manipula os dados de forma a determinar algumas propriedades de seus conjuntos, e a partir destas propriedades, o aprendizado é constituído. Já o aprendizado híbrido ocorre uma combinação dos tipos supervisionado e não-supervisionado, assim, uma camada pode trabalhar com um tipo enquanto outra camada trabalha com o outro (FLECK, 2016).

O uso das redes neurais tem se tornado cada vez mais frequente devido ao avanço nos seus estudos teóricos e de recursos computacionais. Existem diferentes tipos de redes neurais com vantagens e desvantagens dependendo de sua aplicação, dentre elas estão as redes neurais convolucionais, recorrentes, *autoencoders* e *feedforward*.

Neste trabalho serão utilizadas redes neurais *feedforward*, que são redes onde cada perceptron (neurônio artificial cuja função de ativação é dada por um degrau unitário) de uma camada é conectado a todo perceptron da camada seguinte. Todas as conexões portanto, têm a mesma direção, partindo da camada de entrada rumo a camada de saída, sendo assim, a informação é entregue de maneira antecipada de uma camada à seguinte, seguindo sempre em frente.

3.2.1 MLP - Multilayer Perceptron

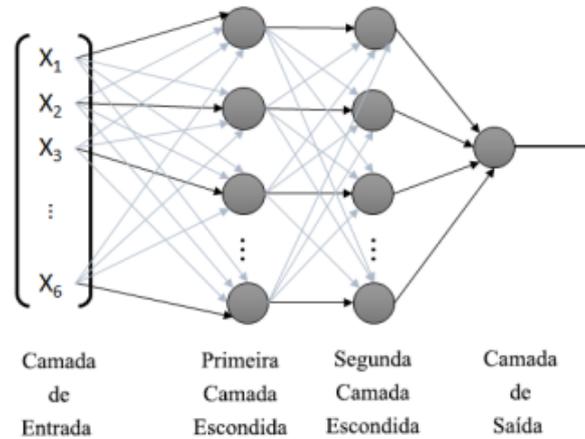
O tipo de rede neural escolhida para o desenvolvimento desta pesquisa foi do tipo MLP. Este tipo de rede neural de múltiplas camadas é subdividida em camada de entrada, camadas ocultas e camada de saída. A camada de entrada distribui as informações para as camadas ocultas, e na saída temos a solução do problema (FLECK, 2016).

As camadas ocultas estão entre a camada de entrada e a camada de saída e tem como função separá-las e permitem que a rede possa aprender tarefas mais complexas progressivamente, por meio do aprendizado. Em uma rede neural os neurônios de uma camada estão conectados a um neurônio da camada imediatamente posterior, sendo assim, não é possível que existam conexões entre neurônios da mesma camada (FLECK, 2016).

O número de camadas escondidas interfere diretamente na relação entre entrada e saída. Uma rede com maior número de camadas ocultas tem uma capacidade maior de extrair características de um processo aleatório. Porém, o uso excessivo de camadas ocultas pode tornar a rede muito grande e ineficiente. Em contrapartida, uma rede muito pequena pode trazer dados não fiéis à realidade (SILVA, 2010).

Para que uma rede trabalhe de forma apropriada, é importante que a mesma tenha uma boa convergência e generalização. A convergência é a capacidade da rede de aprender todos os padrões de um conjunto de treinamentos. Já a generalização é a capacidade de um modelo de aprendizado responder corretamente a novos padrões e é o principal objetivo do processo de aprendizado (SILVA, 2010).

Figura 8 – MLP-Multi-Layer Perceptron



Fonte: (BRITO; FERNANDES; AMORA, 2020)

O processo de aprendizagem de um RNA acontece a partir do momento em que a mesma é estimulada. Por conseguinte, a rede sofre modificações em seus parâmetros e posteriormente a rede neural passa a responder de uma nova forma, devido às modificações ocorridas. O aprendizado de uma rede neural se dá por meio de processos iterativos de ajustes aplicados nos pesos sinápticos e isso é o que chamamos de “treinamento”, processo no qual os pesos sinápticos são ajustados de forma que o vetor de saída coincida com um valor esperado para o vetor de entrada (SILVA, 2010).

A simulação e modelagem de RNAs em softwares podem se tornar complexas de serem realizadas quando a implementação de seu algoritmo é atribuída exclusivamente ao usuário. Por isso é de suma importância que o programa escolhido para a criação do modelo para a predição do risco de quedas tenha uma interface amigável e intuitiva, portanto, o software escolhido para este trabalho é o WEKA.

3.2.2 Algoritmo *BackPropagation*

O algoritmo *BackPropagation* é uma das ferramentas mais utilizadas para o treinamento de redes neurais artificiais. É um algoritmo treinamento supervisionado que calcula o erro e corrige os pesos em todas as camadas, partindo da saída até a entrada (W. SCHIFFMANN M. JOOST, 1994).

A obtenção dos pesos desejados da rede é obtido mediante a atualização de pesos sinápticos no processo de treinamento, que consiste em duas fases: a propagação e a retropropagação.

Na propagação, as entradas são passadas através da rede e as previsões de saída obtidas, já na retropropagação calcula-se o gradiente da função de perda na camada final da rede e usa-se esse gradiente para aplicar recursivamente a regra da cadeia, para atualizar os pesos em nossa rede (SILVA, 2010).

O primeiro passo para o treinamento de uma rede é apresentar um padrão inicial para a mesma, assim ela irá produzir uma saída. Então, é feita uma comparação entre a saída real e a saída desejada e neste momento são realizados os ajustes apropriados nos pesos de modo a alcançar o resultado esperado. O sinal resultante de cada iteração caminha através da rede, camada por camada, até que a resposta seja produzida pela camada de saída, onde é comparada à saída desejada para esse padrão. No caso da resposta estar incorreta, o erro é calculado e propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões de todas as camadas são atualizados à medida que o erro é retropropagado (W. SCHIFFMANN M. JOOST, 1994).

3.3 MÉTRICAS DE AVALIAÇÃO PARA ALGORITMOS DE CLASSIFICAÇÃO

A matriz de confusão é uma tabela de fácil leitura e interpretação do resultado e desempenho de um algoritmo de classificação, como no caso desse trabalho, as redes neurais e árvores de decisões. Normalmente, a tabela é utilizada quando a variável a ser prevista pelo algoritmo é discreta, sendo normalmente uma tabela composta por quatro resultados, mas que também pode ser composta por mais resultados dependendo da construção do algoritmo em questão (LUQUE et al., 2019).

A tabela possui os índices superiores, que seriam os estados possíveis previstos pelo algoritmo e os índices laterais, que seriam os estados possíveis reais da base de dados de entrada. Ao cruzá-los obtemos o significado dos resultados da tabela, sendo que quando o algoritmo prevê o resultado e se equipara com o valor da base de dados resulta em verdadeiro positivo (TP) ou verdadeiro negativo (TN), e quando o algoritmo prevê o resultado, mas ele não coincide com o valor da base de dados, resulta em falso positivo (FP) ou falso negativo (FN), como visto na figura 9 (MARIANO, 2021). Com os resultados classificados pode-se fazer o cálculo dos parâmetros de análise.

Figura 9 – Matriz de confusão

		Previsto (Algoritmo)	
		Sim	Não
Real (Base de dados)	Sim	Verdadeiro positivo (TP)	Falso negativo (FN)
	Não	Falso positivo (FP)	Verdadeiro negativo (TN)

Fonte: Autores

A **Precisão** representa a porcentagem de verdadeiros positivos em relação a quantidade geral de previsões positivas, como visto na equação 1. Já o **Recall, ou Sensibilidade**, representa a porcentagem de verdadeiros positivos em relação a quantidade geral de positivos da base de dados, como visto na equação 2. A **Especificidade** representa a porcentagem de verdadeiros negativos em relação a quantidade geral de negativos da base de dados, como visto na equação 3 (MARIANO, 2021).

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{Especificidade} = \frac{TN}{TN + FP} \quad (3)$$

Fonte: (MARIANO, 2021)

Todos estes parâmetros fazem parte da avaliação do modelo tanto de RNAs quanto da árvore de decisão e, por possuírem fácil interpretabilidade numérica, a matriz serão utilizados para avaliação final de cada modelo.

3.4 MATLAB®

O MATLAB® (*MATrix LABoratory*) é um software de alta performance destinado a cálculos numéricos, integrando análise numérica, cálculo matricial, processamento de sinais e construção de gráficos em um ambiente de fácil uso. Ao contrário da programação convencional, tanto os comandos solicitados pelos usuários quanto as soluções apresentadas são funções matemáticas como são escritas convencionalmente. Atualmente, o software conta com uma ampla gama de bibliotecas cujo conteúdo englobam desde funções matemáticas complexas até análise estatística de dados, que podem auxiliar o usuário, tornando-se a ferramenta de análise matemática para ensino superior mais utilizada no mundo (PALM, 2012).

Desenvolvido pelo professor do departamento de Ciência da Computação da Universidade do novo México, Clever Moler, no final dos anos 70, o MATLAB® foi criado por Moler cujo objetivo era o desenvolvimento de cálculos matemáticos complexos através de equacionamento matricial, que consiste no elemento básico de informação do software até hoje. (SOBIE, 2011) Distribuído atualmente pela empresa norte-americana MathWorks, hoje o MATLAB® conta com a possibilidade de o usuário criar suas próprias bibliotecas, sem a necessidade do uso de linguagem de programação complexa, facilitando o acesso ao ambiente matemático e proporcionando inúmeras opções de simulações.

Por contar com uma plataforma de intuitiva e *low code* para modelagem computacional de algoritmos de aprendizagem de máquina, o MATLAB® foi o software utilizado para a modelagem da árvore de decisão proposta neste trabalho, através de sua plataforma de inteligência artificial *classification learner*. Além disso, o software utiliza o algoritmo CART para a modelagem das árvores, que por sua vez poderá possibilitar resultados mais confiáveis e assertivos para a predição do risco de queda (MATHWORKS, 2021).

3.5 WEKA

O WEKA (*Waikato Environment for Knowledge Analysis*) é um software livre de *machine learning* desenvolvido por alunos da Universidade de Waikato, Nova Zelândia, com o principal objetivo de tornar acessível aos estudantes e pesquisadores o acesso ao aprendizado de máquina, tendo sua primeira versão lançada em abril do ano 2000. Contando com mais de 1,4 milhões de downloads desde o lançamento da sua primeira versão, o WEKA constitui-se como sendo um dos softwares mais utilizados tanto academicamente quanto no ambiente de negócios,

tornando-se portanto referência mundial. Desde seu lançamento até os dias de hoje, o software conta com atualizações constantes em seus algoritmos internos e esquemas de aprendizagem (HALL et al., 2009).

O WEKA conta com diversas opções de aprendizado e mineração de dados, tais como mecanismos de classificação, otimização e *clusters* como árvores de decisão, redes neurais, máquina de vetores de suporte (SVMs), entre outros. Além disso, o software conta com diversas ferramentas e algoritmos relacionados a tratamento de dados, conjuntos de treinamento e modelagem, tendo sua interface gráfica desenvolvida em sua integridade utilizando linguagem JAVA, tornando-a acessível e intuitiva (KOTTHOFF et al., 2017).

Dentre os seus diferenciais, está a possibilidade de simulação e modelagem de forma fácil e rápida de rede neurais do tipo *Multilayer Perceptron*, possuindo frente a outros softwares uma acessibilidade maior aos parâmetros que compõem este modelo, como determinação dos números de camadas internas, quantidade de células por camada, número de épocas, coeficiente de aprendizado, entre outros. Além disso, todos os modelos obtidos podem ser salvos e a rede resultante pode ser visualizada em plataforma gráfica. Por estas razões, o software WEKA foi o escolhido para a modelagem da rede neural proposta neste trabalho.

