



**UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO**



MARIA ADRIANA FERREIRA DA SILVA

**STROKE.IA: UMA FERRAMENTA PARA O AUXÍLIO
NA CLASSIFICAÇÃO DE PACIENTES EM RELAÇÃO
AO AVC**

MOSSORÓ

2023

MARIA ADRIANA FERREIRA DA SILVA

**STROKE.IA: UMA FERRAMENTA PARA O AUXÍLIO
NA CLASSIFICAÇÃO DE PACIENTES EM RELAÇÃO
AO AVC**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação - associação ampla entre a Universidade do Estado do Rio Grande do Norte e a Universidade Federal Rural do Semi-Árido, para a obtenção do título de Mestre em Ciência da Computação.

Orientadora: Dra. Angélica Félix de Castro

Coorientador: Dr. Isaac de Lima Oliveira Filho

MOSSORÓ

2023

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

dS586 da Silva, Maria Adriana Ferreira da.
s Stroke.IA: Uma ferramenta para o auxílio na
classificação de pacientes em relação ao AVC /
Maria Adriana Ferreira da da Silva. - 2023.
132 f. : il.

Orientadora: Angélica Félix de Castro.
Coorientadora: Isaac de Lima Oliveira Filho.
Dissertação (Mestrado) - Universidade Federal
Rural do Semi-árido, Programa de Pós-graduação em
Ciência da Computação, 2023.

1. Acidente Vascular Cerebral. 2. Aprendizagem
de Máquina. 3. Ferramenta Inteligente Preditiva.
I. Castro, Angélica Félix de, orient. II. Filho,
Isaac de Lima Oliveira, co-orient. III. Título.

Ficha catalográfica elaborada por sistema gerador automático em conformidade
com AACR2 e os dados fornecidos pelo(a) autor(a).
Biblioteca Campus Mossoró / Setor de Informação e Referência
Bibliotecária: Keina Cristina Santos Sousa e Silva
CRB: 15/120

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

MARIA ADRIANA FERREIRA DA SILVA

STROKE.IA: UMA FERRAMENTA PARA O AUXÍLIO NA CLASSIFICAÇÃO DE PACIENTES EM RELAÇÃO AO AVC

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação para a obtenção do título de Mestre em Ciência da Computação.

Aprovada em: 30/08/2023.

BANCA EXAMINADORA

Prof^ª. Dra. Angélica Félix de Castro
Orientadora - Universidade Federal Rural do
Semi-Árido - UFERSA

Prof^º. Dr. Isaac de Lima Oliveira Filho
Coorientador e Membro Interno -
Universidade do Estado do Rio Grande do
Norte - UERN

Prof^º. Dr. Araken de Medeiros Santos
Membro Interno - Universidade Federal
Rural do Semi-Árido - UFERSA

Prof^ª. Dra. Anne Magaly de Paula Canuto
Membro Externo - Universidade Federal do
Rio Grande do Norte - UFRN

*A Deus por ter me concedido força, saúde e
persistência e aos meus pais Francisco de Assis
(In Memoriam) e Maria Antônia, vocês são
minhas maiores inspirações.*

Agradecimentos

Falar sobre o AVC vai além de discutir apenas uma questão de saúde. Trata-se também das sequelas deixadas por essa condição e dos casos trágicos de morte, como os de meu pai, minha avó e inúmeros outros pais e avós ao redor do mundo. Portanto, gostaria, em primeiro lugar, de expressar minha gratidão a Deus pela oportunidade de contribuir nessa área. Agradeço por ter sido meu alicerce, minha base e meu ponto de paz e fé em todos os momentos. Obrigada, meu Deus, por tudo que tens proporcionado em minha vida. Sem minha fé em Ti, nada disso seria possível.

Também quero agradecer aos meus pais, Maria Antônia e Francisco de Assis (em memória), pois eles me ensinaram os valores mais importantes que se pode aprender ao longo da vida: humildade, persistência e resiliência para enfrentar todas as situações. Este trabalho é nosso!

Agradeço aos meus irmãos, Amanda Alexandra e Alex Silva, à minha sobrinha, Paloma Vitória, e ao meu avô, Antônio Vicente. Vocês foram essenciais.

Agradeço também o meu namorado, Wallace Holanda, que esteve ao meu lado desde o início. Nunca soltou minha mão, mesmo quando eu mesma queria desistir. Ele confiou e acreditou em todas as etapas, mesmo as mais propensas a darem errado. Obrigada por todo o companheirismo, amor e compreensão ao longo desses anos. Amo-te.

Expresso minha gratidão aos meus orientadores, Angélica Félix e Isaac Lima, por não soltarem minha mão e por aceitarem me guiar nesse desafio. Agradeço por todos os ensinamentos, contribuições, respeito e motivação, mesmo quando eu pensava que tudo daria errado. Sou e serei eternamente grata por tudo!

Agradeço também aos professores Araken de Medeiros e Anne Magaly, pela disponibilidade em compor a Banca Examinadora. Também quero agradecer aos profissionais da saúde que participaram dos testes da ferramenta. Vocês foram fundamentais para a conclusão desse trabalho.

Além disso, gostaria de expressar meus sinceros agradecimentos a minha amiga Danielly Gualberto, que compartilhou comigo todos os momentos de angústia e felicidade, que vibrou comigo a cada conquista e ficou preocupada com cada prazo apertado. Muito obrigada, minha amiga, você merece todo o sucesso do mundo.

Por fim, agradeço a todos os meus colegas e professores pelo conhecimento compartilhado e pelas contribuições para este trabalho.

Entrega o teu caminho ao SENHOR;
confia nele, e ELE tudo fará.
Salmos 37:5

Resumo

Ao longo dos anos, houve uma crescente alta na ocorrência de casos de AVC, devido ao aumento da população idosa. Dados atuais indicam que o AVC é um dos principais causadores de morte e invalidez em todo o mundo, atingindo milhões de pessoas e deixando os sobreviventes com inúmeras sequelas, sejam elas físicas ou mentais. Em sua fase inicial, o AVC pode apresentar sinais indicativos antes mesmo de sua ocorrência. Dentre esses sinais indicativos, a dormência em uma parte do corpo, confusão mental e dificuldade para falar ou compreender são os mais comuns. A identificação precoce desses sinais é de extrema importância, diminuindo o risco de morte instantânea do paciente e o risco de deficiências que podem afetar significativamente sua vida. Muitos fatores como diabetes, tabagismo, hipertensão arterial e outros, também podem favorecer para o surgimento do AVC, o que aumenta cada vez mais os índices de mortalidade, tornando-se necessário o conhecimento desses fatores para contribuir com medidas preventivas precoces. Na literatura, técnicas de inteligência artificial são amplamente estudadas como parâmetros para sistemas preditivos visando auxiliar na identificação precoce do Acidente Vascular Cerebral (AVC). Dentre essas técnicas, as de Aprendizagem de Máquina (AM) são indicadas em sistemas preditivos. Desta forma, o objetivo deste trabalho é apresentar uma ferramenta preditiva inteligente baseada em AM para auxiliar os profissionais da saúde no diagnóstico de pacientes propensos a terem um AVC, em especial na prevenção dos fatores de risco e sinais indicativos. Uma Revisão Sistemática da Literatura (RSL) foi realizada e identificou-se um número significativo de trabalhos que fizeram a utilização de abordagens preditivas para auxiliar no diagnóstico do AVC. Neste estudo, foi utilizado a biblioteca PyCaret para selecionar o melhor algoritmo entre 14 opções, destacando o *Random Forest* como melhor algoritmo. Após isso, identificou-se atributos com menor importância para o modelo e fez-se a criação de três novas bases de dados: Base21, Base16 e Base11. A Base21 se destacou com acurácia, precisão, *f1-score* e *recall* de 90,74%, AUC de 0,97 e kappa de 0,84. Por fim, desenvolveu-se uma aplicação web para exemplificar a utilidade prática do modelo. Essa aplicação foi testada por profissionais da área da saúde, produzindo resultados notáveis e pertinentes.

Palavras-chave: Acidente Vascular Cerebral, Aprendizagem de Máquina, Ferramenta Inteligente Preditiva.

Abstract

Over the years, there has been an increasing increase in the occurrence of stroke cases, due to the increase in the elderly population. Current data indicate that stroke is one of the main causes of death and disability worldwide, affecting millions of people and leaving survivors with numerous consequences, whether physical or mental. In its initial phase, a stroke may present indicative signs even before it occurs. Among these indicative signs, numbness in a part of the body, mental confusion and difficulty speaking or understanding are the most common. Early identification of these signs is extremely important, reducing the patient's risk of instant death and the risk of disabilities that can significantly affect their life. Many factors such as diabetes, smoking, high blood pressure and others can also contribute to the onset of stroke, which increasingly increases mortality rates, making it necessary to know these factors to contribute to early preventive measures. In the literature, artificial intelligence techniques are widely studied as parameters for predictive systems to assist in the early identification of stroke. Among these techniques, Machine Learning (ML) are recommended in predictive systems. Therefore, the objective of this work is to present an intelligent predictive tool based on AM to assist healthcare professionals in diagnosing patients prone to having a stroke, especially in preventing risk factors and indicative signs. A Systematic Literature Review (SLR) was carried out and a significant number of studies were identified that used predictive approaches to assist in the diagnosis of stroke. In this study, the PyCaret library was used to select the best algorithm among 14 options, highlighting *Random Forest* as the best algorithm. After this, attributes with less importance for the model were identified and three new databases were created: Base21, Base16 and Base11. Base21 stood out with accuracy, precision, *f1-score* and *recall* of 90.74%, AUC of 0.97 and kappa of 0.84. Finally, a web application was developed to exemplify the practical usefulness of the model. This application was tested by healthcare professionals, producing notable and relevant results.

Keywords: Stroke, Machine Learning, Predictive Smart Tool.