4 METODOLOGIA

Nesta seção serão abordados os métodos para a obtenção dos modelos de árvore de decisão e redes neurais para a predição do risco de quedas em idosos. Uma vez que esta temática esta intrinsecamente ligada à saúde de indivíduos, é de suma importância que todos os modelos obtidos sejam embasados em dados reais e de alta confiança. Buscou-se, portanto, um banco de dados que contemplasse parâmetros da vida de idosos que durante um certo período vieram a cair ou não, para que assim a predição seja realizada com base nos dados outrora coletados. Para tal fim, a árvore de decisão será modelada no MATLAB® e a rede MLP será modelada no software WEKA, por meio do qual será realizada a variação de alguns parâmetros de cada modelo, de forma a buscar o melhor resultado para ambos artefatos.

4.1 BANCO DE DADOS

O banco de dados escolhido para análise foi obtido do ELSI-Brasil (Estudo Longitudinal da Saúde dos Idosos Brasileiros) que investigou a ocorrência de quedas na população com 50 anos ou mais, e. (LIMA-COSTA MF, 2015)

Diversas perguntas foram feitas aos participantes sendo divididas com base em 5 módulos: domiciliar, individual, medidas físicas, contatos pessoais e caracterização do informante. Como por exemplo endereço, idade, doenças oculares, cirurgias, infarto, diabetes entre outras, totalizando 1084 questionamentos. De posse dessas informações foi possível realizar uma avaliação sobre as perguntas que estavam mais relacionadas a quedas, contidas principalmente no módulo individual e bloco referente à saúde geral e doenças. Após esse filtro, 45 perguntas foram mantidas como variáveis a serem treinadas e posteriormente testadas conforme consta no Apêndice A.

O software Stata foi utilizado inicialmente para visualizar de forma separada e clara as perguntas feitas aos participantes da pesquisa e suas respectivas respostas, como ilustra a figura 10.

Figura 10 – Banco de dados Stata

Variable	Label	Type	Format	Value Labels
id	ID do individuo	int	%8.0g	
iddom	ID do domicilio	float	%8.0g	
URA		double	%10.0g	URA
peso_calibrado_n		double	%10.0g	
estrato		double	%10.0g	
regiao	Regiao	double	%12.0g	regiao
zona	Zona	double	%10.0g	Rural_U
an4	Data de entrevista	int	%d	
an6	Total de pessoas que m...	byte	%10.0g	
an8	Sexo do respondente(pai)	byte	%10.0g	an8
an10	Idade do respondente(pai)	int	%10.0g	
an12_1	Sexo do morador 2	byte	%10.0g	an12
an14_1	Idade do morador 2	int	%10.0g	an14_1
an15_1	Relacao do morador 2 c...	float	%8.0g	an15_1
an12_2	Sexo do morador 3	byte	%10.0g	an12
an14_2	Idade do morador 3	int	%10.0g	
an16_3	Relacao do morador 3 c...	float	%8.0g	an16_3

Fonte: Autores

O site do ELSI disponibiliza para download do banco de dados, o formato Stata (versão 13) que contém a descrição dos *labels*, apresentados na primeira coluna da tabela da figura 11, enquanto a versão .csv não.

Figura 11 – Exemplo de *label* contido no banco de dados

QUEDAS E CIRURGIAS DE ARTICULAÇÕES		
n18	Nos ÚLTIMOS 12 MESES, o(a) Sr(a) teve alguma queda?	(0) Não (VÁ PARA n24) (1) Sim (9) Não sabe/não respondeu (VÁ PARA n24)

Fonte: (LIMA-COSTA MF, 2015)

O programa permitiu que os dados fossem exportados para o formato .xlsx e por conseguinte, aceitáveis de serem usados no Excel para padronização dos caracteres que estavam diferentes para uma mesma pergunta. Além disso haviam códigos como “8/88/888/8888/88888” que se referiam a “Não se aplica (NA)” e caracteres não reconhecidos, portanto precisaram ser ajustados, para que não fosse interpretado como múltiplas respostas, conforme está representado na figura 12.

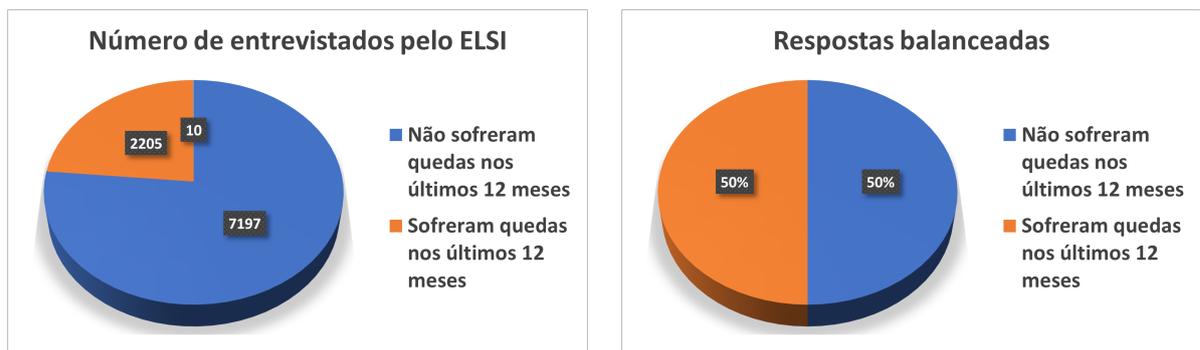
Figura 12 – Banco de dados Excel

	A	B	C	AX	AY
1	Idade	Usa óculos ou lente de contato	Como avalia sua visão para enxergar de longe, mesmo usando óculos ou lente	Tem dificuldade para estender um ou os dois braços acima dos ombros?	Nos últimos 12 meses sofreu alguma queda?
4	58	Não	Regular	Não tem dificuldade (faz a atividade sem esforço)	Sim
6	88	Sim	Boa	Não consegue	Sim
8	75	Sim	Muito boa ou excelente	Tem pequena dificuldade (só faz a atividade com algum esforço)	Sim
12	54	Sim	Regular	Tem pequena dificuldade (só faz a atividade com algum esforço)	Sim
19	56	Sim	Muito Ruim	Tem pequena dificuldade (só faz a atividade com algum esforço)	Sim
20	50	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
21	85	Não	Ruim	Tem pequena dificuldade (só faz a atividade com algum esforço)	Sim
26	50	Não	Boa	Tem grande dificuldade (só faz a atividade com muito esforço, mas só consegue fazer sozinho)	Sim
36	71	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
39	83	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
42	76	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
54	63	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
59	56	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
63	51	Sim	Muito boa ou excelente	Não tem dificuldade (faz a atividade sem esforço)	Sim
67	56	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
68	60	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
74	73	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
79	41	Não	Boa	Tem grande dificuldade (só faz a atividade com muito esforço, mas só consegue fazer sozinho)	Sim
83	58	Sim	Regular	Não tem dificuldade (faz a atividade sem esforço)	Sim
92	62	Sim	Muito Ruim	Não consegue	Sim
98	65	Sim	Regular	Não tem dificuldade (faz a atividade sem esforço)	Sim
103	73	Não	Muito Ruim	Não tem dificuldade (faz a atividade sem esforço)	Sim
108	77	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
117	65	Sim	Boa	Tem pequena dificuldade (só faz a atividade com algum esforço)	Sim
118	51	Sim	Muito boa ou excelente	Tem grande dificuldade (só faz a atividade com muito esforço, mas só consegue fazer sozinho)	Sim
123	79	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
128	75	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
139	53	Não	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
143	57	Sim	Boa	Não tem dificuldade (faz a atividade sem esforço)	Sim
144	74	Sim	Regular	Não tem dificuldade (faz a atividade sem esforço)	Sim
146	60	Sim	Boa	Tem pequena dificuldade (só faz a atividade com algum esforço)	Sim
148	79	Não	Muito boa ou excelente	Não tem dificuldade (faz a atividade sem esforço)	Sim
150	60	Não	Muito Ruim	Tem grande dificuldade (só faz a atividade com muito esforço, mas só consegue fazer sozinho)	Sim
158	67	Sim	Ruim	Não tem dificuldade (faz a atividade sem esforço)	Sim
163	79	Não	Muito Ruim	Não tem dificuldade (faz a atividade sem esforço)	Sim

Fonte: Autores

A variável escolhida como saída do sistema foi “nos últimos 12 meses sofreu alguma queda?”. No entanto, a resposta para essa pergunta foi “não” para 7197 dos entrevistados, enquanto 10 não responderam ou não sabiam e 2205 responderam "sim", conforme imagem 13. Para que o sistema não ficasse desproporcional e super treinado para uma das respostas foi necessário fazer o balanceamento do conjunto de treinamento. Dessa forma, todas as respostas positivas foram treinadas juntamente com outras 2205 respostas negativas, escolhidas de forma aleatória como ilustra o gráfico da figura 13.

Figura 13 – Comparação da quantidade de dados de entrada antes e após balanceamento



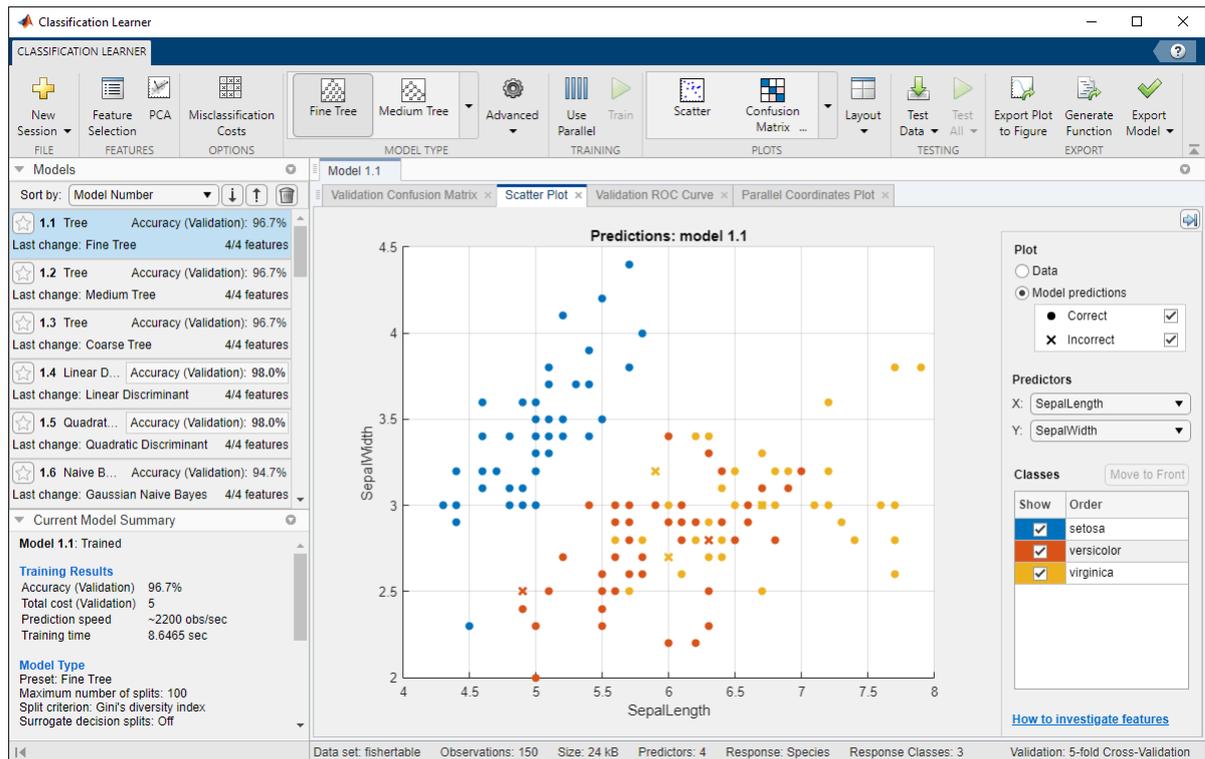
Fonte: Autores

4.2 MODELAGEM POR ÁRVORE DE DECISÃO

Após o tratamento de todos os dados, seleção e extração de variáveis do banco de dados original, a obtenção dos modelos de árvore de decisão e rede neural pôde ser iniciada. Para o

treinamento de uma árvore de decisão, fora utilizado o ambiente de simulação MATLAB® e seu utilitário interno *classification learner*. Este utilitário permite de forma rápida e prática o treinamento de uma base dados previamente estabelecida à diversos algoritmos computacionais existentes e suas derivações, como árvores, vetores de suporte e redes neurais. A interface desta ferramenta pode ser observada na figura 14.

Figura 14 – Interface do classification learner presente no MATLAB® versão R2021a

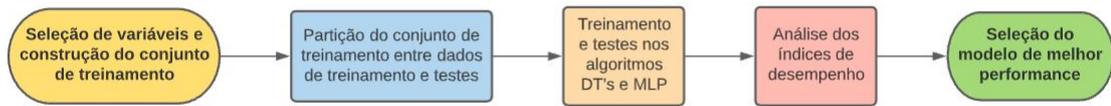


Fonte: (MATHWORKS, 2021)

O fluxo de trabalho simplificado adotado para a obtenção dos modelos propostos, tanto em árvore de decisão quanto em redes neurais, pode ser esquematizado conforme figura 15.

Após a seleção e tratamento das 45 variáveis selecionadas dentre as 1084 presentes no banco de dados original, pôde-se então particionar o conjunto de treinamento previamente construído em percentuais de instâncias de treinamento e testes, de forma a não deixarmos os modelos obtidos hipertreinados exclusivamente ao conjunto de treinamento, fenômeno conhecido como *overfitting*, aumentando portanto sua confiabilidade. Para a condução de todos os testes, foram efetuadas as seguintes divisões: 60% para treinamento e 40% para teste, 80% para treinamento e 20% para teste, 70% para treinamento e 30% para teste, 40% para treinamento e 60% para teste e por fim 20% para treinamento e 80% para teste.

Figura 15 – Fluxo de trabalho simplificado para obtenção dos modelos



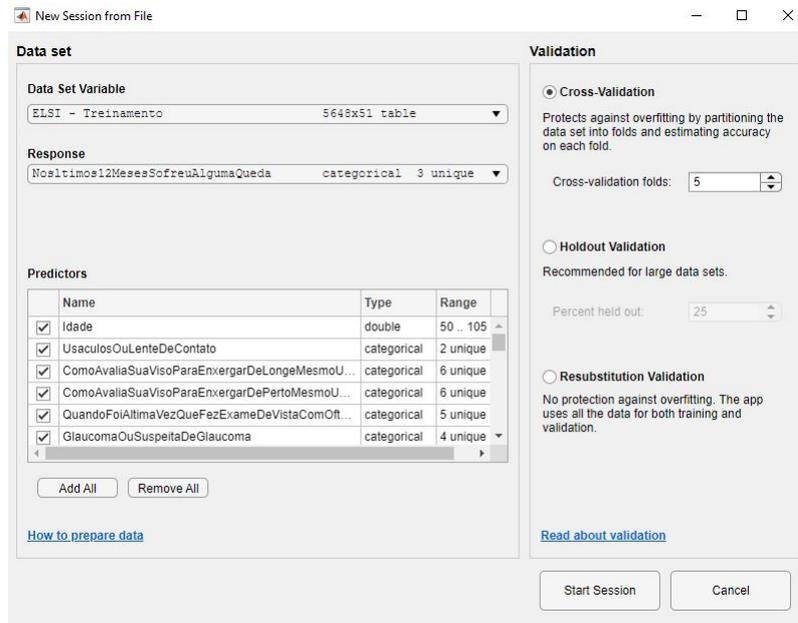
Fonte: Autores

A realização da simulação utilizando o *classification learner* demonstrou-se bastante simples, iniciando com a inserção, dentro da plataforma de simulação, dos dados destinados exclusivamente ao treinamento dos modelos, que conforme descrito anteriormente, foi segmentado do conjunto de dados original. Ao importar qualquer tipo de dado é possível visualizar, logo em seguida, todas as variáveis que estarão envolvidas na simulação (*predictors*), bem como qual a variável que será utilizada como saída (*response*).

No cálculo da acurácia de treinamento dos algoritmos, o MATLAB® utiliza o algoritmo de *Cross-Validation* para a validação inicial do modelo obtido, no qual o resultado é testado nos mesmos dados inseridos previamente e não em dados externos para teste, conforme inseriremos a seguir. É importante ressaltar que, embora esteja previamente selecionado, este parâmetro será descartado após a inserção dos dados de teste.

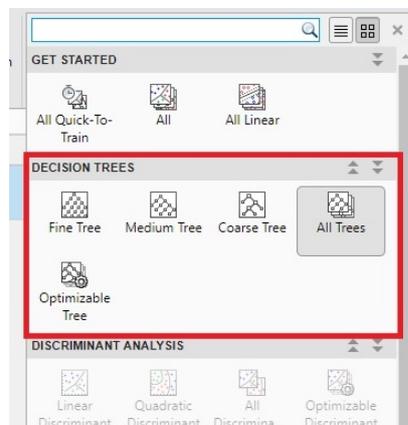
Finalizada a inserção do conjunto de dados específico para treino e ao iniciarmos a sessão, pode-se selecionar os algoritmos de árvore de decisão presentes na plataforma, que dispõe de 4 tipos: *Fine tree*, *Medium tree*, *Coarse tree* e *Optimizable Tree*. Os 4 tipos se diferenciam pela quantidade máxima de divisões que podem ter (*splits*). A Árvore fina se caracteriza, no contexto do software, por ser uma árvore com no máximo 100 divisões, já as árvores médias e grossas possuem números máximos de divisões 20 e 4, respectivamente. Este parâmetro também pode ser inserido pelo usuário livremente na configuração avançada dos modelos. Quanto maior o número de divisões, maiores distinções poderão ser efetuadas entre os nós e portanto mais profunda a árvore será, impactando diretamente em seu tamanho. A figura 16 mostra a tela de confirmação exibida sempre que dados são importados enquanto a figura 17 exhibe os tipos de árvore de decisões presentes na ferramenta.

Figura 16 – Importação de dados na plataforma do *classification learner*



Fonte: Autores

Figura 17 – Árvores de decisões presentes no classification learner



Fonte: Autores

Pode-se efetuar o treinamento de todas as árvores simultaneamente ao selecionarmos a opção *All trees*. Assim, todas as árvores serão enfileiradas e treinadas uma após a outra. No caso do algoritmo de árvore de decisão, os treinamentos são realizados em poucos segundos e as acurácias poderão ser visualizadas, enquanto o próprio software destaca qual foi a maior delas. Também pode ser visualizada a quantidade de variáveis (*features*) importadas e treinadas. Neste caso, foram treinadas 45 de 45 variáveis importadas, ou seja, todas as variáveis importadas foram levadas em consideração na construção do modelo. Para o cenário no qual 60% dos

dados foram admitidos para treinamentos, por exemplo, os resultados estão expostos na figura 18.

Figura 18 – Exemplificação da exibição das acurácias de treinamento

The screenshot shows the 'CLASSIFICATION LEARNER' interface. The 'Models' section is expanded, showing a list of models sorted by 'Model Number'. The models and their training accuracies are as follows:

Model	Accuracy (Validation)
1.1 Tree Last change: Fine Tree	73.9%
1.2 Tree Last change: Medium Tree	75.6%
1.3 Tree Last change: Coarse Tree	76.5%
2 Tree Last change: Optimizable Tree	76.6%

Fonte: Autores

Efetuada a acurácia de treinamento, pode-se neste momento inserir os dados para teste, que comprovarão definitivamente o quanto os modelos obtidos nos treinamentos são assertivos. O processo é muito semelhante ao descrito anteriormente, a diferença é que os dados de teste serão inseridos na seção *Testing* da plataforma. Ao inserir os dados e selecionar variáveis de importação, os modelos poderão ser testados e a acurácia será imediatamente atualizada com a observação *Test* ao invés de *Validation*, como ocorrera com os dados de treinamento. Para o cenário no qual 40% dos dados originais foram destinados para teste, as acurácias definitivas podem ser visualizadas na figura 19.

Figura 19 – Acurácia definitiva (teste) das árvores para o cenário anterior

The screenshot shows the 'CLASSIFICATION LEARNER' interface with the 'Models' section expanded. The models and their test accuracies are as follows:

Model	Accuracy (Test)
1.1 Tree Last change: Fine Tree	74.8%
1.2 Tree Last change: Medium Tree	75.6%
1.3 Tree Last change: Coarse Tree	76.3%
2 Tree Last change: Optimizable Tree	76.3%

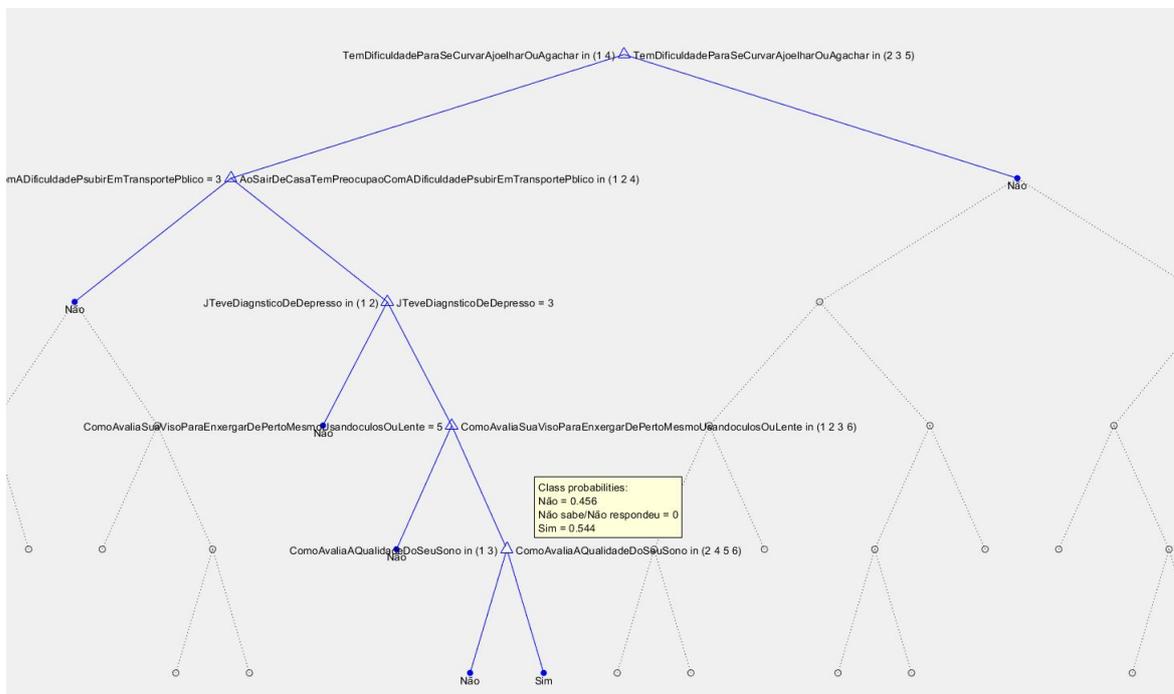
Fonte: Autores

Os parâmetros qualitativos de cada modelo, como sua matriz de confusão, por exemplo, a serem analisados na seção de discussão e análise, podem ser acessados e extraídos pela seção *Plots*.

É possível também visualizar graficamente e textualmente a árvore de decisão, de forma a averiguar graficamente todos os seus nós e ramificações, ou verificar o seu modelo textual para ser utilizado em algoritmos de programação posteriores, por exemplo. Ao exportarmos o modelo para o *workspace* do MATLAB® na seção *export*, podemos utilizar o comando "`view(trainedModel.ClassificationTree,'Mode','graph')`" para gerar a janela gráfica cuja árvore estará inserida, ou trocar a palavra *graph* por *text*, para obter seu modelo textual.