Lista de ilustrações

Figura 1 – Representação da metodologia de pesquisa pela perspectiva do <i>Design Science</i>	21
Figura 2 – Maiores causas de morte no mundo em 2019.	26
Figura 3 – Tipos de AVC.	26
Figura 4 – AVC Hemorrágico.	27
Figura 5 – AVC Isquêmico.	28
Figura 6 – Definições da IA.	31
Figura 7 – Validação cruzada do tipo 10- <i>fold</i>	33
Figura 8 – Visão geral de classificação com PyCaret.	34
Figura 9 – Ferramentas utilizadas.	47
Figura 10 – Algoritmos e modelos utilizados na classificação.	48
Figura 11 – Etapas da criação do modelo preditivo.	56
Figura 12 – Importância dos atributos com a diminuição média da impureza.	63
Figura 13 – Importância dos atributos com a permutação de recursos.	64
Figura 14 – Relação da ocorrência do AVC com os sinais indicativos.	66
Figura 15 – Relação da ocorrência do AVC com os sinais indicativos.	66
Figura 16 – Relação da ocorrência do AVC com os fatores de risco.	67
Figura 17 – Relação da ocorrência do AVC com os fatores de risco.	68
Figura 18 – Arquitetura da ferramenta proposta.	70
Figura 19 – Diagrama de casos de uso.	72
Figura 20 – Diagrama Entidade-Relacionamento.	74
Figura 21 – Tela inicial do sistema.	75
Figura 22 – Visualização de todos os pacientes.	76
Figura 23 – Cadastro dos dados pessoais do paciente.	76
Figura 24 – Edição e busca do paciente.	77
Figura 25 – Visualização de todos os quadros clínicos.	77
Figura 26 – Cadastro do quadro clínico 1.	78
Figura 27 – Cadastro do quadro clínico 2.	78
Figura 28 – Cadastro do quadro clínico 3.	79
Figura 29 – Classificação do paciente gerada pelo sistema.	80
Figura 30 – Ranking dos algoritmos gerados pelo PyCaret.	82
Figura 31 – Matriz de confusão para a Base25.	84
Figura 32 – Matriz de confusão da Base21.	85
Figura 33 – Matriz de confusão para a Base16.	86
Figura 34 – Matriz de confusão Base11.	87
Figura 35 – Fatores de risco mais relevantes para a ocorrência do AVC.	90

Figura 36 – Sintomas mais comuns relacionados à ocorrência do AVC. 91

Lista de quadros

Quadro 1 – Fatores de risco para desenvolvimento de AVCi	29
Quadro 2 – Matriz de confusão.	36
Quadro 3 – Termos de busca.	43
Quadro 4 – Trabalhos selecionados.	46
Quadro 5 – Principais limitações identificadas nos trabalhos.	49
Quadro 6 – Métricas utilizadas na validação das soluções	51
Quadro 7 – Principais atributos utilizados nos estudos do capítulo 3.	60
Quadro 8 – Atributos resultantes após o pré-processamento	61
Quadro 9 – Bases de dados geradas	65
Quadro 10 – Requisitos Funcionais.	71
Quadro 11 – Parâmetros do modelo utilizando o PyCaret	82
Quadro 12 – Parâmetros do <i>Random Forest</i> utilizando o <i>scikit-learn</i>	83
Quadro 13 – Questionário sobre o perfil do participante	89
Quadro 14 – Roteiro de tarefas na avaliação da ferramenta	93
Quadro 15 – Entrevista pós-teste.	97

Lista de tabelas

Tabela 1 – Número de trabalhos retornados para cada fonte de busca nas quatro etapas.	45
Tabela 2 – Avaliação de qualidade dos trabalhos selecionados.	53
Tabela 3 – Resultados da Base25	83
Tabela 4 – Resultados da Base21.	84
Tabela 5 – Resultados da Base16.	85
Tabela 6 – Resultados da Base11.	86

Lista de abreviaturas e siglas

AM	Aprendizagem de Máquina
AVC	Acidente Vascular Cerebral
AVCh	Acidente Vascular Cerebral Hemorrágico
AVCi	Acidente Vascular Cerebral Isquêmico
AIT	Ataque Isquêmico Transitório
TICs	Tecnologias da Informação e do Conhecimento
TC	Tomografia Computadorizada
IA	Inteligência Artificial
SVM	Máquina de Vetor de Suporte
LS	Lista de Seleccionados
LR	Lista de Removidos
ID	Identificador
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
NIH	<i>National Institutes of Health</i>
CHS	<i>Cardiovascular Health Study</i>
PRC	<i>Precision Recall Curve</i>
PCA	Análise de Componentes Principais
IST	<i>The International Stroke Trial</i>
SRS	<i>Stroke Risk Scorecard</i>
RFECV	Eliminação de Característica Recursiva com Validação Cruzada
SGBD	Sistema de Gerenciamento de Banco de Dados
EUA	Estados Unidos da América
CE	Critério de Exclusão

CI	Critério de Inclusão
FN	Falso Negativo
FP	Falso Positivo
RSL	Revisão Sistemática da Literatura
QC	Questão Conceitual
QGP	Questão Geral de Pesquisa
OMS	Organização Mundial da Saúde
QP	Questão de Pesquisa
QPT	Questão Prática
QS	Questão Secundária
QT	Questão Tecnológica
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
AUC	<i>Area Under the Curve</i>
SMOTE	<i>Synthetic Minority Over-sampling Technique</i>
RF	Requisito Funcional
DER	Diagrama Entidade-Relacionamento

Sumário

1	INTRODUÇÃO	17
1.1	Contexto e Problema	17
1.2	Questões de Pesquisa	19
1.3	Objetivos	20
1.4	Metodologia	20
1.5	Organização do Documento	22
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Promoção do bem-estar e prevenção de doenças	23
2.2	Acidente Vascular Cerebral	24
2.2.1	AVC Hemorrágico	27
2.2.2	AVC Isquêmico	27
2.3	Sistemas Inteligentes	29
2.4	Inteligência Artificial	30
2.5	Aprendizagem de Máquina	31
2.6	Aprendizado Supervisionado	32
2.6.1	Bibliotecas de aprendizado de máquina	33
2.6.1.1	PyCaret	34
2.6.1.2	Scikit-Learn	35
2.6.2	Métricas de avaliação	35
2.7	Ferramentas Utilizadas	38
2.7.1	Streamlit	38
2.7.2	Python	39
2.7.3	NumPy	39
2.7.4	Pandas	39
2.7.5	Banco de dados PostgreSQL	40
2.7.6	Ambiente de desenvolvimento - PyCharm	40
2.8	Técnicas de Validação	40
2.9	Considerações Finais	41
3	MAPEAMENTO SISTEMÁTICO DA LITERATURA	42
3.1	Questões de Pesquisa	42
3.2	Processo de Busca	42
3.3	CrITÉrios para seleção e avaliação	43
3.4	Seleção dos Trabalhos	44
3.5	Resultados	45

3.6	Considerações Finais	54
4	DEFINIÇÃO E CONSTRUÇÃO DO MODELO DE PREDIÇÃO . . .	55
4.1	Descrição do Modelo de Predição	55
4.2	Base de Dados	58
4.3	Pré-Processamento dos Dados	59
4.4	Seleção de Recursos	63
4.5	Análise dos Dados	65
4.6	Considerações Finais	68
5	UMA FERRAMENTA PARA AUXÍLIO NA CLASSIFICAÇÃO DE PACIENTES EM RELAÇÃO AO AVC	69
5.1	Visão Geral	69
5.2	Descrição e Modelagem da Ferramenta	70
5.3	STROKE.IA - Uma Ferramenta para Auxílio na Classificação de Pacientes em Relação ao AVC	75
5.4	Considerações Finais	80
6	RESULTADOS E DISCUSSÕES	81
6.1	Análise do Desempenho do Modelo Preditivo	81
6.2	Análise de Desempenho e Usabilidade da Ferramenta Preditiva . . .	87
6.2.1	Questionário pré-teste	87
6.2.2	Teste de usabilidade	92
6.2.3	Entrevista pós-teste	96
6.3	Discussões dos resultados	98
7	CONCLUSÕES	101
	REFERÊNCIAS	103
	APÊNDICE A – DESCRIÇÃO DOS ATRIBUTOS DA BASE	109
	APÊNDICE B – ROTEIRO DO TESTE	127

1 Introdução

1.1 Contexto e Problema

As Tecnologias da Informação e do Conhecimento (TICs) interferem na vida profissional de toda e qualquer pessoa e, no âmbito da saúde apresentam um crescimento fundamental no que refere-se à prevenção, diagnóstico e tratamento de doenças (NASCIMENTO *et al.*, 2019). A utilização de sistemas de informação para a saúde tem o propósito de oferecer métodos que visem a melhora no atendimento de serviços de saúde e a falta de sua oferta (NASCIMENTO *et al.*, 2019).

Uma das propostas de tecnologias voltadas a este contexto é o uso de sistemas inteligentes. Tais sistemas podem contribuir para a definição de abordagens que auxiliem em escolhas precisas no qual o conhecimento é baseado em experiências já vividas (QUILICI-GONZALEZ; ZAMPIROLI, 2014). Esses sistemas podem ser utilizados para auxiliar no diagnóstico de doenças graves onde o tratamento mais adequado é a detecção precoce de seus fatores de risco, como o Acidente Vascular Cerebral (AVC).

O AVC define-se como uma modificação no fluxo sanguíneo do cérebro, e pode ser categorizado em três tipos: Acidente Vascular Cerebral Isquêmico (AVCi), Acidente Vascular Cerebral Hemorrágico (AVCh) e Ataque Isquêmico Transitório (AIT), sendo o AVC Isquêmico o tipo mais comum (BVS, 2015). Conforme dados recentes, o AVC é uma das principais causas de falecimentos e deficiências em todo o mundo (CAMPBELL; KHATRI, 2020).

Em sua fase inicial, o AVC pode manifestar sinais indicativos antes mesmo de sua ocorrência. Os sinais que ocorrem com maior frequência são: dormência em apenas um lado do corpo, confusão mental, dificuldade para falar ou compreender e outros (BVS, 2015). A identificação precoce desses sinais é de extrema importância, pois uma lesão muito grave pode causar morte instantânea do paciente ou deixar deficiências que podem afetar significativamente sua vida (BRASIL, 2013). Além disso, essa identificação precoce permite o início imediato do acompanhamento do paciente antes da ocorrência do AVC, resultando na diminuição das sequelas e na prevenção do AVC (CAMPBELL; KHATRI, 2020).

Conhecer os fatores de risco do AVC também é fundamental para prevenir a sua ocorrência e como consequência, diminuir os custos envolvidos na reabilitação e internação hospitalar (BRASIL, 2013). Os principais fatores de risco associados ao AVC são: hipertensão, idade, raça, dislipidemia, sexo, diabetes, tabagismo, sedentarismo, histórico de AVC na família (MESCHIA *et al.*, 2014). A realização de exames regulares são as

atitudes mais recomendadas pelas diretrizes de saúde para evitar a ocorrência do AVC (PANDIAN *et al.*, 2018).

Os fatores de risco do AVC podem ser classificados em modificáveis e não modificáveis. Os fatores de risco modificáveis são aqueles que a pessoa tem a possibilidade de controlar, tais como: hipertensão, colesterol, diabetes, tabagismo, sedentarismo entre outros (MESCHIA *et al.*, 2014). Os fatores de risco não modificáveis são fatores que não podem ser controlados como: histórico de AVC na família, idade, raça, sexo (MESCHIA *et al.*, 2014).

Estimativas apontam que a cada seis pessoas ao redor do mundo, uma delas pode enfrentar um AVC em qualquer fase da vida (MIRANDA, 2023). Tais dados mostram a necessidade de desenvolver soluções voltadas para a melhoria da saúde e qualidade de vida dessas pessoas, principalmente no que diz respeito à reabilitação, prevenção e diagnóstico de doenças (BRASIL, 2013).

Na literatura, diversas soluções vêm sendo desenvolvidas com o objetivo de auxiliar no diagnóstico do AVC, utilizando técnicas de inteligência artificial. O trabalho de Tursynova *et al.* (2021), por exemplo, descreve a aplicação de aprendizado de máquina e ressonância magnética para ajudar no diagnóstico de distúrbios cerebrais. Em Taleb *et al.* (2017), é apresentada uma abordagem para previsão do tempo de permanência hospitalar de pacientes com AVC utilizando técnicas de mineração de dados. O propósito principal dessas soluções é ajudar os profissionais da saúde a fazerem previsões clínicas com maior precisão. No entanto, o diagnóstico do AVC, especialmente por meio da utilização de exames por imagem, pode ser caro e difícil de ser realizado (YU *et al.*, 2020).