No que tange à opção gráfica, algumas observações podem ser efetuadas. É possível, no canto superior da janela, alterar o seu nível de podagem. Observa-se também que o software altera as respostas das variáveis por números equivalentes, de forma a encurtar e facilitar a leitura dos nós. É possível também visualizar a probabilidade de ramificações de cada nó para cada resposta de saída. A figura 20 exhibe, para a melhor condição e melhor podagem dimensionada para 60% de treinamento e 30% de testes, a árvore de decisão resultante em seu formato gráfico.

Figura 20 – Árvore de decisão resultante da modelagem - formato gráfico



Fonte: Autores

No exemplo da figura 20 e referente ao nó raiz da árvore, as respostas 1 e 4 representam, respectivamente, as respostas "**Não consegue**" e "**Tem grande dificuldade**". Já as respostas

2, 3 e 6 comprimem, de forma respectiva, as respostas "**Não sabe/Não respondeu**", "**Não tem dificuldade**" e "**Tem pequena dificuldade**". Além disso, o nó em sua camada mais inferior possui 45,6% de probabilidade de resultar em "**Não**" e 54,4% de resultar em "**Sim**".

Conforme mencionado anteriormente, foram efetuadas 5 simulações com diferentes partições do conjunto de treinamento balanceado, sendo adotado como nosso modelo da situação-problema (incidência ou não de queda) o resultado que apresentar acurácia e precisão satisfatórios. Uma divisão bastante comum é a de 80% de treinamento para 20% de teste, associada principalmente ao princípio de Pareto, cuja afirmação é que 80% dos efeitos advém de 20% das causas e portanto, com uma divisão de valores próximos a essa proporção, a acurácia tende a ser maior. Mas isso não é uma regra. É importante considerar que não existe um número ideal que se pode cravar a respeito desta divisão, pois com mais dados de treinamento, espera-se obter uma maior variação nos parâmetros do modelo. Em contrapartida, com mais dados de teste, espera-se obter uma maior variação nos resultados obtidos ao aplicá-lo.

Cabe ressaltar também que em todas as simulações efetuadas a **acurácia de validação** foi calculada considerando um parâmetro de 5 *folds* de **validação cruzada** (vide figura 16), ou seja, o MATLAB® particiona por si só todo conjunto de treinamento em 5 partes iguais nos quais quatro são utilizadas para treinar, e uma é utilizada para testar. A tabela 2 exhibe o resultado da simulação considerando a acurácia para cada divisão do conjunto dos dados, balanceada com *undersampling*.

Tabela 2 – Simulação de árvores de decisão para diferentes partições do conjunto de treinamento balanceado

Árvore de Decisão balanceada com undersampling			
Divisão		Acurácias máximas	
Treinamento (%)	Teste (%)	Treinamento (%)	Teste (%)
20	80	58,3	61,1
40	60	60,7	60,9
60	40	61,7	58,0
70	30	60,9	60,5
80	20	59,6	67,9

Fonte: Autores

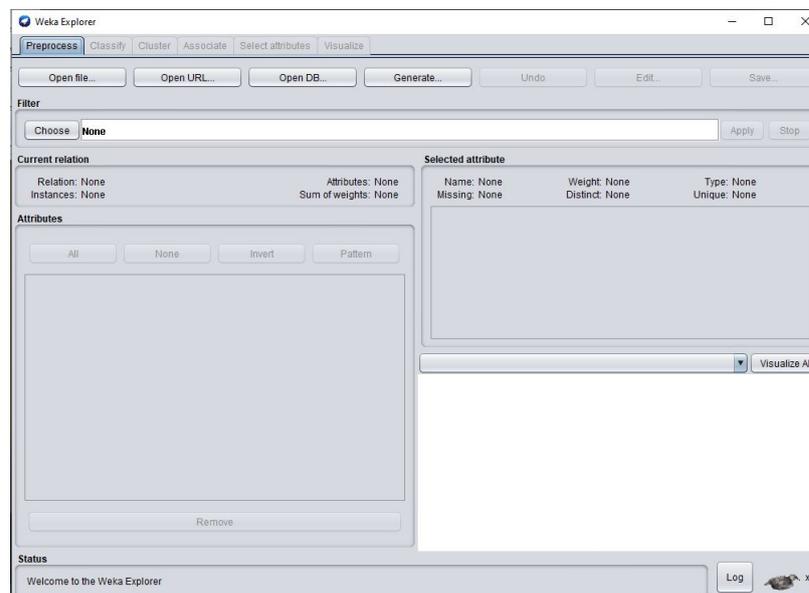
Como pode ser observado na tabela 2, a divisão **80/20** se mostrou mais eficaz quando consideramos apenas o parâmetro de eficácia, pois se obteve as maiores acurácias de treinamento por validação cruzada e acurácia de teste. É importante ressaltar que embora a acurácia tenha sido utilizada para visualizar, ainda que de forma inicial, possíveis modelos candidatos,

este parâmetro por si só não valida o modelo. Isto se deve ao fato de que não basta o modelo apresentar uma acurácia elevada, é preciso também ter uma precisão minimamente satisfatória para cada uma das situações de saída. Os demais parâmetros oriundos da simulação serão abordados na seção de resultados e discussão.

4.3 MODELAGEM POR REDE NEURAL

Para realizar o treinamento da rede neural foi utilizado o ambiente de simulação WEKA. No software estão presentes diversos recursos que utilizam diferentes algoritmos computacionais, que por sua vez permitem a simulação de árvores, vetores de suporte, redes neurais, dentre outros. Para o treinamento da rede neural foi utilizado o recurso *MultilayerPerceptron* que permite com facilidade o treinamento, simulação e visualização de uma rede neural MLP utilizando uma base de dados importada. A interface inicial do software pode ser observada na figura 21.

Figura 21 – Interface principal - WEKA



Fonte: Autores

O fluxo de trabalho simplificado adotado para a obtenção dos modelos propostos, pode ser observado conforme a figura 15 (na seção Modelagem Árvore de Decisões). Assim como o processo de treinamento da árvore de decisão, após a seleção das 45 variáveis escolhidas a partir do banco de dados original, pode-se fazer a divisão deste banco em diferentes percentuais de instâncias para treinamento e testes (*hold-out*), com a finalidade de evitar o *overfitting*, fenômeno no qual os modelos obtidos ficam enviesados unicamente ao conjunto de treinamento.

Uma grande vantagem do software WEKA é que, ao contrário do software utilizado na seção anterior, a realização deste particionamento da base de dados se dá de forma automática, restando apenas ao usuário a responsabilidade de inserir a base de dados no programa e selecionar o percentual de instâncias que deverão ser utilizados para o treinamento no campo especificado. Para a realização dos testes foram efetuadas as mesmas divisões aplicadas ao algoritmo de árvore de decisão.

A simulação utilizando a ferramenta se mostrou bem simples. Para iniciar a simulação, foi feita a inserção da base de dados completa para o treinamento e testes da rede neural. Após a importação dos dados, a plataforma exibe todas as variáveis em formato de lista para visualização na seção (*attributes*), em seguida, é selecionada a variável que será utilizada como saída da simulação. Os dados referentes às respostas atribuídas a essa variável são exibidas em uma lista secundária com suas respectivas quantidades, sendo possível também visualizar de forma gráfica e numérica todas as quantidades de respostas de qualquer uma das 45 variáveis importadas da base de dados, como pode ser observado na figura 22.

Figura 22 – Importação dos dados completos - WEKA

The screenshot shows the Weka Explorer interface. The 'Attributes' list on the left contains 45 variables, with 'nosultimos12mesesofreualgumaqueda' selected. The 'Selected attribute' table on the right shows the distribution of responses for this variable:

No.	Label	Count	Weight
1	Nao	7197	7197.0
2	NS/NR	10	10.0
3	Sim	2205	2205.0

Below the table, a bar chart visualizes the counts for each label: 'Nao' (7197), 'NS/NR' (10), and 'Sim' (2205).

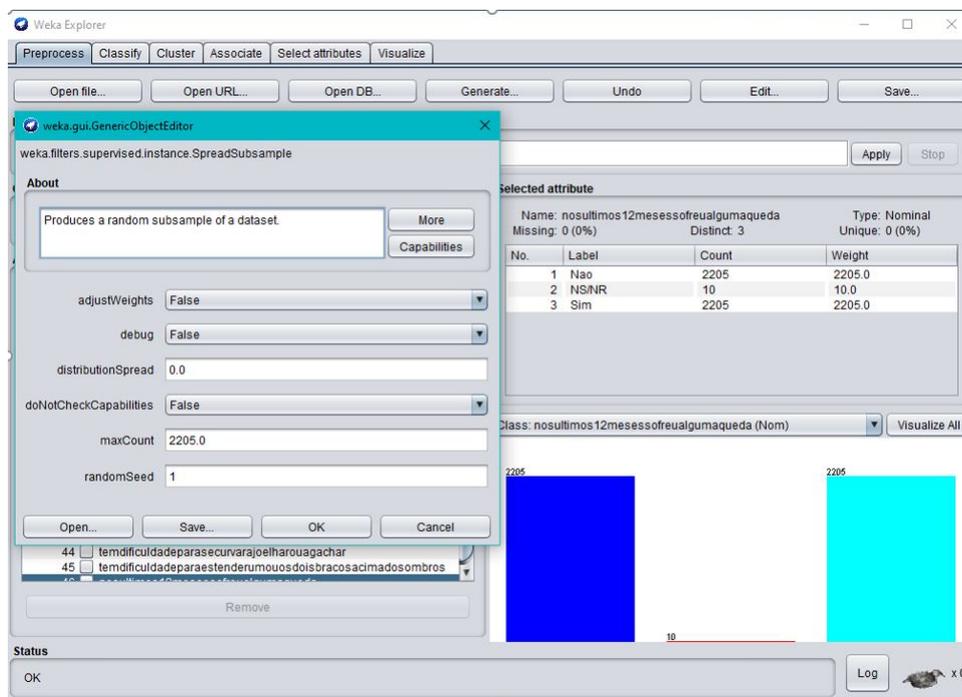
Fonte: Autores

Após a inserção dos dados completos, faz-se necessário o balanceamento da quantidade de respostas “Sim” e “Não” presentes na variável de saída selecionada, para diminuir as chances da rede neural sofrer *overfitting*, como foi observado em testes preliminares considerando que

na base de dados original, situação no qual a quantidade de respostas “Não” era quase 3 vezes superior a quantidade de respostas “Sim” (vide seção BANCO DE DADOS).

O balanceamento é feito facilmente através do campo *Filter*, selecionando o recurso *SpreadSubsample* e aplicando a quantidade de instâncias que serão utilizadas para a simulação, neste caso, foi selecionado o valor de 2205 instâncias, referentes a quantidade de respostas “Sim” presentes no conjunto de treinamento inicial, conforme a figura 22. É importante ressaltar que o software executa este balanceamento por *undersampling* e de forma **randômica**. Após a aplicação do filtro, é obtida a mesma quantidade de instâncias para ambas as respostas, finalizando a preparação dos dados para simulação, conforme observado na figura 23.

Figura 23 – Balanceamento do conjunto de treinamento - WEKA

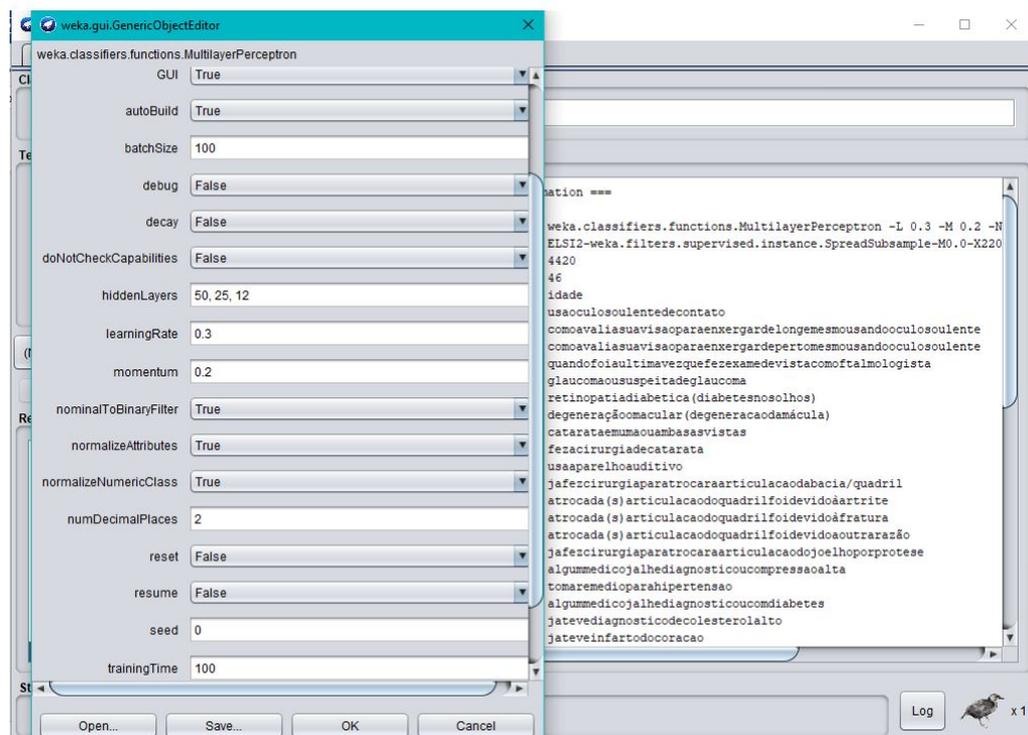


Fonte: Autores

Depois de balancear o conjunto de treinamento, pode-se selecionar a aba *Classify* na plataforma, que contém o ambiente de simulação a ser utilizado. No campo *Classifier* é possível fazer a seleção de diversos algoritmos para simulação disponíveis no software, sendo selecionado, no contexto deste trabalho, o algoritmo de *MultilayerPerceptron*. Em seguida, o usuário pode realizar a configuração do número de camadas internas, quantidade de células por camada e número de épocas (iterações) para a simulação. Para a rede neural proposta neste projeto, foram adotadas as seguintes especificações: 5 camadas no total, constituída por 3 camadas ocultas. A 1ª camada oculta possui 50 células, 2ª camada oculta 25 células e 3ª camada oculta

com 12 células. A camada de entrada conta com 100 células e camada de saída com 3 células. Para cada percentual de divisão da base de dados, o número de épocas escolhidos foram de 100, 500, 1000, 2500 e 4000 épocas, totalizando 5 simulações por percentual. Em razão da limitação do software, a função de ativação nativa é a **sigmóide**. O campo GUI foi selecionado como “TRUE” para habilitar a visualização da rede, como observado na figura 24.

Figura 24 – Configuração de parâmetros para a MLP - WEKA



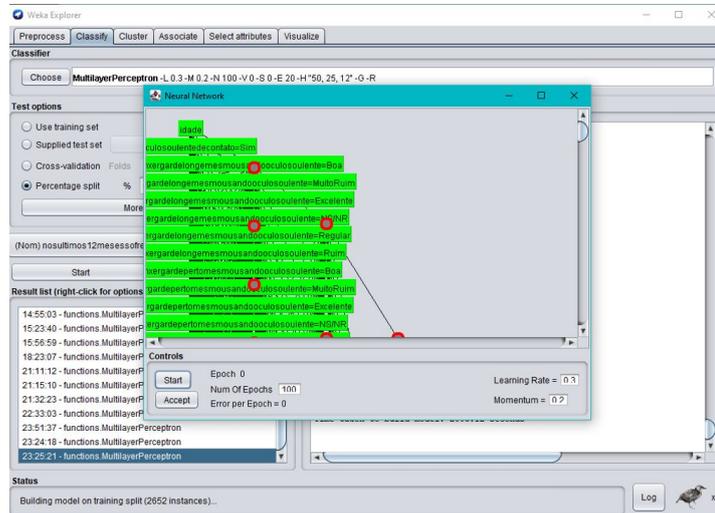
Fonte: Autores

Concluídas as inserções de parâmetros do algoritmo, pode-se dar início ao treinamento. Para realizar o cálculo dos pesos da rede neural o Weka faz uso do algoritmo **BackPropagation**, como anteriormente descrito (vide subseção Algoritmo **BackPropagation**). Após a realização da primeira iteração o software exibe um resultado preliminar do erro por épocas e oferece duas opções ao usuário: “aceitar”, no qual a simulação é finalizada e os resultados da iteração atual são exibidos, ou “iniciar”, no qual outra iteração na rede será iniciada e as métricas serão atualizadas, conforme a figura 25.

A presença da segunda opção indica que o software reconhece, automaticamente, a possibilidade de alcançar por meio de mais uma iteração, um modelo melhor ao que foi obtido na iteração anterior. Uma vez que na simulação pretende-se obter o melhor resultado possível nas condições inseridas, o uso dessa opção é altamente recomendada até que software obtenha o

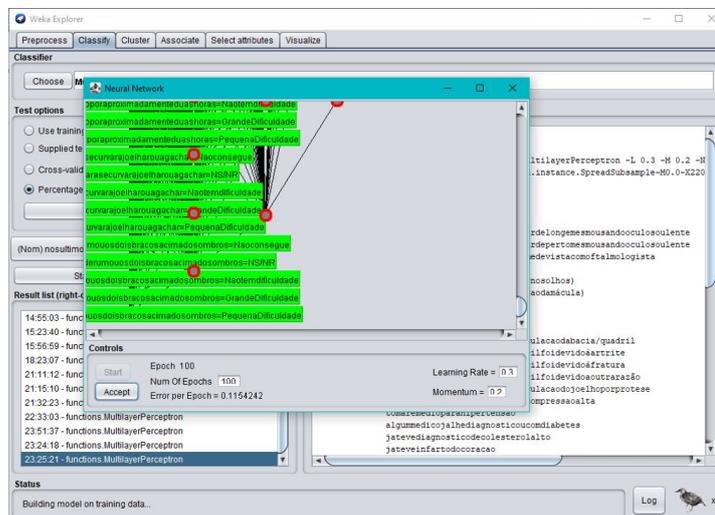
melhor modelo para os parâmetros de entrada, situação no qual a simulação é encerrada e o resultado do modelo é exibido, exemplificado na figura 26.

Figura 25 – Iteração na rede neural em épocas - WEKA



Fonte: Autores

Figura 26 – Conclusão de iterações - WEKA



Fonte: Autores

Ao chegar no melhor modelo e finalizar a simulação o software exibe o modelo obtido no campo **Classifier Output**, com os valores dos pesos atribuídos, acurácia, precisão, matriz de confusão, falsos positivos e falsos negativos, além de outros resultados que também podem ser observados, como observado na figura 27.

Para os resultados presentes na tabela 3, foram realizadas 20 simulações respeitando as configurações especificadas anteriormente com em média 3 iterações por simulação para atingir

Figura 27 – Obtenção do resultado final de simulação - WEKA

The screenshot shows the Weka Explorer interface with the following details:

- Classifier:** MultilayerPerceptron -L 0.3 -M 0.2 -N 100 -V 0 -S 0 -E 20 -H "50, 25, 12" -G -R
- Test options:**
 - Use training set:
 - Supplied test set: Set...
 - Cross-validation: Folds: 10
 - Percentage split: % 60
- Classifier output:**

```

Node 75  -0.5038546143627832
Node 76  -0.368037317855179
Node 77  -0.4853334703972158
Class Nao
Input
Node 0
Class NS/NR
Input
Node 1
Class Sim
Input
Node 2

Time taken to build model: 139.23 seconds

=== Evaluation on test split ===

Time taken to test model on test split: 0.11 seconds

=== Summary ===

Correctly Classified Instances      1037      58.6538 %
Incorrectly Classified Instances    731      41.3462 %
Kappa statistic                    0.1747
Mean absolute error                 0.2945
Root mean squared error             0.4438

```
- Result list (right-click for options):**
 - 12:56:47 - functions.MultilayerPerceptron
 - 13:48:33 - functions.MultilayerPerceptron
 - 14:48:29 - functions.MultilayerPerceptron**
 - 14:55:03 - functions.MultilayerPerceptron
 - 15:23:40 - functions.MultilayerPerceptron
 - 15:56:59 - functions.MultilayerPerceptron
 - 18:23:07 - functions.MultilayerPerceptron
 - 21:11:12 - functions.MultilayerPerceptron
 - 21:15:10 - functions.MultilayerPerceptron
 - 21:32:23 - functions.MultilayerPerceptron
 - 22:33:03 - functions.MultilayerPerceptron

Fonte: Autores

o melhor modelo para cada simulação, sendo considerado como um bom candidato a melhor modelo o resultado de 60% de treinamento da base com 100 épocas (destacado em negrito).

Conforme já citado anteriormente, vale ressaltar que o percentual de acertos por si só não é suficiente para determinar qualitativamente as simulações efetuadas, pois conforme fora observado, ao aumentar o percentual de acertos, o erro por época também tende a aumentar necessitando portanto a análise das outras métricas que o modelo fornece. O ideal é que seja selecionado o modelo com acurácias e taxa de treinamento (erro por época) melhor possível. O melhor modelo obtido foi destacado em negrito na tabela 3 e serão detalhados na seção a seguir.

Tabela 3 – Resultados gerais para simulação da rede neural MLP

Resultados de simulação - MLP			
Treinamento[%]	Número de épocas	Acurácia[%]	Erro por época
20	100	58,06	0,0814053
	500	55,91	0,0303380
	1000	55,91	0,0521052
	2500	55,09	0,0176827
	4000	55,85	0,0398952
40	100	55,13	0,1057526
	500	54,49	0,0364688
	1000	54,19	0,0183488
	2500	53,21	0,0361220
	4000	54,86	0,0262420
60	100	58,65	0,1014492
	500	57,18	0,0521052
	1000	56,11	0,0545548
	2500	57,58	0,0669256
	4000	56,62	0,0694863
80	100	56,79	0,1161387
	500	57,01	0,0661279
	1000	54,98	0,0528439
	2500	56,56	0,0635261
	4000	58,03	0,0670892

Fonte: Autores

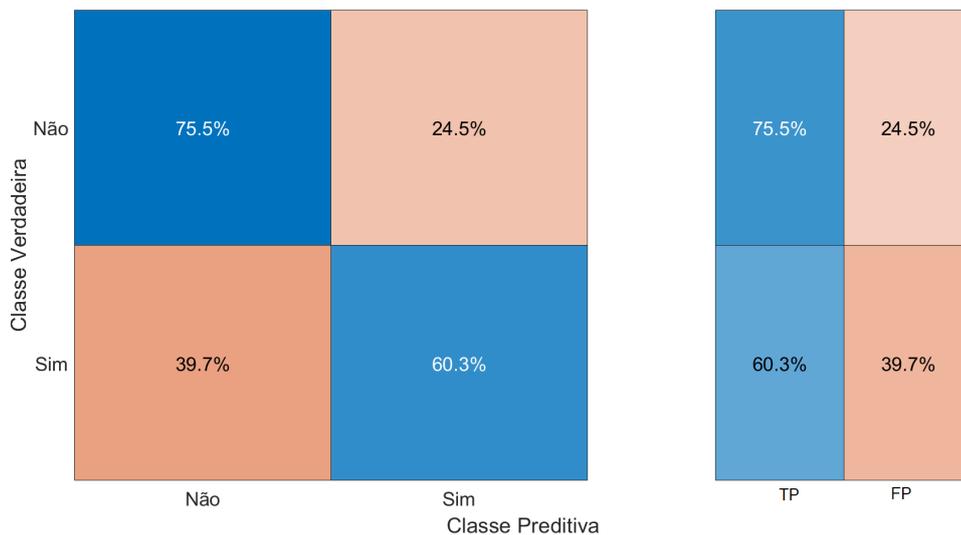
5 RESULTADOS E DISCUSSÃO

Neste capítulo serão analisados mais aprofundadamente os melhores resultados obtidos durante a execução dos procedimentos presentes no capítulo de **METODOLOGIA**.