Neste caso, o reconhecimento precoce desses sinais e fatores de risco do AVC facilita no atendimento inicial e se torna vital para a identificação de complicações que venham a acontecer (BRASIL, 2013). Também constata-se que para controlar tais fatores de risco e sinais indicativos, faz-se necessário a adoção de hábitos saudáveis de modo que previnam os problemas causados individualmente por cada fator de risco (BRASIL, 2013). Além disso, é necessário o desenvolvimento de ferramentas para ajudar o médico em um diagnóstico mais rápido de modo a auxiliá-lo em decisões mais assertivas (OLIVEIRA *et al.*, 2019).

Diante dessa perspectiva, o presente trabalho propõe o desenvolvimento de uma ferramenta inteligente baseada em AM, com o objetivo de auxiliar os profissionais da saúde no diagnóstico de pacientes com probabilidade de desenvolver um AVC, priorizando a prevenção de fatores de risco e a identificação de sinais indicativos.

1.2 Questões de Pesquisa

Este trabalho adota o *Design Science* como paradigma de trabalho. Desta forma, são formuladas questões para conduzir a metodologia na qual as mesmas são respondidas ao longo da execução da pesquisa. De acordo com essa perspectiva, a Questão Geral de Pesquisa (QGP) a ser respondida é:

QGP: O uso de técnicas de inteligência artificial podem auxiliar profissionais da saúde no diagnóstico de pacientes com probabilidade de desenvolver um AVC no contexto de prevenção dos fatores de riscos e sinais indicativos?

Para explicitar os objetivos da pesquisa, Wieringa (2014) propõe um detalhamento da QGP, dividindo-a em: Questões Conceituais (QC), Questões Tecnológicas (QT) e Questões Práticas (QP). A seguir, a QGP é reestruturada em questões mais específicas.

QC: O que são e como são desenvolvidas soluções inteligentes baseadas em técnicas de AM?

QC1 Quais as técnicas mais adequadas?

QC2 Quais as abordagens utilizadas na literatura para o desenvolvimento dessas soluções?

QC3 Quais as etapas necessárias para a criação dessas soluções?

QT: Quais técnicas de AM são mais adequadas no desenvolvimento de soluções inteligentes preditivas?

QT1 Quais ferramentas e linguagens podem ser usadas no desenvolvimento de soluções preditivas?

QP: Quais métodos podem ser utilizados para avaliar qualidade dessas soluções?

QP1 Quais métricas podem ser consideradas adequadas para obtenção dos resultados?

QP2 Quais requisitos de usabilidade, aceitação e utilidade podem ser percebidos pelo usuário da aplicação?

QP3 Quais as limitações encontradas?

1.3 Objetivos

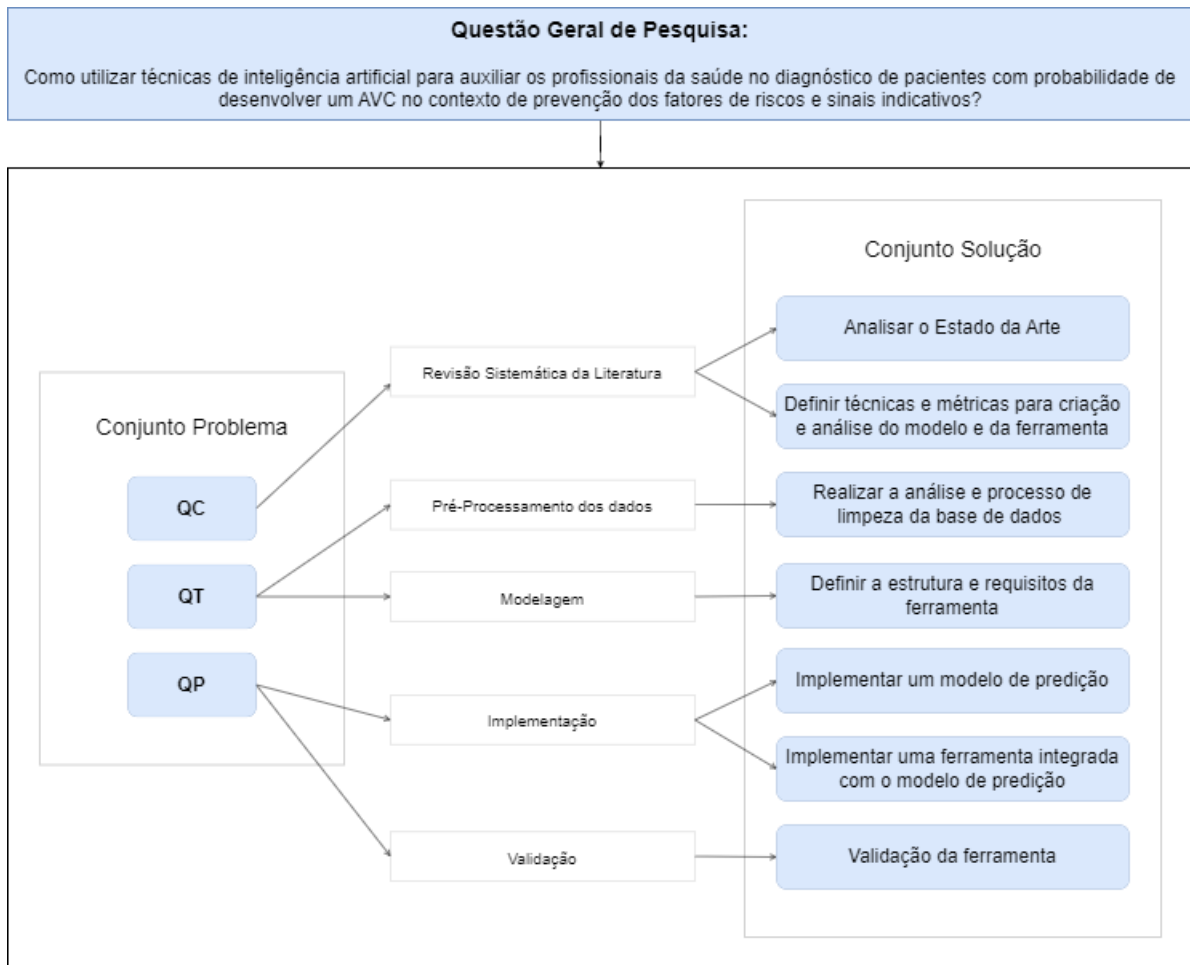
O proposito geral deste trabalho é **desenvolver uma ferramenta inteligente baseada em AM que auxilie na identificação de pacientes com probabilidade de desenvolver um AVC no contexto de prevenção dos fatores de risco e sinais indicativos**. Para alcançar o objetivo geral deste trabalho, alguns objetivos específicos que devem ser alcançados incluem:

- realizar um mapeamento sistemático sobre as principais soluções e métodos disponíveis na literatura para a prevenção do AVC;
- explorar técnicas e algoritmos de inteligência artificial através de pesquisa e levantamento bibliográfico;
- selecionar uma ou mais bases de dados hospitalares, seja por meio de pesquisa de campo ou utilizando conjuntos de dados disponíveis em repositórios de dados abertos;
- desenvolver e implementar um modelo preditivo baseado em técnicas de aprendizado de máquina para classificar os pacientes;
- realizar a análise dos requisitos e elaborar a modelagem estrutural de uma ferramenta inteligente;
- implementar as principais funcionalidades da ferramenta inteligente, utilizando o modelo preditivo desenvolvido anteriormente;
- avaliar o desempenho da ferramenta com profissionais da saúde, a fim de analisar a viabilidade e a usabilidade do mesmo.

1.4 Metodologia

A metodologia deste trabalho foi definida a partir do *Design Science*. Diante desta perspectiva, para alcançar os objetivos propostos pela pesquisa, a metodologia foi segmentada em sete etapas. Após a definição do conjunto problema (questões de pesquisa), foi estabelecida a metodologia utilizada para chegar ao conjunto de soluções (artefatos) desejadas. Na Figura 1 é possível ver uma representação deste processo.

Uma RSL é um método que responde às QC, com foco no estado da arte e na definição de técnicas e ferramentas para a criação do modelo e da ferramenta. As QT são respondidas por meio do pré-processamento dos dados e da modelagem da ferramenta. A implementação resulta na criação de uma ferramenta inteligente preditiva. Por fim, a validação envolve a aprovação e aceitação da ferramenta pelos usuários, considerando sua usabilidade e viabilidade. As etapas percorridas pela metodologia utilizada serão definidas a seguir:

Figura 1 – Representação da metodologia de pesquisa pela perspectiva do *Design Science*.

Fonte: Autoria.

- **Revisão Sistemática da Literatura:** Uma RSL é uma abordagem de pesquisa que busca mapear, localizar, avaliar e complementar os resultados de estudos relacionados a uma questão de pesquisa específica (DRESCH; LACERDA; JÚNIOR, 2015). Neste trabalho, a RSL determinou o estado de soluções que fazem o uso de técnicas de aprendizado de máquina para ajudar na prevenção do AVC antes mesmo da sua ocorrência.
- **Pré-Processamento dos dados:** Segundo Ferrari e Castro (2016), a etapa de pré-processamento de dados é um conjunto de técnicas voltadas para o conhecimento e preparação dos dados de forma adequada para um melhor entendimento do conhecimento neles contido. As bases de dados podem variar em características, dimensões e formatos, e frequentemente apresentam ruídos, imperfeições, valores incorretos, inconsistentes e outras inconsistências. Nesse caso, a utilização de técnicas de pré-processamento podem ser utilizadas para melhorar a qualidade dos dados por meio da eliminação ou minimização desses problemas (FACELI *et al.*, 2021). Com isso, torna-se importante a aplicação de técnicas de pré-processamento para este

trabalho a citar: limpeza, desbalanceamento e redução dos dados.

- **Modelagem:** A modelagem é um processo essencial que envolve a definição detalhada da estrutura, comportamento e requisitos. Neste trabalho, para essa etapa foi identificado componentes, relações, fluxos de dados, interfaces e regras de negócio cruciais para o desenvolvimento e implementação eficientes da ferramenta.
- **Implementação:** Segundo Sommerville (2011), a implementação é o processo de transformar uma especificação em um sistema que pode ser executado, no qual envolve processos de projeto e programação de software em termos de componentes de código. Com os conhecimentos adquiridos na etapa anterior, esta etapa consistiu no desenvolvimento e implementação do modelo preditivo e da ferramenta inteligente preditiva em termos de desenvolvimento dos componentes de código.
- **Validação:** De acordo com Pressman e Maxim (2016), a validação de um software está relacionada com um conjunto de tarefas que asseguram que um determinado software foi criado de acordo com os requisitos. Nesse caso, a validação da ferramenta foi realizada com profissionais da saúde, objetivando verificar se a mesma atende às necessidades e se demonstrou viabilidade e usabilidade satisfatórias.

1.5 Organização do Documento

Além da introdução descrita neste capítulo, este documento está dividido em outros seis capítulos. No Capítulo 2 é exposta a fundamentação teórica, destacando os principais conceitos sobre as temáticas pertinentes a este trabalho. No Capítulo 3 é descrito o protocolo de Revisão Sistemática de Literatura e seus resultados alcançados no âmbito desta pesquisa. O Capítulo 4 apresenta a descrição do pré-processamento dos dados e a criação do modelo preditivo. O Capítulo 5 apresenta a modelagem da ferramenta em termos de definição de requisitos, regras e a apresentação das telas da ferramenta preditiva. No Capítulo 6 são expostos os resultados do modelo preditivo e os resultados do teste de usabilidade realizados com a ferramenta. E, por fim, no Capítulo 7 são apresentadas as considerações finais, as limitações e as sugestões de trabalhos futuros.

2 Fundamentação Teórica

Este capítulo é voltado a descrição da fundamentação teórica acerca dos conceitos e temáticas pertinentes a este trabalho. Inicialmente, é apresentado sobre a conscientização à saúde e medidas de prevenção a doenças (Seção 2.1). Após isso, são discutidos os aspectos relacionados ao AVC (Seção 2.2). Em seguida, são ilustrados os principais conceitos de sistemas inteligentes e técnicas de inteligência artificial com foco na AM (Seção 2.5). Ao final, na Seção 2.9 são apresentadas as considerações finais do capítulo.

2.1 Promoção do bem-estar e prevenção de doenças

A promoção da saúde é um processo que permite às pessoas aumentarem o controle e melhora de sua saúde física, mental e social (BRASIL, 2010). Para se alcançar tal um bem estar geral que englobe tanto a saúde física, mental e social, faz-se necessário que as pessoas ou grupos de pessoas sejam capazes de identificar e realizar ações, para satisfazer as necessidades e mudar ou lidar com o ambiente. Saúde é um conceito que enfatiza artifícios pessoais e sociais bem como capacidades físicas (WHO, 2009). Sendo assim, a promoção da saúde não se limita à responsabilidade do setor da saúde, mas vai além de estilos de vida saudáveis para o bem estar das pessoas (WHO, 2009).

Segundo Czeresnia e Freitas (2009), as definições iniciais de promoção e bem estar à saúde, foram citados pelos autores Winslow e Sigerist, entre os anos de 1920 e 1946. Sigerist definiu quatro tarefas essenciais da medicina, sendo elas: a promoção da saúde, a prevenção das doenças, a recuperação e a reabilitação. Em 1965, Leavell e Clark, a partir da definição de promoção à saúde, criaram um modelo voltado para a história natural das doenças, que constitui três estágios de prevenção: primária, secundária e terciária (CZERESNIA; FREITAS, 2009).

No entanto, verificou-se que o modelo proposto por Leavell e Clark, não era adequado para doenças crônicas não transmissíveis. Assim, na década de 80, após uma carta de Ottawa, as definições voltadas à promoção da saúde foram revistas, tornando-se propósito de políticas públicas em inúmeras regiões do mundo (CZERESNIA; FREITAS, 2009). Após isso, em 1995, Jamouille e Roland apresentaram a definição de prevenção quaternária (ALMEIDA, 2005), tornando-se quatro níveis de prevenção à saúde, vistos a seguir.

- **Prevenção Primária:** tem como propósito implementar estratégias que busquem evitar a ocorrência de problemas de saúde individual ou populacional (BRASIL, 2010).

- **Prevenção Secundária:** tem como propósito identificar uma condição de saúde no início, em uma pessoa ou na população em geral. Tem por objetivo facilitar um diagnóstico definitivo, contribuindo para um tratamento pequeno além de prevenir a propagação da doença após um período (BRASIL, 2010).
- **Prevenção Terciária:** tem como propósito reduzir, em uma pessoa ou na população os danos decorrentes de um problemas de saúde mais grave, incluindo reabilitação (BRASIL, 2010).
- **Prevenção Quaternária:** tem como propósito detectar pessoas em risco de intervenções, diagnósticas em excesso, para protegê-las de novos procedimentos médicos inadequados e apresentando alternativas eticamente mais aceitáveis (BRASIL, 2010).

Na Seção 2.2, será apresentado sobre o AVC, seus tipos, fatores de risco e sinais indicativos.

2.2 Acidente Vascular Cerebral

O AVC, popularmente conhecido como “derrame” ou “trombose”, é uma doença que ocorre quando uma artéria fica obstruída ou rompe, resultando na falta de oxigênio e nutrientes necessários o que pode levar a morte de parte do tecido cerebral (BRASIL, 2013; CAMARGO, 2019). O AVC está ligado ao desenvolvimento rápido de sinais clínicos de distúrbios localizados ou abrangentes, possui início súbito e o paciente pode apresentar incapacidade ou dificuldade para executar movimentos básicos com membros de um lado do corpo (BRASIL, 2013; CAMARGO, 2019).

O AVC, também conhecido como Acidente Vascular Encefálico (AVE) é uma condição que envolve lesões que podem afetar todo o encéfalo, incluindo o cérebro, tronco encefálico e cerebelo. Enquanto o AVC refere-se especificamente a lesões no cérebro. Ambos os termos estão corretos, mas o termo AVE abrange uma variedade mais ampla de lesões e seus efeitos (MA, 2021). Para os propósitos deste trabalho, será utilizado o termo AVC.

O AVC se manifesta de forma inesperada, pois o cérebro não consegue sobreviver sem oxigênio. Seus sintomas ou sinais indicativos mais comuns são: dificuldade de movimentar uma parte do corpo, dificuldade para falar, compreender a fala e assimetria da face. Outros sintomas como dor de cabeça e tontura, embora menos comuns, também podem ser considerados (BRASIL, 2013). Os sintomas do AVC podem ter uma duração de 24 horas ou mais e podem provocar mudanças tanto físicas como mentais, podendo ocorrer em qualquer idade, sendo na fase adulta que ocorre com maior frequência (BRASIL, 2013; CAMARGO, 2019).

Além dos sintomas comuns, também existem fatores de risco que podem ser levados em consideração. Os fatores de risco para a ocorrência do AVC, podem ser classificados


em não modificáveis, modificáveis e de risco potencial. Os fatores de risco modificáveis são caracterizados aos quais a pessoa tem a possibilidade de controlar, tais como: tabagismo, diabetes mellitus, hipertensão arterial sistêmica, dislipidemia, fibrilação atrial e outras doenças cardiovasculares (BRASIL, 2013; BVS, 2015).

Os fatores de risco não modificáveis se caracterizam por não poderem ser controlados, como: idade avançada, sexo, baixo peso ao nascimento, histórico familiar de ocorrência de AVC, histórico de AIT e condições genéticas (BRASIL, 2013). Em relação aos fatores de risco potencial, que são aqueles que apresentam um maior risco para a ocorrência do AVC, dentre eles destacam-se: sedentarismo, obesidade, uso de pílulas anticoncepcionais, alcoolismo, terapia hormonal para mulheres após a menopausa, aumento da homocisteína plasmática (aminoácido do sangue), síndrome metabólica devido a gordura abdominal excessiva e uso de cocaína e anfetaminas (BRASIL, 2013).

No Brasil, embora tenha ocorrido uma redução nas taxas de mortalidade, o AVC ainda caracteriza a principal causa de óbito e invalidez no país. Em 2013 a taxa de incidência anual foi de 108 casos por 100 mil habitantes com 18,5% de fatalidade em 30 dias e 30,9% em 12 meses, com índice de recorrência de 15,9% (BRASIL, 2013).

De acordo com Who (2020), as principais causas globais de morte, na ordem do número total de vidas perdidas, estão relacionadas a três grandes tópicos: doenças cardiovasculares, doenças respiratórias e condições neonatais. Em escala mundial, 7 das 10 principais causas de óbito em 2019, foram de doenças não transmissíveis. Essas causas foram correspondentes a 44% de todas as mortes ou 80% das 10 principais. As doenças cardíacas são responsáveis por 16% do total de mortes no mundo. O AVC é a 2ª principal causa de morte, responsável por aproximadamente 11% do total de mortes, respectivamente (WHO, 2020). A Figura 2 apresenta a ilustração desses dados.


Figura 2 – Maiores causas de morte no mundo em 2019.



Fonte: Adaptado de Who (2020).

Dependendo da causa, o AVC pode ser de dois tipos: o AVC hemorrágico (AVCh) ou o AVC isquêmico (AVCi). O AVCh é o derrame causado pelo rompimento de um vaso cerebral, ocasionando em uma hemorragia em alguma área do sistema nervoso (MINHAVIDA, 2021). O AVCi é o derrame com entupimento de uma artéria, bloqueando o fluxo de oxigênio para as células cerebrais (MINHAVIDA, 2021). A Figura 3 apresenta os tipos de AVC e suas características serão melhor apresentadas na Seção 2.2.1 e na Seção 2.2.2.

Figura 3 – Tipos de AVC.



Fonte: AVC (2021).

2.2.1 AVC Hemorrágico

O termo AVCh embora apresente conflitos em suas definições, refere-se a uma hemorragia cerebral, em que acontece uma ruptura de vaso sanguíneo seguida de hemorragia cerebral, essa situação clínica também é conhecida como sangramentos intracranianos intraparenquimatosos não traumáticos (espontâneos) (BERNARDO *et al.*, 2017; AZEVEDO *et al.*, 2013). Os principais sintomas associados ao AVCh são: desmaios e convulsões. É mais raro de ocorrer, no entanto, apresenta maiores índices de mortalidade (MINHAVIDA, 2021). Essas características podem ser melhor observadas na Figura 4.

Figura 4 – AVC Hemorrágico.



Fonte: Adaptado de MINHAVIDA (2021).

De acordo com Azevedo *et al.* (2013), cerca de 37.000 a 65.000 casos de AVCh ao ano ocorrem nos EUA, constituindo 10% a 15% de todos os casos americanos de AVC. Embora não existam bons dados epidemiológicos, no Brasil, o AVC hemorrágico ocorre com mais frequência que nos EUA (AZEVEDO *et al.*, 2013).

Ainda segundo Azevedo *et al.* (2013), na literatura médica, o AVCh apresenta uma mortalidade aguda entre 30% e 40%, chegando a 50% após 1 mês. O AVCh pode apresentar diferentes quadros neurológicos, isso irá depender do local do sangramento. Em geral, chama-se atenção um quadro de instalação aguda, com sintomas neurológicos focais, diminuição e/ou alteração do nível de consciência e vômitos, que é presente em até 49% dos casos.

2.2.2 AVC Isquêmico

O AVCi é causado pela obstrução de uma artéria em uma área específica ou em todo o sistema nervoso central, resultando na falta de circulação adequada (AZEVEDO *et al.*, 2013). Essa falta de fluxo sanguíneo pode acontecer por um coágulo sanguíneo que se forma na parede de um vaso sanguíneo ou por um êmbolo que viaja pela corrente sanguínea e fica preso em um vaso sanguíneo menor que seu tamanho (MINHAVIDA, 2021). Os sintomas mais comuns do AVCi são: paralisia facial e perda da força em um dos lados do corpo, sendo o tipo mais comum que ocorre com maior frequência (Figura 5).

Figura 5 – AVC Isquêmico.



Fonte: Adaptado de MINHAVIDA (2021).

Segundo Azevedo *et al.* (2013), os acidentes vasculares cerebrais focais acontecem quando há um déficit no fluxo sanguíneo cerebral por mais de 24 horas. Nesses casos, o fluxo arterial não é restaurado, o que resulta em infarto e morte das células nervosas. Os acidentes vasculares focais com duração do déficit neurológico menor que 24 horas são chamados de Ataques Isquêmicos Transitórios (AIT) também mencionados pelo autor (AZEVEDO *et al.*, 2013). A maioria dos AIT apresenta melhora do déficit em menos de 2 horas, mas se o fluxo sanguíneo não for normalizado em menos de 1 hora, já existe dano estabelecido (AZEVEDO *et al.*, 2013).