5.1 ÁRVORE DE DECISÃO

No que tange aos testes referentes à árvore de decisão, algumas observações podem ser realizadas de imediato. Conforme mencionado anteriormente, o princípio de Pareto prevê que para uma proporção de 80% das consequências, há de 20% das causas que a originaram. Este princípio embasa a divisão mais comum, no contexto do *machine learning*, do conjunto de dados original em subconjuntos de teste e treinamentos, que recebe esta atribuição por oferecer, supostamente, melhores acurácias. Neste trabalho, pôde-se observar que esta divisão de fato acarretou em uma maior acurácia e de uma forma geral, em um modelo mais confiável. Ao utilizar o banco de dados balanceado para treinamento e teste, obtem-se a matriz de confusão presente na figura 28.

Figura 28 – Matriz de confusão para melhor condição da árvore podada - Dados balanceados



Fonte: Autores

Conforme pode ser observado a classificação obteve parâmetros classificatórios equilibrados para as duas opções de saída ("Sim" e "Não"). Cerca de **75,5%** da não ocorrência de queda nos últimos 12 meses foi eficientemente classificada, frente à **60,3%** de classificação

assertiva para a ocorrência de quedas neste mesmo período. Ou seja, o modelo é assertivo para ambas as classes de saída e portanto mais seguro de ser utilizado, pois não há a presença de *overfittings*. Além disso, as taxas de predições falsas (**FPs**), podem ser visualizadas na coluna vermelha da matriz à direita.

No que tange as características construtivas da árvore, a árvore resultante foi uma do tipo fina, que apresentou 173 nós e com um nível de profundidade alto, com cerca de 8 níveis. Além disso, nota-se que o nó raiz, mediante às 45 variáveis iniciais, correspondeu a variável referente à dificuldade do idoso em ajoelhar ou agachar, imputando-a portanto a característica de ser a mais relevante da árvore, demonstrando que dentre as demais, possui maior relação com a saída. A tabela 4 exhibe, os resultados para cada métrica de avaliação em relação a árvore obtida.

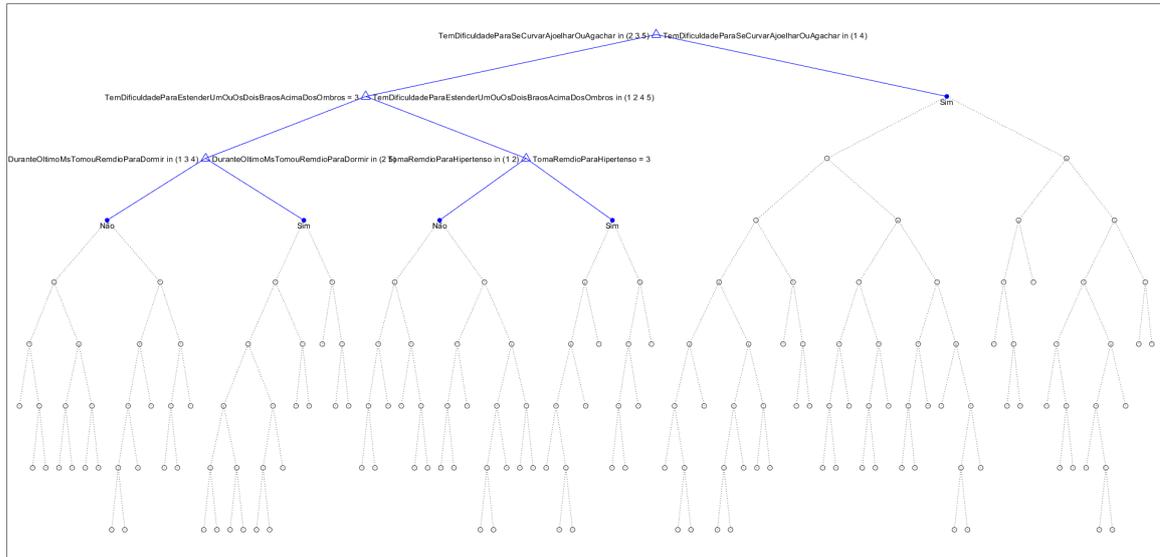
Tabela 4 – Resultado gerais da árvore de decisão obtida

	Banco de dados balanceado
Quantidade de instâncias	4408
Divisão Treino/Teste	80% 20%
Acurácia	67,90%
Precisão (Verdadeiro positivo)	60,30%
Verdadeiro negativo	75,50%
Falso positivo	39,70%
Falso negativo	24,50%
Sensibilidade	71,20%
Tipo	<i>Fine (Fina)</i>
Número de Nós	173
Número de Níveis	8
Nó raiz	Dificuldade em Ajoelhar ou Agachar

Fonte: Autores

Em termos gráficos, as DT oriunda da simulação, devido ao grande número de nós e elevado nível de profundidade, não pode ser sintetizada em uma única imagem e apresentou cerca de 19 níveis de poda automáticos que podem ser selecionados por meio da janela gráfica do MATLAB®. A figura 29 exhibe a árvore resultante com um nível 16 de poda com relação ao seu tamanho original, em cinza claro.

Figura 29 – Árvore de decisão resultante - Dados balanceados (Nível de poda: 16)



Fonte: Autores

Conforme pode ser observado na tabela 4, o sistema apresentou uma sensibilidade de **71,2%**, ou seja, esta é a chance do sistema classificar de forma assertiva resultados classificados como positivos em relação ao conjunto de treinamento. O modelo textual da árvore de decisão está presente no Apêndice B deste trabalho e posteriormente pode ser implementado, por meio de programação, em qualquer sistema para testes posteriores. Conforme modelo textual presente no apêndice, observa-se também que variáveis envolvendo mobilidades se sobressaíram em termos de relevância a atributos gerais como por exemplo, a idade.

5.2 MULTILAYER PERCEPTRON - MLP

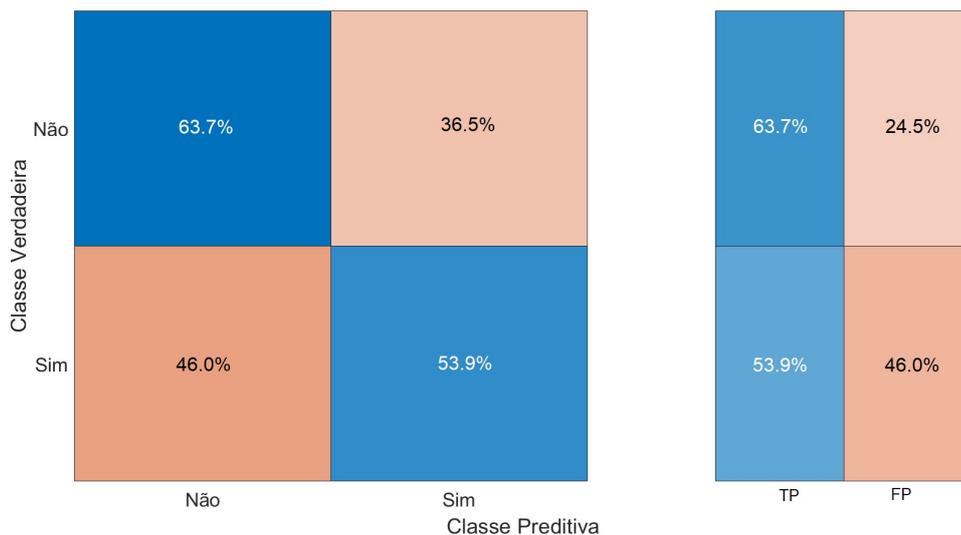
No que se refere às simulações referentes à rede MLP, podemos observar as mesmas métricas de avaliação do algoritmo anterior. Conforme mencionado na seção de metodologia, o melhor resultado de rede neural na configuração proposta, isto é, 3 camadas internas com 50,25 e 12 neurônios respectivamente, além da camada de entrada e camada de saída, aconteceu na situação no qual a base de dados foi dividida em 60% de treinamento e 40% para testes. Logo, este cenário já se diferencia do anterior, cujo melhor resultado era oriundo de uma divisão distinta.

Por meio da observação da tabela 3, alguns pontos podem ser notados. Pode-se observar inicialmente que, o melhor modelo obtido em termos de acurácia, ou seja, quantidade de instâncias classificadas corretamente, foi a que obteve o segundo maior erro por época. Em conjunto

com os demais dados presentes na tabela, pode-se observar uma relação entre o número de épocas e o erro por época: Quanto menor a quantidade de épocas (ciclo de aprendizagem através dos exemplos de treinamento), menor a quantidade de ciclos de aprendizagem e portanto, maior tende a ser o erro. A título de exemplificação, para 100 épocas utilizadas, o erro tende a se aproximar de **0,1**, o que comparado aos demais valores apresentados, pode ser considerado um alto erro.

Conforme já mencionado anteriormente, a acurácia do modelo NÃO pode ser utilizada como único e exclusivo critério na escolha da rede neural. Para efetuar esta seleção, é necessário observar sim as acurácias maiores, mas também observar a taxa de aprendizagem obtida (erro por época). Com relação às métricas de avaliação qualitativas da, obteve-se a matriz a matriz de confusão exposta na figura 30.

Figura 30 – Matriz de confusão para a rede neural MLP obtida



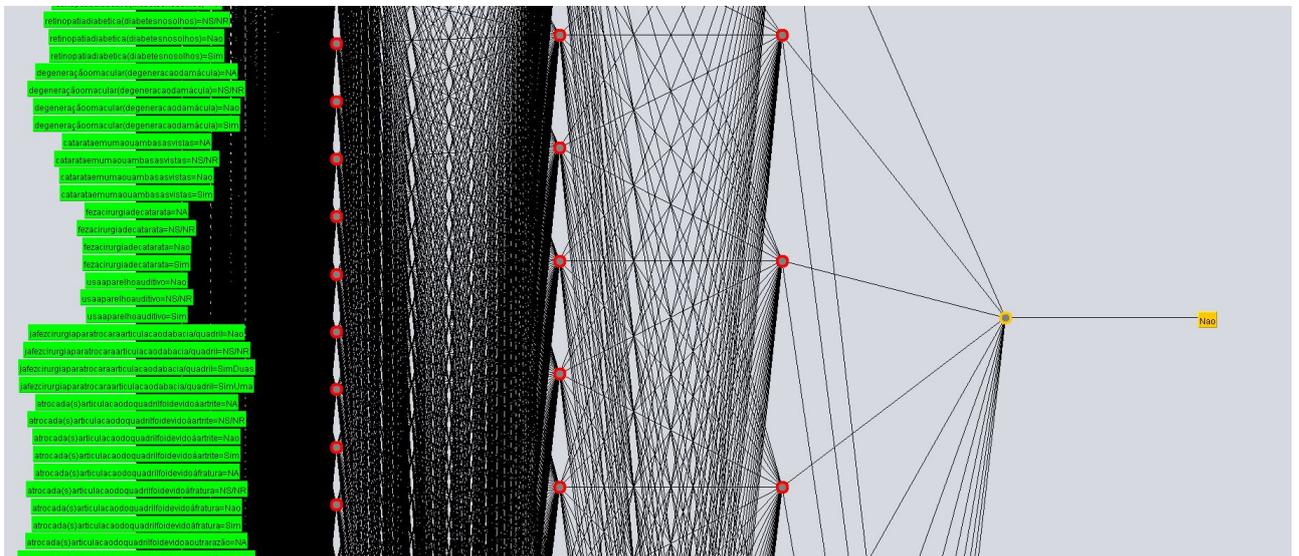
Fonte: Autores

Observa-se, portanto, que o modelo obteve uma precisão de 53,9% para respostas "Sim" e 63,7% para respostas "Não", tornando o modelo confiável, aceitável e equilibrado, ou seja, sem *overfitting*. Além disso, o modelo possui a vantagem de poder ser obtido rapidamente na plataforma WEKA, isto é, possui simulação rápida em comparação com as simulações com grande quantidade de épocas. Esta observação é importante pois, para simulações de redes neurais cuja complexidade pode ser elevada, a simulação pode durar horas. O fato de ser gerado um modelo confiável e rápido de ser obtido constitui-se, portanto, como uma vantagem do modelo preditivo.