A mortalidade do AVCi situa-se em torno de 10% a 17% dos casos, e os indivíduos mais idosos, que possuem comorbidades, tendem a ter uma menor taxa de sobrevivência. Durante a última década, houve uma significativa redução na mortalidade associada a essa doença. No entanto, a partir de 2010, a velocidade de diminuição da mortalidade estabilizou-se (AZEVEDO *et al.*, 2013). Muitos dos pacientes que se recuperam do AVCi, apresentam sequelas significativas que permanecem pelo resto de sua vida. Devido a essas sequelas, os custos do sistema de saúde aumentam, tornando o paciente dependente da família ou de instituições capacitadas para seu acompanhamento e tratamento (AZEVEDO *et al.*, 2013).

Existem vários fatores de risco que podem influenciar para a ocorrência de um primeiro AVCi. Uma das formas de minimizar a presença desses fatores é encontrar alternativas que visem modificar a relação do paciente com eles. Adotar um modo de vida mais saudável, pode ajudar para reduzir o risco de um evento vascular cerebral (AZEVEDO *et al.*, 2013). O Quadro 1 apresenta os principais fatores de risco modificáveis e não modificáveis para AVCi.

Quadro 1 – Fatores de risco para desenvolvimento de AVCi .

Fatores de risco modificáveis	Doença coronariana
	Hipertensão arterial sistêmica
	Diabetes mellitus
	Fibrilação atrial
	Estreitamento assintomático da carótida
	Insuficiência cardíaca congestiva
	Tabagismo
	Dislipidemia
	Obesidade
	Sedentarismo
	Terapia de reposição hormonal
Fatores de risco não modificáveis	Idade
	Raça
	Sexo
	Peso ao nascer
	História familiar de AVCi ou de AIT

Fonte: Adaptado de Azevedo *et al.* (2013).

Ainda segundo Azevedo *et al.* (2013), o conhecimento desses fatores é importante, pois permite o planejamento de alternativas que busquem alterar sua perspectiva com os eventos vasculares cerebrais, logo, é mais importante modificá-los do que quantificá-los. Assim, uma vez que esses fatores não sejam tratados e ocorra o AVC, os danos causados podem ser permanentes (HAKIM *et al.*, 2019).

Nesse sentido, sistemas inteligentes voltados para a previsão precoce de AVC, usando técnicas de aprendizagem de máquina, podem auxiliar o profissional em um diagnóstico mais rápido e nas decisões a serem tomadas (HAKIM *et al.*, 2019; OLIVEIRA *et al.*, 2019). Na Seção 2.3 serão apresentados os sistemas inteligentes e técnicas de inteligência artificial, mais precisamente as de aprendizagem de máquina, utilizadas neste trabalho.

2.3 Sistemas Inteligentes

Sistemas inteligentes são sistemas capazes de melhorar sua eficácia a partir de experiências passadas (QUILICI-GONZALEZ; ZAMPIROLI, 2014). O comportamento dos sistemas inteligentes é diferente dos sistemas tradicionais. Os sistemas tradicionais normalmente utilizam abordagens manuais para resolver tarefas, enquanto os sistemas inteligentes utilizam entidades do mundo real para trabalhar de forma eficaz com o conhecimento (QUILICI-GONZALEZ; ZAMPIROLI, 2014). Segundo Rezende (2005), os pontos-chave para os sistemas inteligentes estão relacionados com a habilidade para usar determinado conhecimento na resolução de problemas complexos que tenham semelhanças com problemas reais.

Entre as habilidades a serem utilizadas em um sistema inteligente, está a de armazenar e recuperar de forma eficaz uma grande quantidade de dados, com o propósito de resolver problemas ou tomar decisões (REZENDE, 2005). Esse tipo de sistema, além de ser relacionado com a habilidade organizacional, também está relacionado com a habilidade de se adaptar ou modificar o comportamento baseado na racionalidade (REZENDE, 2005). Assim, para um sistema de computação ser considerado “inteligente” é necessário possuir pelo menos alguma dessas habilidades e identificar como elas modelam tarefas específicas (REZENDE, 2005).

De acordo com Rezende (2005), a aquisição de conhecimento, lógica fuzzy, agentes, multiagentes, aprendizado de máquina e redes neurais, são as principais técnicas e metodologias utilizadas no desenvolvimento de sistemas inteligentes presentes na área da inteligência artificial. As Seções 2.4 e 2.5 descrevem sobre a inteligência artificial e a aprendizagem de máquina respectivamente.

2.4 Inteligência Artificial

Durante muitos anos, os pesquisadores buscaram entender como o ser humano pensa, compreende, prevê e manipula as entidades do mundo real. A área da Inteligência Artificial (IA), vai muito além desse pensamento, pois não busca apenas compreender, como também procura desenvolver entidades que sejam inteligentes (RUSSELL; NORVIG, 2013).

Russell e Norvig (2013) estruturaram as definições da IA em 8 definições organizadas em quatro estratégias conforme a Figura 6. As definições da parte superior estão relacionadas ao pensamento e raciocínio humano, e o comportamento na parte inferior. As definições do lado esquerdo determinam a semelhança em relação ao desempenho humano, enquanto as do lado direito especificam o sucesso relacionado a um conceito de racionalidade (RUSSELL; NORVIG, 2013).

Figura 6 – Definições da IA.

Pensando como um humano	Pensando racionalmente
“O novo e interessante esforço para fazer os computadores pensarem (...) <i>máquinas com mentes</i>, no sentido total e literal.” (Haugeland, 1985) “[Automatização de] atividades que associamos ao pensamento humano, atividades como a tomada de decisões, a resolução de problemas, o aprendizado...” (Bellman, 1978)	“O estudo das faculdades mentais pelo uso de modelos computacionais.” (Charniak e McDermott, 1985) “O estudo das computações que tornam possível perceber, raciocinar e agir.” (Winston, 1992)
Agindo como seres humanos	Agindo racionalmente
“A arte de criar máquinas que executam funções que exigem inteligência quando executadas por pessoas.” (Kurzweil, 1990) “O estudo de como os computadores podem fazer tarefas que hoje são melhor desempenhadas pelas pessoas.” (Rich and Knight, 1991)	“Inteligência Computacional é o estudo do projeto de agentes inteligentes.” (Poole <i>et al.</i>, 1998) “AI... está relacionada a um desempenho inteligente de artefatos.” (Nilsson, 1998)

Fonte: Russell e Norvig (2013).

Em 1943 foi reconhecido o primeiro trabalho inicialmente definido como IA e foi desenvolvido por Warren McCulloch e Walter Pitts. Neste, os pesquisadores apresentaram um modelo de neurônios artificiais, em que cada neurônio era definido como “ativo” ou “inativo”, com a ativação ocorrendo em resposta à estimulação de um número adequado de neurônios vizinhos. (RUSSELL; NORVIG, 2013). No entanto, foi a partir dos anos 70, que houve uma ampla difusão do uso de técnicas computacionais baseadas em IA para solução de problemas reais (FACELI *et al.*, 2021).

Nas últimas décadas, esses problemas vêm se tornando cada vez mais complexos, tornando-se clara a necessidade de ferramentas computacionais mais sofisticadas e mais independentes de modo a reduzir a interferência humana e dependência de especialistas (FACELI *et al.*, 2021). Para isso, essas técnicas devem ser capazes de criar por si próprias, a partir de experiências passadas, uma hipótese ou função capaz de resolver o problema que se deseja tratar. Técnicas de IA, em particular de AM, têm sido utilizadas com sucesso na resolução de alguns desses problemas (FACELI *et al.*, 2021).

2.5 Aprendizagem de Máquina

Mitchell (1997) define AM como a capacidade de desenvolver programas de computadores, baseado em tarefas que melhoram seu desempenho por meio de experiências passadas. Sistemas que sofrem aprendizagem, devem ser capazes de se adaptar ou mudar seu comportamento com base em exemplos, de forma que as técnicas envolvidas na AM consigam de alguma forma aprender a resolver os problemas (CASTRO; FERRARI, 2016). Segundo Géron (2019), existem quatro categorias principais de aprendizado: supervisionado, não supervisionado, semissupervisionado e por reforço.

- **Aprendizado Supervisionado:** fundamenta-se em um conjunto de dados de entrada que incluem as saídas desejadas, também chamadas de rótulos. Assim, nesse tipo de aprendizado, o conjunto de dados de entrada é utilizado para aprender a prever o valor de saída para conjuntos de dados ainda não conhecidos (GÉRON, 2019).
- **Aprendizado Não Supervisionado:** nesse tipo de aprendizado não existe a presença de dados rotulados e sim a utilização de agrupamento de dados. Nesse aprendizado, o objetivo é encontrar grupos semelhantes e identificar relações existentes entre eles no conjunto de dados. Esse tipo de aprendizado é normalmente utilizado em tarefas descritivas, na qual recebe um conjunto de dados sem rótulo e busca encontrar grupos com características similares (GÉRON, 2019).
- **Aprendizado Semisupervisionado:** possibilita o aprendizado a partir de um conjunto de dados parcialmente rotulado, ou seja, composto por dados rotulados e não rotulados. É aplicado quando há uma quantidade considerável de dados não rotulados e poucos dados rotulados disponíveis. O objetivo é utilizar os dados rotulados para a classificação inicial e analisar a estrutura dos dados não rotulados para melhorar o desempenho do modelo (GÉRON, 2019).
- **Aprendizado por Reforço:** consiste em uma série de reforços, em que o sistema de aprendizado seleciona e executa ações, que resultam em recompensas quando uma ação é considerada positiva ou punições quando uma ação é considerada negativa (GÉRON, 2019).

Neste trabalho será utilizada a abordagem de aprendizagem supervisionada, por se tratar de um problema com dados rotulados como entrada e a partir disso prever um valor de saída. Essa abordagem será melhor detalhada na Seção 2.6.

2.6 Aprendizado Supervisionado

De acordo com Russell e Norvig (2013), a aprendizagem supervisionada é caracterizada pela presença de um conjunto de treinamento com N pares de exemplos de entrada e saída $(x_1, y_1), (x_2, y_2), \dots (x_n, y_n)$, em que cada y_j foi gerado por uma função desconhecida $y = f(x)$, para descobrir uma função h que se aproxime da função verdadeira f . Os valores de x e y , não necessariamente precisam ser números, logo, podem assumir quaisquer valores e a função h é uma hipótese (RUSSELL; NORVIG, 2013).


Para avaliar a precisão de uma hipótese, é preciso fornecer um conjunto de testes de exemplos que são diferentes do conjunto de treinamento. Nesse caso, diz-se que uma hipótese generaliza bem se prevê corretamente o valor de y para novos exemplos (RUSSELL;

NORVIG, 2013). Quando a saída y for um conjunto de valores discretos, o problema da aprendizagem será chamado de classificação. Quando y for um valor contínuo, o problema da aprendizagem é chamado de regressão (RUSSELL; NORVIG, 2013).

Para definir o conjunto de treinamento e teste, pode-se utilizar uma técnica chamada validação cruzada em k -pastas (do inglês, *k-fold cross-validation*), onde k representa o número de divisões ou pastas que a base de dados é dividida. A validação cruzada, tem como objetivo dividir a base de dados em conjuntos de treinamento e teste. Assim, os dados de treinamento serão usados para ajustar os parâmetros do modelo e os dados de teste serão usados como estimativa de generalização para dados não usados no treinamento (FERRARI; CASTRO, 2016).

Segundo Ferrari e Castro (2016), a validação cruzada com $k = 10$ *fold* é bastante usada para estimar o erro de generalização. Na Figura 7 é apresentado um exemplo da validação cruzada com $k = 10$ *fold*, que consiste em separar a base de dados em k divisões, sendo $k - 1$ para treinamento e 1 para teste. Esse processo é realizado k vezes, até que todos os dados sejam utilizados para treinamento e teste.

Figura 7 – Validação cruzada do tipo 10-*fold*.



Fonte: Ferrari e Castro (2016).

2.6.1 Bibliotecas de aprendizado de máquina

O desenvolvimento de modelos de AM requer o uso de métodos e ferramentas capazes de auxiliar nesse processo. Entre essas ferramentas, destacam-se as bibliotecas baseadas em Python, que desempenham diversas tarefas e atividades, e servem como blocos de construção essenciais para a criação bem-sucedida de um modelo de AM (DATASCIENCE, 2021). Duas bibliotecas amplamente utilizadas são PyCaret e *Scikit-Learn*, que serão apresentadas com mais detalhes a seguir.

2.6.1.1 PyCaret

PyCaret¹ é uma biblioteca de AM de código aberto que visa automatizar tarefas de AM, facilitando a preparação dos dados, o desenvolvimento, a comparação e a implantação de modelos de forma simples e eficaz (ALI, 2020; SARANGPURE *et al.*, 2023). Em comparação com outras bibliotecas de AM de código aberto, o PyCaret se destaca como uma opção de baixo código, capaz de substituir centenas de linhas de código por apenas algumas. Essa abordagem permite a realização de experimentos de forma significativamente mais rápida e eficiente (ALI, 2020).

Com o PyCaret é possível executar todas as etapas do processo de AM em um único experimento, utilizando um *pipeline* reproduzível (ALI, 2020). Além disso, o PyCaret é versátil e pode ser aplicada em uma variedade de problemas como classificação, regressão, clusterização, detecção de anomalias, processamento de linguagem natural e mineração de regras de associação (ALI, 2020). Para problemas de classificação, o PyCaret pode lidar tanto com classificação binária quanto multiclasse, oferecendo uma abrangente variedade de recursos, com mais de 14 algoritmos e mais de 18 métodos disponíveis para análise de desempenho do modelo (SARANGPURE *et al.*, 2023). A Figura 8 apresenta uma visão geral da aplicação do PyCaret para problemas de classificação.

Figura 8 – Visão geral de classificação com PyCaret.

```
# Classification Functional API Example

# loading sample dataset
from pycaret.datasets import get_data
data = get_data('juice')

# init setup
from pycaret.classification import *
s = setup(data, target = 'Purchase', session_id = 123)

# model training and selection
best = compare_models()

# evaluate trained model
evaluate_model(best)

# predict on hold-out/test set
pred_holdout = predict_model(best)

# predict on new data
new_data = data.copy().drop('Purchase', axis = 1)
predictions = predict_model(best, data = new_data)

# save model
save_model(best, 'best_pipeline')
```

Fonte: Ali (2020).

Dentre os modelos de AM utilizados pelo PyCaret estão: *Random Forest Classi-*

¹ <https://pycaret.org/>

fier, *Extra Trees Classifier*, *Extreme Gradient Boosting*, *Light Gradient Boosting Machine*, *Decision Tree Classifier*, *Neighbors Classifier*, *Gradient Boosting Classifier*, *Ada Boost Classifier*, *Logistic Regression*, *Ridge Classifier*, *Linear Discriminant Analysis*, *SVM - Linear Kernel*, *Naive Bayes*, *Quadratic*, *Dummy Classifier* e outros (ALI, 2020).

2.6.1.2 Scikit-Learn

*Scikit-learn*² é uma biblioteca de AM de código livre que abrange tanto o aprendizado supervisionado quanto o não supervisionado. Essa biblioteca oferece recursos completos para o ajuste de modelos, pré-processamento de dados, seleção de modelos, avaliação de desempenho e muito mais. Além disso, ela disponibiliza dezenas de algoritmos e modelos de AM para tarefas como classificação, regressão, clusterização, redução de dimensionalidade e pré-processamento de dados (PEDREGOSA *et al.*, 2011).

Dentre alguns dos principais algoritmos disponíveis no *Scikit-Learn* estão: *Linear Regression*, *Logistic Regression*, *Decision Trees*, *Random Forest*, *Gradient Boosting*, *Support Vector Machines*, *Naive Bayes*, *k-Nearest Neighbors*, *Neural Networks*, *Principal Component Analysis*, *Linear Discriminant Analysis*, *Quadratic Discriminant Analysis* e outros (PEDREGOSA *et al.*, 2011).

2.6.2 Métricas de avaliação

Após a apresentação conceitual das principais bibliotecas de AM, também é importante levar em consideração métricas que possibilitem fazer a análise e avaliação do desempenho dos modelos. Segundo Faceli *et al.* (2021), é recomendável seguir procedimentos que garantam a corretude, a validade e a execução dos experimentos realizados, bem como ajudam a fornecer *insights* sobre diferentes aspectos da classificação alcançada.

A avaliação dos algoritmos de Aprendizado de Máquina pode ser realizada levando em consideração diversos aspectos, tais como acurácia, interpretabilidade do conhecimento extraído, tempo de treinamento, entre outros. No contexto de problemas de classificação, existem diversas métricas de avaliação amplamente utilizadas na literatura (FACELI *et al.*, 2021). Entre as principais métricas, destacam-se: acurácia, matriz de confusão, precisão, *recall*, *f1-score*, coeficiente kappa, e outros, vistos a seguir.

- **Matriz de confusão**

Segundo Faceli *et al.* (2021), uma matriz de confusão é aplicada normalmente em um problema de duas classes, em que uma classe é positiva (+) e a outra classe é negativa (-). A matriz de confusão permite um melhor entendimento dos algoritmos e divide os resultados em quatro tipos, sendo eles:

² <https://scikit-learn.org/stable/>

Verdadeiro Positivo (VP): consiste no número de verdadeiros positivos, ou seja, a contagem de amostras da classe positiva que foram classificados corretamente.

Verdadeiro Negativo (VN): consiste no número de verdadeiros negativos, como por exemplo o número de exemplos da classe negativa que foram classificados corretamente.

Falso Positivo (FP): consiste no número de falsos positivos, ou seja, o número de exemplos que foram classificados incorretamente como positivos, mas sendo sua classe verdadeira a classe negativa.

Falso Negativo (FN): consiste no número de falsos negativos, ou seja, o número de exemplos que foram classificados incorretamente como negativos, mas sendo sua classe originalmente pertencente a classe positiva.

No Quadro 2 tem-se a representação da matriz de confusão ilustrada.

Quadro 2 – Matriz de confusão.

		Classe predita	
		+	-
Classe verdadeira	+	VP	FN
	-	FP	VN

Fonte: Faceli *et al.* (2021).

- **Acurácia**

Conhecida como a taxa de acerto geral do algoritmo, a acurácia está relacionada com a soma das classificações corretas dividida pelo total de classificações. A acurácia também pode ser definida como o grau de conformidade de um valor medido ou calculado com seu valor real (FERRARI; CASTRO, 2016). Na Equação 2.1 é apresentada essa divisão para problemas de duas classes

$$ACC = \frac{VP + VN}{VP + FP + VN + FN} \quad (2.1)$$

Quando aplicada a validação cruzada, que divide o conjunto de treinamento em *k-folds* para prever e avaliar as previsões em cada conjunto como apresentado na Figura 7, conta-se o número de previsões corretas e entrega a proporção das previsões corretas, ou seja, a média da acurácia de cada iteração da validação cruzada. Também utiliza-se o desvio padrão para medir a dispersão da média em todo o conjunto de dados (GÉRON, 2019).

- **Precisão**

É uma métrica utilizada para especificar a qualidade ou exatidão do algoritmo e a taxa de verdadeiros positivos entre todos aqueles preditos como positivos (FACELI *et al.*, 2021; FERRARI; CASTRO, 2016). Assim, a quantidade de valores Verdadeiro Positivo (VP) e Falso Positivo (FP) são considerados (Equação 2.2).

$$Precisão = \frac{VP}{(VP + FP)} \quad (2.2)$$

- **Recall**

É uma métrica que corresponde à taxa de acertos na classe positiva dos valores que foram classificados corretamente (FACELI *et al.*, 2021). Para isso, a quantidade de valores Verdadeiro Positivo (VP) e Falso Negativo (FN) são utilizados para determinar o valor do *Recall* (Equação 2.3).

$$Recall = \frac{VP}{(VP + FN)} \quad (2.3)$$

- **F1-Score**

Essa métrica considera a precisão e o *recall*, em um intervalo entre 0 e 1 (Equação 2.4). Também pode ser aplicada em casos de recuperação de informações com o objetivo de avaliar o desempenho de ferramentas voltadas para busca e classificação (FERRARI; CASTRO, 2016).

$$F1 = \frac{2 \times Precisão \times Recall}{(Precisão + Recall)} \quad (2.4)$$

- **Coeficiente Kappa**

O Coeficiente kappa de Cohen é uma métrica utilizada para avaliar a capacidade de predição de um modelo de acordo com as classificações observadas e esperadas. Pode variar entre -1 e 1, no qual valores próximos a 1 indicam uma melhor concordância, valores próximos a 0 indicam concordância igual à esperada e valores próximos a -1 indicam uma concordância inversa. Além disso, o coeficiente kappa leva em consideração o desequilíbrio na distribuição de classes durante a avaliação da concordância entre os avaliadores. (VIERA; GARRETT *et al.*, 2005; JUNIOR *et al.*, 2022)

- **AUC**

A AUC, também conhecida como a área sob a Curva ROC, é uma métrica utilizada para analisar o desempenho de modelos de classificação em termos de sua capacidade de distinguir entre as classes. Ela mede o grau de separabilidade entre as classes. Assim, quanto maior for o valor da AUC, melhor o modelo está em prever corretamente as classes positivas como positivas e as classes negativas como negativas. Isso significa que uma AUC maior indica um melhor funcionamento do modelo em distinguir entre as classes (JUNIOR *et al.*, 2022; SENGUPTA, 2009).

2.7 Ferramentas Utilizadas

Ambiente e ferramentas de desenvolvimento apresentam um importante papel no que diz respeito à criação e implantação de softwares. Escolher ferramentas adequadas, contribuem para auxiliar na configuração de um ambiente de qualidade para o desenvolvimento das soluções. A seguir são apresentadas algumas ferramentas utilizadas para o desenvolvimento de soluções inteligentes, bem como a apresentação de um ambiente de desenvolvimento.