No que se refere aos pesos calculados pelo software, foi possível identificar algumas observações interessantes. Variáveis relacionadas à capacidade de locomoção e movimentação do idoso obtiveram pesos significativos nos nós de entrada da rede. Destaca-se também a variável referente à qualidade do sono, que também apresentou pesos maiores em alguns nós. Além disso, os nós superiores da redes neurais apresentaram maior valores de *thresholds*, ou seja, valor responsável pela sua ativação. Ainda relacionados ao valor de ativação, praticamente todos os nós apresentaram valores negativos de *threshold*, o que indica a completa ativação da rede neural referente aos dados inseridos.

Em relação ao número de sinapses, ou seja, conexões que o neurônio recebe e transmite aos nós seguintes, pôde-se observar que tanto o nó de saída correspondente à resposta "Não", quanto o nó de saída correspondente a resposta "Sim", apresentaram o mesmo número de sinapses, 12 no total. Este aspecto demonstra que a rede obtida não requer grandes esforços para que ambas as classificações seja efetuadas. A figura 31 exibe, no contexto do resultado real de simulação, as sinapses referentes ao nó de saída "Não", contendo a camada de entrada, tres camadas ocultas e classificação de saída.

Figura 31 – Visualização gráfica de sinapses para a MLP obtida



Fonte: Autores

A tabela 5 exibe os resultados gerais para o modelo obtido. Apesar da rede em si poder ser visualizada na janela gráfica do software, assim como a árvore de decisão, não será possível incluir uma imagem completa neste documento. Não obstante, o modelo textual da rede neural estará presente em sua íntegra no **Apêndice C** deste trabalho, incluindo todos os

pesos, acurácias, sensibilidades, quantidades de instâncias e outros parâmetros conforme aqui mencionados.

Tabela 5 – Resultados gerais para a rede neural MLP obtida através do WEKA

	Resultados gerais - Rede neural MLP
Quantidade de instâncias	4410
Divisão Treino/Teste	60% 40%
Acurácia	58,65%
Precisão (Verdadeiro positivo)	60,00%
Verdadeiro negativo	57,50%
Falso positivo	36,50%
Falso negativo	46,00%
Sensibilidade	58,70%
Camada de entrada (<i>Batch size</i>)	100
Número de camadas ocultas	3
Números de neurônios respectivos	50,25 e 12
Variável com maior peso registrado	Tem dificuldade para estender um ou dois braços acima dos ombros?
Maior peso encontrado (aproximado)	7,25584249

Fonte: Autores

6 CONCLUSÃO

Conforme as projeções do Departamento de Assuntos Econômicos e Sociais das Nações (2017), a população idosa mundial cresce rapidamente, com estimativa de atingir 25% da população global em 2050, e de acordo com o relato do Estudo Longitudinal da Saúde dos Idosos Brasileiros (ELSI-Brasil), o avanço da idade da população é seguido pelo aumento da probabilidade de quedas. Em vista disso, faz-se necessário soluções preventivas para mitigar os danos direcionados a esse público.

Diante do exposto, foi criado um modelo computacional estruturado em inteligência artificial que prediz a probabilidade de queda dos idosos baseado em seus dados clínicos de fácil acesso, o qual obteve bons resultados de predição avaliados pelo seu percentual de precisão de acertos, seu percentual de verdadeiros positivos e seu percentual de falsos positivos.

A pesquisa partiu da hipótese de que podemos prever a probabilidade de queda de um indivíduo idoso através de uma rede neural de camada única treinada, no entanto verificou-se durante o trabalho que é necessária uma rede neural de múltiplas camadas para que o sistema possa prever as probabilidades de quedas com uma boa qualidade de acerto.

O grande problema derivado das inevitáveis quedas do público idoso é solucionado graças ao sistema desenvolvido no trabalho, que ao prever a probabilidade de queda do indivíduo, possibilita que uma instituição cuidadora ou cuidador pessoal que esteja sob seus cuidados, de tomar medidas preventivas, e remediar a queda e suas conseqüentes complicações.

A respeito do desenvolvimento do sistema, primeiramente foi realizada a escolha da base de dados do Estudo Longitudinal da Saúde dos Idosos Brasileiros (ELSI-Brasil), que obteve 9142 amostras, posteriormente efetuou-se o tratamento da base utilizando o software Stata para a visualização e filtragem da mesma, por conseguinte, para que não houvesse um super treinamento da rede neural efetuamos um balanceamento de amostras da base entre valores positivos (2205) e negativos (2205) para queda.

O resultado da modelagem da árvore de decisão foi de uma árvore fina, com elevado nível de profundidade, que foi capaz de identificar a presença de queda em uma relação 6 para 4, isto é, em cada 10 casos, 6 poderiam ser identificados como corretos, apresentando também os parâmetros de precisão, recall e especificidade aceitáveis e equilibrados. Já o resultado oriundo das simulações para uma rede neural MLP, o modelo adotado conta com 5 camadas no total, 1 de entrada, 1 de saída e 3 ocultas com 50, 25 e 12 células respectivamente, tendo seus maiores pesos relacionados a variáveis de locomoção do idoso. Assim como a árvore de decisão, a MLP

apresentou bons índices de precisão, recall e especificidade, tendo o modelo sido salvo para ser atualizado e se estudado mais a fundo.

Entretanto, foram vivenciadas algumas dificuldades durante o desenvolvimento do projeto, como por exemplo, não poder realizar a captação de dados e desenvolvimento de uma base de dados de autoria própria, devido a atual situação de pandemia. Da mesma forma não podem ser feitos treinamentos mais extensos da rede neural de múltiplas camadas para possível obtenção de melhores resultados da porcentagem de precisão de acertos, devido a impossibilidade de acesso a computadores mais potentes com tempo reduzido de processamento. Por fim não pôde-se desenvolver um protótipo físico que armazene o modelo matemático da rede neural (sistema desenvolvido) e seja testado por indivíduos idosos, devido também a situação de pandemia.

No entanto, recomenda-se que pesquisadores que querem dar sequência a esse trabalho se possível façam a captação e desenvolvam a própria base de dados para obter um sistema que demonstre com maior fidelidade as probabilidades de quedas referentes ao local e a data em questão, recomenda-se também que montem um protótipo que armazene o modelo matemático da rede neural e propiciem testes com o público idoso para captar o feedback do dispositivo e analisar a usabilidade e eficácia do mesmo.

Ainda referente a possíveis trabalhos futuros, durante a execução metodológica, foram identificadas diversas variações de simulações que poderiam ser efetuadas cujos resultados poderiam ser analisados e por esta razão, este trabalho pode ser considerado como um ponto de partida para o estudo da predição do risco de quedas utilizando este algoritmo. Devido sua grande numerosidade, nem todas as variações de simulação puderam ser executadas no escopo deste projeto. Portanto, sugere-se para um trabalho futuro a expansão da modelagem do banco de dados para outros algoritmos de classificação através das duas plataformas (MATLAB® e WEKA), de forma a analisar seus parâmetros de modelagem e verificar resultados promissores da predição do risco de quedas. É válido ressaltar que ambos os softwares já dispõem de outros algoritmos para utilização, não sendo necessária nenhuma adaptação adicional dos arquivos utilizados neste projeto.

Uma outra proposição de trabalho futuro, dotado de um viés mais prático, é a implementação dos modelos obtidos neste trabalho em um ambiente de programação de alto nível, de forma a produzir um software capaz de utilizar os modelos obtidos para predição. Nesta aplicação, um profissional de saúde inseriria as entradas (correspondente as variáveis selecionadas do banco de dados) no programa, que por sua vez calcularia as porcentagens do idoso

vir a cair ou não. Este software, cujos modelos internos de predição poderiam ser atualizados constantemente, auxiliaria no combate desta problemática entre os mais idosos.

REFERÊNCIAS

A. LEVALLEY E J. VERGHESE, A. Ambrose e. Uma comparação de idosos residentes na comunidade com andamentos frontais e parkinsonianos. v. 248, 2006.

ASSUNTOS ECONÔMICOS E SOCIAIS DAS NAÇÕES, Departamento de. Perspectivas para a propulação mundial - Revisão 2017. **Nações Unidas**, v. 53, p. 17, 2017.

BELCHIOR, Luciana Dias. **Caminhada controlada na esteira em pacientes com doença de Parkinson: influência sobre a marcha, equilíbrio e em medidas plasmáticas de parâmetros oxidativos e neurotrofina**. 2014. F. 137. Diss. (Mestrado) – Universidade Federal do Ceará, Ceará.

BITTENCOURT, Helio Radke; CLARKE, Robin T. Use of classification and regression trees (CART) to classify remotely-sensed digital images. **IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No.03CH37477)**, v. 6, 3751–3753 vol.6, 2003.

BIZOVSKA, L. et al. Local dynamic stability during gait for predicting falls in elderly people: A one-year prospective study. **PLoS ONE**, v. 13, 2018.

BREIMAN, L. et al. **Classification and Regression Trees**. [S.l.]: Taylor & Francis, 1984. ISBN 9780412048418. Disponível em: <<https://books.google.com.br/books?id=JwQx-WOmSyQC>>.

BRITO, Rhyann De; FERNANDES, Carlos Alexandre Molena; AMORA, Marcio André Baima. Análise de Desempenho com Redes Neurais Artificiais, Arquiteturas MLP e RBF para um Problema de Classificação de Crianças com Autismo. v. 13, p. 60–76, 2020.

BUISSERET, F. et al. Timed Up and Go and Six-Minute Walking Tests with Wearable Inertial Sensor: One Step Further for the Prediction of the Risk of Fall in Elderly Nursing Home People. **Sensors (Basel, Switzerland)**, v. 20, 2020.

CABETE, Nélia Pereira; CARDOSO, Margarida. Algoritmo CART: Previsão do Desempenho na Matemática do Secundário. **Revista de Ciências de Computação CORE**, v. 1, p. 1–17, 2006.

DITE, Wayne; TEMPLE, V. Desenvolvimento de uma medida clínica de torneamento para adultos mais velhos. v. 81 11, 2002.

FERNANDEZ, Ibai Gorordo; AHMAD, S. A.; WADA, C. Inertial Sensor-Based Instrumented Cane for Real-Time Walking Cane Kinematics Estimation. **Sensors (Basel, Switzerland)**, v. 20, 2020.

FERNEDA, Edberto. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, n. 1, ago. 2006. Disponível em: <<http://revista.ibict.br/ciinf/article/view/1149>>.

FIGUEIREDO RIBEIRO, Karyna; GUERRA, Ricardo; LIMA, Kenio. Instrumentos de avaliação do equilíbrio corporal em idosos. **Brazilian Journal of Kinanthropometry and Human Performance**, p. 1–7, out. 2015.

FLECK, Leandro Silveira. Redes neurais artificiais: principios basicos. **Revista Científica Eletrônica Inovação e Tecnologia**, v. 1, p. 47–57, 2016.