2.7.1 Streamlit

Streamlit³ é uma biblioteca de código aberto projetada para a criação e implantação rápida de aplicativos voltados para ciência de dados e AM (KAZMI *et al.*, 2021). Diferentemente de outras bibliotecas, como Dash ou Flask, o Streamlit permite criar interfaces web ou painéis de forma ágil e simplificada, sem a necessidade de conhecimentos avançados em HTML e CSS (MATOS, 2021). Oferece uma ampla variedade de componentes de interface de usuário e suporta a conexão com bancos de dados, incluindo o SQLite e o PostgreSQL, facilitando a realização de operações básicas de criação, leitura, atualização e exclusão em bancos de dados (STREAMLIT, 2021; MATOS, 2021).

O Streamlit oferece aos desenvolvedores a capacidade de escrever aplicativos usando uma sintaxe simples em Python, permitindo a inclusão de elementos interativos, como gráficos, tabelas, botões e entradas de texto. Esses aplicativos podem ser executados localmente e compartilhados facilmente, possibilitando uma experiência colaborativa de visualização e análise de dados (MATOS, 2021). Uma das principais vantagens do Streamlit é sua facilidade de uso e curva de aprendizado rápida, permitindo que os desenvolvedores criem e compartilhem aplicativos de maneira eficiente (MATOS, 2021). Além disso, possui uma comunidade ativa, com uma ampla variedade de bibliotecas e recursos disponíveis para aprimorar ainda mais os aplicativos (STREAMLIT, 2021; MATOS, 2021).

³ <https://streamlit.io/>

2.7.2 Python

Python⁴ é uma linguagem de programação, caracterizada pela sua tipagem dinâmica, interpretação e interatividade. Sua sintaxe clara e concisa favorece a legibilidade do código-fonte, tornando-a uma linguagem altamente produtiva. Além disso, a linguagem oferece uma grande variedade de estruturas de alto nível, como listas, dicionários, manipulação de datas/horas, números complexos, entre outros, e um conjunto de módulos prontos para uso, juntamente com *frameworks* de terceiros que podem ser facilmente integrados. Python também incorpora recursos comuns a outras linguagens modernas, como geradores, introspecção, persistência de dados, metaclasses e suporte a unidades de teste (BORGES, 2014).

Com o Python é possível desenvolver aplicações em uma plataforma e executá-las em diferentes sistemas operacionais, ou até mesmo executar o código diretamente. Python é um software de código aberto, porém com uma licença menos restritiva, permitindo que seja incorporado em produtos proprietários (BORGES, 2014). Além disso, o Python também pode ser utilizado como uma linguagem de extensão para aplicativos que necessitam de uma interface programável. Sua portabilidade é notável, sendo capaz de executar em várias variantes do Unix, incluindo Linux e macOS, além do Windows (PYTHON, 2023).

2.7.3 NumPy

O NumPy⁵ é uma biblioteca Python de código livre amplamente utilizada em ciência e engenharia. Ele é o padrão universal para trabalhar com dados numéricos em Python e é essencial nos ecossistemas científicos Python e PyData. O NumPy oferece suporte a matrizes multidimensionais e estruturas de dados de matriz, permitindo a execução eficiente de operações matemáticas em vetores. Além disso, possui uma extensa biblioteca de funções matemáticas que operam em vetores e matrizes (OLIPHANT *et al.*, 2006).

2.7.4 Pandas

O Pandas⁶ é um pacote Python que oferece estruturas de dados rápidas, flexíveis e expressivas para trabalhar com dados relacionais ou rotulados. Ele é projetado para tornar a análise de dados práticos do mundo real em Python fácil e intuitiva. O Pandas é adequado para uma ampla variedade de tipos de dados, incluindo dados tabulares com colunas de tipos diferentes, dados de séries temporais ordenadas e não ordenadas, dados de matriz com rótulos de linha e coluna e outros conjuntos de dados observacionais ou

⁴ <https://www.python.org/>

⁵ <https://numpy.org/>

⁶ <https://pandas.pydata.org/>

estatísticos. O Pandas permite trabalhar com dados não rotulados também, sendo uma ferramenta versátil para diversas aplicações (FOUNDATION, 2023).

2.7.5 Banco de dados PostgreSQL

Um banco de dados é um conjunto de informações que registra as operações e informações relacionadas a uma ou várias organizações (RAMAKRISHNAN; GEHRKE, 2008). O PostgreSQL⁷ é um sistema de banco de dados objeto-relacional gratuito e de código aberto. Ele oferece uma ampla gama de recursos para desenvolvedores e administradores, incluindo a capacidade de criar aplicativos, proteger a integridade dos dados e criar ambientes que sejam capazes de suportar falhas e continuar funcionando sem problemas. Além disso, o PostgreSQL é altamente extensível, permitindo a definição de tipos de dados personalizados, criação de funções personalizadas e até mesmo a escrita de código em muitas linguagens de programação sem a exigência de recompilar o banco de dados. O PostgreSQL também busca conformidade com o padrão SQL, embora possa apresentar diferenças sintáticas ou funcionais em alguns casos (PostgreSQL, 2023).

2.7.6 Ambiente de desenvolvimento - PyCharm

O PyCharm⁸ é um IDE (Ambiente de Desenvolvimento Integrado, do inglês *Integrated Development Environment*) Python dedicado que oferece uma ampla variedade de ferramentas essenciais para o desenvolvimento de Python, web e ciência de dados. Disponível em duas edições, o PyCharm *Community* (gratuito e de código aberto) que oferece recursos como assistência de código, refatorações, depuração visual e integração de controle de versão. Já o PyCharm *Professional* (pago) inclui recursos adicionais, como configurações remotas, implantação, suporte a *frameworks* populares da web (como Django e Flask), suporte a banco de dados e ferramentas científicas, incluindo suporte a notebook Jupyter e big data. O PyCharm é um IDE compatível com Windows, macOS e Linux, e também oferece suporte a outras linguagens, como HTML, CSS, JavaScript e XML, por meio de *plugins* opcionais (JETBRAINS, 2023).

2.8 Técnicas de Validação

Na literatura existem muitas técnicas voltadas para a validação de softwares que podem ser aplicadas para garantir a qualidade e a eficácia de um sistema. Dentre elas existem os testes de usabilidade. O teste de usabilidade é um método direto que utiliza simulações e ferramentas para observar o comportamento dos usuários e coletar suas

⁷ <https://www.postgresql.org/>

⁸ <https://www.jetbrains.com/pt-br/pycharm/>

opiniões sobre a experiência de uso de um sistema (MACHADO; VERGARA; FERREIRA, 2014).

Durante o teste, é importante criar um ambiente o mais próximo do real, e os avaliadores devem desenvolver um roteiro para os participantes seguirem. Os avaliadores acompanham e monitoram as decisões tomadas pelos participantes ao longo do teste (CILUMBRIELLO *et al.*, 2019).

Embora seja ideal ter um grande número de participantes nos testes de interface, questões de custo e tempo geralmente limitam essa possibilidade na prática. Estudos mostram que mesmo com apenas 5 usuários é possível identificar cerca de 75% dos problemas mais críticos de experiência do usuário (OLIVEIRA, 2021; AGNER, 2009). Portanto, esse número reduzido de participantes é comumente utilizado na prática (AGNER, 2009).

2.9 Considerações Finais

Após a apresentação e definição dos conceitos envolvidos neste trabalho, foi possível compreender sobre a promoção e prevenção de riscos e doenças, bem como ao AVC, seus tipos, fatores de risco e sinais indicativos. Além disso, foram explorados os sistemas inteligentes, a inteligência artificial e os diferentes tipos de aprendizado de máquina. Também foram discutidas métricas e ferramentas relevantes e necessárias para a análise e desenvolvimento desses sistemas.

3 Mapeamento Sistemático da Literatura

Para Kitchenham (2004) uma Revisão Sistemática da Literatura (RSL) é um tipo de pesquisa, que utiliza métodos para identificar, selecionar e avaliar estudos relevantes para um problema específico. Com isso, este capítulo apresenta uma RSL objetivando verificar trabalhos que apresentam soluções que fazem o uso de técnicas de AM, para auxiliar no diagnóstico do AVC antes mesmo da sua ocorrência.

Esta revisão sistemática seguiu as diretrizes definidas por Kitchenham e Charters (2007) e algumas etapas do processo de *Design Science* proposto em Dresch, Lacerda e Júnior (2015). O protocolo foi definido para ser realizado em cinco etapas: i) definir a questão de pesquisa e questões específicas; ii) definir as fontes de busca; iii) identificar os trabalhos relevantes; iv) avaliar a qualidade dos trabalhos, e v) responder a questão de pesquisa. Cada uma dessas etapas será apresentada nas seções a seguir.

3.1 Questões de Pesquisa

A Questão de Pesquisa (QPE) desta RSL se caracteriza como: **“Quais soluções disponíveis na literatura são utilizadas para atuar na prevenção e diagnóstico do AVC?”**. Para responder este questionamento, foram elaboradas quatro Questões Específicas (QE):

- **QE1:** Quais as principais soluções?
- **QE2:** Quais recursos tecnológicos (linguagens, ferramentas e bibliotecas) utilizados para o desenvolvimento dessas soluções?
- **QE3:** Quais as limitações identificadas no trabalho?
- **QE4:** Como foi realizada a validação dessas soluções?

3.2 Processo de Busca

Esta RSL teve por objetivo encontrar estudos publicados entre 2016 e 2021, e escritos no idioma inglês, tendo em vista a sua utilização na maioria das conferências, revistas e periódicos de relevância para a área tecnológica. A busca foi realizada em cinco fontes de busca relevantes na área, a citar:

- *ACM Digital Library* ¹

¹ www.dl.acm.org

- *IEEE Xplore*²
- *MedLine*³
- *Scopus*⁴
- *Web of Science*⁵

Essas fontes foram escolhidas com base na disponibilidade em acessar o conteúdo dos artigos voltados para o objetivo desta pesquisa. Para auxílio no processo de busca, decidiu-se utilizar alguns termos relacionados à temática desta pesquisa, com foco na área médica e tecnológica. Os termos definidos são apresentados no Quadro 3.

Quadro 3 – Termos de busca.

Área	Termos
Médica	<i>Stroke; Hemorrhagic Stroke; Ischemic Stroke.</i>
Tecnológica	<i>Machine Learning; Artificial Intelligence; Deep Learning; Algorithm; Plataform; Application; Decision tree; Support Vector Machine; K-closest neighbors; Multi Layer Perceptron; Ensemble.</i>

Fonte: Autoria.

Para realizar o processo de busca, uma *string* de busca foi definida baseada nos termos elencados no Quadro 3, resultando na seguinte *string* de busca:

((“Stroke” OR “Hemorrhagic Stroke” OR “Ischemic Stroke”) AND (“Machine Learning” OR “Artificial Intelligence” OR “Deep Learning”) AND (“Algorithm” OR “Plataform” OR “Application”) AND (“Decision tree” OR “Support Vector Machine” OR “K-closest neighbors” OR “Multi Layer Perceptron” OR “Ensemble”))

3.3 Critérios para seleção e avaliação

Para a selecionar os estudos de maior relevância, foram definidos Critérios de Inclusão (CI) e Critérios de Exclusão (CE).

Critério de Inclusão :

CI1) Estudos com foco na pesquisa.

² <https://ieeexplore.ieee.org/>

³ <https://pubmed.ncbi.nlm.nih.gov/>

⁴ <https://www.scopus.com/>

⁵ <https://login.webofknowledge.com/>

CI2) Estudos publicados entre os anos de 2016 e 2021.