FONSECA, J.M.M.R. **Indução em Árvore de Decisão**. 1994. F. 137. Diss. (Mestrado) – Universidade Nova de Lisboa, Lisboa.

GAMA, João; BRAZDIL, P. Characterization of Classification Algorithms. **Springer Berlin Heidelberg**, v. 1, p. 189–200, 1995.

GASPAROTTO, L. P. R. As quedas no cenário da velhice: conceitos básicos e atualidades da pesquisa em saúde. **Revista Brasileira de Geriatria e Gerontologia**, v. 17, p. 201–209, 2014.

HAGE, R. et al. DYSKIMOT: An Ultra-Low-Cost Inertial Sensor to Assess Head's Rotational Kinematics in Adults during the Didren-Laser Test. **Sensors (Basel, Switzerland)**, v. 20, 2020.

HALL, Mark A. et al. The WEKA data mining software: an update. **SIGKDD Explor.**, v. 11, p. 10–18, 2009.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. [S.l.]: Bookman, 2000. ISBN 8573077182.

I. HAJJAR E L. QUACH E R. JONES E D. KIELY E PEGGY GAGNON E L. LIPSITZ, Anupama Gangavati e. Hypertension, Orthostatic Hypotension, and the Risk of Falls in a Community-Dwelling Elderly Population: The Maintenance of Balance, Independent Living, Intellect, and Zest in the Elderly of Boston Study. v. 59, 2011.

IAKOVAKIS, D.; PAPADOPOULOU, F. A.; HADJILEONTIADIS, L. Fuzzy logic-based risk of fall estimation using smartwatch data as a means to form an assistive feedback mechanism in everyday living activities. **Healthcare technology letters**, v. 3 4, p. 263–268, 2016.

IBGE. **Projeção da População 2018: número de habitantes do país deve parar de crescer em 2047**. 2018. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/21837-projecao-da-populacao-2018-numero-de-habitantes-do-pais-deve-parar-de-crescer-em-2047>>. Acesso em: 7 jun. 2021.

JÚNIOR, Cesar Luiz Buzin Júnior. **SDQI : sistema de detecção de quedas de idosos**. [S.l.: s.n.], 2017. P. 70. Trabalho de Conclusão de Curso (Bacharel em Ciência da Computação), UCS (Universidade de Caxias do Sul), Caxias do Sul, Brazil.

K. PRIEST E A. SALARIAN E DONALD PIERCE E F. HORAK, L. King e. Comparando o Mini-BESTest com a escala de equilíbrio de Berg para avaliar distúrbios de equilíbrio na doença de Parkinson. v. 2012, 2012.

KOTTHOFF, Lars et al. Auto-WEKA 2.0: Automatic model selection and hyperparameter optimization in WEKA. **J. Mach. Learn. Res.**, v. 18, 25:1–25:5, 2017.

KUSPINAR, Ayse et al. Development and validation of an algorithm to assess risk of first-time falling among home care clients. **BMC Geriatrics**, v. 19, out. 2019. DOI: 10.1186/s12877-019-1300-2.

L. RUBENSTEIN E M. TINETTI E K. BREWER E K. CAMERON E E. CAPEZUTI E DP JOHN E S. LAMB E F. MARTIN E P. ROCKEY E M. SUTHER E E. PETERSON E A. SOC E B. SOC, K. RAM. e. Resumo das Diretrizes de Prática Clínica para Prevenção de Quedas em Pessoas Idosas da Sociedade Britânica de Geriatria / American Geriatrics Society. v. 59, 2011.

LIMA-COSTA MF, et al. ESTUDO LONGITUDINAL DA SAÚDE DOS IDOSOS BRASILEIROS, 2015. Disponível em: <<http://elsi.cpqrr.fiocruz.br>>. Acesso em: 8 mai. 2021.

LUQUE, Amalia et al. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. **Pattern Recognit.**, v. 91, p. 216–231, 2019.

MARIANO, Diego. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score. **BIOINFO - Revista Brasileira de Bioinformática e Biologia Computacional**, 2021.

MATHWORKS. **Classification Learner**. 2021. Disponível em: <<https://www.mathworks.com/help/stats/classificationlearner-app.html>>. Acesso em: 21 out. 2021.

MCKECHNIE, D.; PRYOR, J.; FISHER, M. Predicting falls: considerations for screening tool selection vs. screening tool development. **Journal of advanced nursing**, v. 72 9, p. 2238–50, 2016.

MEDEIROS, A. et al. Modelo de suporte à decisão aplicado à identificação de indivíduos não aderentes ao tratamento anti-hipertensivo. **Revista Scielo Brasil**, v. 1, 2014. DOI: <https://doi.org/10.5935/0103-104.20140016>.

MOORE, D. H. Classification and regression trees, by Leo Breiman, Jerome H. Friedman, Richard A. Olshen, and Charles J. Stone. Brooks/Cole Publishing, Monterey, 1984, 358 pages, \$27.95. **Cytometry**, v. 8, p. 534–535, 1987.

MORSE, J. et al. A prospective study to identify the fall-prone patient. **Social science & medicine**, v. 28 1, p. 81–6, 1989.

N. SHEPARD, Julie A. Honaker e. Uso do Teste de Acuidade Visual Dinâmica como um rastreador para idosos residentes na comunidade que caem. v. 21 5, 2011.

OLIVEIRA, LÍLIAN MARIA DE; MAILLARD, Philippe. Aplicação de Árvores de Decisão na Modelagem das Concentrações de Nitrato e Fósforo Total: Estudo de Caso no Rio das Velhas. **Revista Brasileira de Recursos Hídricos**, v. 20, p. 795–808, 2015.

PALM, W. **Introduction to MATLAB for Engineers**. [S.l.]: McGraw-Hill Education, 2012. ISBN 9780073534879.

PIMENTEL, Wendel Rodrigo Teixeira et al. Quedas entre idosos brasileiros residentes em áreas urbanas: ELSI-Brasil. **Revista De Saude Publica**, v. 52, 2018.

QUINLAN, J. Ross. **C4.5: Programs for Machine Learning**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1993. ISBN 1558602380.

R. IVERS E L. CLEMSON E J. CULLEN E MF HAYES E M. TANZER E P. MITCHELL, R. Cumming e. Melhorando a visão para prevenir quedas em idosos frágeis: um ensaio randomizado. v. 55, 2007.

RAUBER, Thomas Walter. Redes Neurais Artificiais. **Universidade Federal do Espírito Santo**, Vitória, ES, 2005.

S. KIVEL "A, L. Salonen e. Doenças oculares e visão prejudicada como possíveis fatores de risco para quedas recorrentes em idosos: uma revisão sistemática. v. 2012, 2012.

SCHOOTEN, Kim van et al. Daily-Life Gait Quality as Predictor of Falls in Older People: A 1-Year Prospective Cohort Study. **PLOS ONE**, v. 11, e0158623, jul. 2016. DOI: 10.1371/journal.pone.0158623.

SILVA, Marília Paula e. **Aplicação de redes neurais artificiais no diagnóstico de falhas em turbinas a gás**. [S.l.: s.n.], 2010. cap. 3. DOI: <https://doi.org/10.17771/PUCRio.acad.16580>.

SOBIE, E. An Introduction to MATLAB. **Science Signaling**, v. 4, 2011.

SOUZA URBANETTO, Janete de et al. Analysis of risk prediction capability and validity of Morse Fall Scale Brazilian version. **Revista gaucha de enfermagem**, v. 37 4, e62200, 2017.

T. HERMAN E ROSSITZA BALTA DJIEVA E T. GUREVICH E NIR GILADI, Jeffrey M. Hausdorff e. Equilíbrio e marcha em idosos com hipertensão sistêmica. v. 91 5, 2003.

TANG, Rong; ZHANG, Xiaojun. CART Decision Tree Combined with Boruta Feature Selection for Medical Data Classification. **2020 5th IEEE International Conference on Big Data Analytics (ICBDA)**, p. 80–84, 2020.

URBANETTO, Janete Souza de et al. [Morse Fall Scale: translation and transcultural adaptation for the Portuguese language]. **Revista da Escola de Enfermagem da U S P**, v. 47 3, p. 569–75, 2013.

VASSALLO, M. et al. A Comparative Study of the Use of Four Fall Risk Assessment Tools on Acute Medical Wards. **Journal of the American Geriatrics Society**, v. 53, 2005.

W. PICKETT E N. YIANNAKOULIAS E B. ROWE E D. SCHOPFLOCHER E L. SVENSON E D. VOAKLANDER, K. Kelly e. **Uso de medicamentos e quedas em idosos que vivem na comunidade**. v. 32 5. [S.l.: s.n.], 2003.

W. SCHIFFMANN M. JOOST, R. Werne. Optimization of the Backpropagation Algorithm for Training Multilayer Perceptrons, p. 5–7, 1994.

**APÊNDICE A – VARIÁVEIS PRESENTES NO BANCO DE DADOS SELECIONADAS
PARA ANÁLISE**

Variáveis utilizadas no sistema
Idade
Usa óculos ou lente de contato?
Como avalia sua visão para enxergar de longe, mesmo usando óculos ou lente?
Como avalia sua visão para enxergar de perto, mesmo usando óculos ou lente?
Quando foi a última vez que fez exame de vista com oftalmologista?
Glaucoma ou suspeita de glaucoma?
Retinopatia diabética (diabetes nos olhos)
Degeneração macular (degeneração da mácula)
Catarata em uma ou ambas as vistas
Fez a cirurgia de catarata?
Usa aparelho auditivo?
Já fez cirurgia para trocar a articulação da bacia/quadril?
A troca da(s) articulação(ções) do quadril foi devido à artrite?
A troca da(s) articulação(ções) do quadril foi devido à fratura?
A troca da(s) articulação(ções) do quadril foi devido a outra razão?
Já fez cirurgia para trocar a articulação do joelho por prótese?
Algum médico já lhe diagnosticou com pressão alta?
Toma remédio para hipertensão?
Algum médico já lhe diagnosticou com diabetes?
Já teve diagnóstico de colesterol alto?
Já teve infarto do coração?
Já teve diagnóstico de insuficiência cardíaca?
Já teve diagnóstico de AVC (derrame)?
Já teve diagnóstico de asma?
Já teve diagnóstico de enfisema, bronquite crônica ou DPOC?
Já teve diagnóstico de artrite ou reumatismo?
Já teve diagnóstico de osteoporose?
Já teve diagnóstico de problema crônico de coluna?
Já teve diagnóstico de depressão?
Já teve diagnóstico de câncer?
Já teve diagnóstico de insuficiência renal crônica?
Já teve diagnóstico de doença de Parkinson?
Já teve diagnóstico de Alzheimer?
Já fez alguma cirurgia de ponte de safena, colocação de stent ou angioplastia?
Nos últimos 3 meses, perdeu peso sem fazer nenhuma dieta?
Com que frequência sentiu que Não conseguiria levar as coisas adiante?
Como avalia a qualidade do seu sono?
Durante o último mês tomou remédio para dormir?
Faz uso de algum medicamento de uso regular contínuo?
Ao sair de casa tem preocupação com a dificuldade p/subir em transporte público?
Tem dificuldade para caminhar 100 metros (uma quadra/quarteirão)?
Tem dificuldade para subir UM lance de escadas sem parar ou descansar?
Tem dificuldade para ficar sentado por aproximadamente duas horas?
Tem dificuldade para se curvar, ajoelhar ou agachar?
Tem dificuldade para estender um ou os dois braços acima dos ombros?

**APÊNDICE B – MODELO TEXTUAL DA ÁRVORE DE DECISÃO OBTIDA PARA
PREDIÇÃO DO RISCO DE QUEDA**

Link para a árvore de decisão obtida como resultado deste trabalho.

**APÊNDICE C – MODELO TEXTUAL DA REDE NEURAL OBTIDA PARA PREDIÇÃO
DO RISCO DE QUEDA**

Link para a rede neural Multilayer Perceptron obtida como resultado deste trabalho.