CI3) Estudos publicados no idioma Inglês.

CI4) Estudos que utilizaram técnicas de AM para desenvolvimento de soluções.

Critérios de Exclusão :

CE1) Estudos que não apresentam informações suficientes para responder a nenhuma das questões de pesquisa.

CE2) Estudos que não possibilitem download do arquivo completo de forma gratuita.

CE3) Estudos repetidos nas fontes de busca.

Além disso, também foram definidos Critérios de Qualidade (CQ) para avaliar os estudos, os quais são listados a seguir.

Critérios de Qualidade :

CQ1) O estudo possibilita responder às questões de pesquisa apresentadas na Seção 3.1? (1 ponto atribuído para cada pergunta respondida).

CQ2) A metodologia apresentada é intuitiva de modo a possibilitar a utilização do trabalho? (0 - Não; 1 - Parcialmente; 2 - Completamente)

CQ3) O estudo fez a utilização de métricas para validar as soluções? (0 - Não; 1 - Sim)

3.4 Seleção dos Trabalhos

A seleção e escolha dos trabalhos foi dividida em quatro etapas: (I). Busca nas bases e pré-seleção dos artigos, (II). Leitura do título, palavras-chaves e resumo, (III). Leitura da introdução, metodologia e conclusão, (IV). Leitura completa dos trabalhos selecionados nas etapas anteriores.

A Etapa I consistiu na pré-seleção dos artigos a partir da aplicação das *strings* de busca nas fontes de dados juntamente com a leitura do título e palavras-chaves. Nessa etapa fez-se a verificação dos critérios de inclusão CI2 e CI3. Ao final, 615 trabalhos foram selecionados.

Na etapa II foram analisados o título, palavras-chaves e os resumos dos trabalhos, verificando-se também o critério de inclusão CI1 e os critérios de exclusão CE2 e CE3. Os

trabalhos que contemplavam os critérios de inclusão foram adicionados à uma Lista de Selecionados (LS1), enquanto os excluídos foram organizados em uma Lista de Removidos (LR1). Ao final da Etapa II, 57 trabalhos foram selecionados.

Na etapa III fez-se a leitura da introdução, metodologia e conclusão dos trabalhos inseridos na LS1. Para esta etapa, foram analisados também os critérios de inclusão CI1 e CI4 e o critério de exclusão CE1. Com isso, os estudos excluídos foram inseridos em uma LR2, já os trabalhos que passaram pelos critérios foram adicionados em uma segunda LS2. Com a finalização da etapa III, apenas 12 trabalhos continuaram para a próxima etapa.

A etapa IV foi realizada a partir dos trabalhos contidos na LS2. Assim, foi realizada a leitura completa dos trabalhos e uma análise de todos os critérios de inclusão e exclusão. Ao final desta etapa, os trabalhos que cumpriram todos os critérios foram direcionados a responder às QEs. Ao fim dessa etapa, 9 trabalhos foram selecionados.

A seleção desses 9 estudos foi baseada nos critérios de seleção para garantir a relevância e qualidade dos dados e atender os objetivos específicos do estudo e minimizar possíveis vieses. Além disso, o processo de seleção dos estudos seguiu o protocolo estabelecido nesta pesquisa para garantir a integridade e qualidade dos resultados.

3.5 Resultados

Ao final do processo de seleção dos trabalhos partiu-se para a análise dos trabalhos com o objetivo de buscar respostas às QEs⁶. Na Tabela 1 é apresentado um quantitativo de trabalhos retornados em cada fonte de pesquisa, para cada etapa do processo de avaliação.

Tabela 1 – Número de trabalhos retornados para cada fonte de busca nas quatro etapas.

Base	Etapa I	Etapa II	Etapa III	Etapa IV
IEEE	106	30	8	7
ACM	295	2	0	0
MedLine	66	7	1	1
Scopus	95	13	1	0
Web of Science	53	5	2	1
Total	615	57	12	9

Fonte: Autoria.

A leitura completa dos trabalhos teve por objetivo buscar respostas para as Questões de Pesquisa apresentadas na Seção 3.1. No Quadro 4 são apresentados as fontes de busca, um identificador (IDs) definido para cada trabalho de forma ordinal, o ano de publicação, o título e os respectivos autores de cada trabalho selecionado. A seguir são apresentadas as respostas obtidas para as QEs.

⁶ O processo realizado nas 4 etapas está disponível em <https://cutt.ly/8IyneTh>

Quadro 4 – Trabalhos selecionados.

Fonte	ID	Ano	Título	Autores
IEEE	1	2019	Comparison of Different Machine Learning Approaches to Model Stroke Subtype Classification and Risk Prediction	García-Temza <i>et al.</i> (2019)
	2	2019	An Efficient Modified Bagging Method for Early Prediction of Brain Stroke	Hakim <i>et al.</i> (2019)
	3	2019	Detection of Stroke Disease using Machine Learning Algorithms	Shoily <i>et al.</i> (2019)
	4	2019	Semantic Analysis of NIH Stroke Scale using Machine Learning Techniques	Yu <i>et al.</i> (2019)
	5	2020	Performance Analysis of Machine Learning Approaches in Stroke Prediction	Emon <i>et al.</i> (2020)
	6	2019	Computational Methods for Predicting Chronic Disease in Healthcare Communities	Induja e Raji (2019)
	7	2020	Automated Ischemic Stroke Subtyping Based on Machine Learning Approach	Fang, Xu e Liu (2020)
MedLine	8	2021	A prehospital diagnostic algorithm for strokes using machine learning: a prospective observational study	Hayashi <i>et al.</i> (2021)
Web Of Science	9	2017	Stroke Prediction using Artificial Intelligence	Singh e Choudhary (2017)


Fonte: Autoria.

Com relação a questão específica **QE1: Quais as principais soluções?**, dentre as principais soluções identificadas nos trabalhos selecionados, destacaram-se: 6 trabalhos (ID3, ID4, ID5, ID6, ID7, ID9) desenvolveram modelos a partir de algoritmos de aprendizado de máquina já existentes, 1 trabalho (ID8) desenvolveu um novo algoritmo e 2 trabalhos (ID1, ID2) compararam algoritmos de aprendizado de máquina. Com isso, foi observado que a maioria das soluções propostas consistiam na criação de modelos utilizando algoritmos de

aprendizagem de máquina.

Para a questão específica **QE2: Quais recursos tecnológicos (linguagens, ferramentas e bibliotecas) utilizados para o desenvolvimento dessas soluções?**, nos estudos selecionados alguns autores destacaram quais bibliotecas e pacotes foram utilizados durante o desenvolvimento das soluções, a citar: Linguagem de programação Python (ID1, ID2, ID5, ID8), Biblioteca *scikit-learn* (ID1, ID5, ID8), Biblioteca *pandas* (ID8), Biblioteca *numpy* (ID8), Biblioteca *matplotlib* (ID8) e o software weka (ID3). A partir dessa análise pode-se perceber que dos 9 estudos selecionados 4 deles fizeram o uso da linguagem de programação Python, 3 deles fazem uso da biblioteca *scikit-learn* e pelo menos 1 dos 9 trabalhos selecionados faz uso das bibliotecas *pandas*, *numpy*, *matplotlib* e do software weka. Na Figura 9 são apresentadas as ferramentas utilizadas pelos trabalhos juntamente com um quantitativo de estudos que as utilizaram.


Figura 9 – Ferramentas utilizadas.



Fonte: Autoria.

Entre as principais técnicas e algoritmos identificados nos trabalhos selecionados, destacaram-se: Árvore de decisão (ID1, ID3, ID4, ID5, ID6, ID9), Rede Neural (ID1, ID5, ID9), Regressão logística (ID1, ID5, ID8), *Random Forest* (ID1, ID3, ID7, ID8), SVM (ID1, ID8), XGBoost (ID5, ID8), *Extra Trees* (ID7), *Adaboost* (ID5, ID7), *Naive Bayes* (ID1, ID3, ID5, ID6, ID7), K-NN (ID1, ID3, ID5, ID6) e o *bagging* (ID2). Com isso, foi possível perceber que a maioria das técnicas de aprendizagem direcionadas à abordagem supervisionada foram utilizadas. Na Figura 10 são apresentados os algoritmos e modelos utilizados pelos trabalhos juntamente com um quantitativo dos estudos que os utilizaram.

Figura 10 – Algoritmos e modelos utilizados na classificação.



Fonte: Autoria.

Ao analisar os trabalhos, foi observado uma relação na forma como os estudos eram conduzidos. Inicialmente, os autores selecionaram os algoritmos de AM a serem testados e, posteriormente, o algoritmo que apresentasse o melhor desempenho seria escolhido como solução a ser empregada no modelo preditivo. Essa abordagem demonstrou ser uma alternativa promissora, pois permite a utilização de uma variedade de algoritmos de aprendizagem e, em seguida, a seleção dos melhores com base no desempenho alcançado.

Com relação a questão específica **QE3: Quais as limitações identificadas nos trabalhos?** No Quadro 5 são apresentadas as principais limitações encontradas para os nove trabalhos selecionados.

Quadro 5 – Principais limitações identificadas nos trabalhos.

ID	Limitações identificadas
1	Falta de recursos de diagnósticos, como tomografia computadorizada ou ressonância magnética, principalmente em áreas rurais.
2	O algoritmo proposto não foi testado com outros comitês disponíveis na literatura.
3	O conjunto de dados utilizado, foi coletado de várias fontes, o que pode ter contribuído para não ser perfeitamente simétrico, o que pode ter afetado o desempenho do algoritmo.
4	Os autores não deixam claro quais foram as ferramentas utilizadas para o desenvolvimento e se o sistema é um protótipo ou se já foi desenvolvido, pois só é especificado uma arquitetura do sistema e a apresentação do modelo de aprendizagem.
5	Os autores não mencionam se o classificador foi desenvolvido pelos próprios autores, se foi uma adaptação de um método existente na literatura ou se foi um classificador disponível na literatura.
6	Os autores não especificaram quais ferramentas foram utilizadas para o desenvolvimento das soluções, bem como o processo de pré-processamento dos dados.
7	Os autores não especificaram quais ferramentas foram utilizadas para o desenvolvimento das soluções.
8	Devido ao estudo ser multicêntrico, mas conduzido em uma única região do Japão, não ficou claro se o algoritmo teria alto valor preditivo em diferentes áreas com diferentes origens e generalização. Limitações relacionadas à base de dados e ao pré-processamento dos dados.
9	O conjunto de dados tinha uma grande quantidade de valores ausentes, com quase 60% das medições ausentes. Devido a isso, fizeram uma redução nos dados de modo que a base de teste ficou com poucas instâncias. As variáveis utilizadas também não são citadas.

Fonte: Autoria.

Em García-Temza *et al.* (2019), os autores citam a importância fundamental de identificar o AVC para fornecer um tratamento precoce e preciso, no entanto eles afirmaram que isso nem sempre é possível devido à falta de recursos de diagnósticos, como tomografia computadorizada ou ressonância magnética, principalmente em áreas rurais.

Em Hakim *et al.* (2019), os autores desenvolveram um algoritmo baseado no comitê *bagging*, no entanto, o algoritmo foi testado apenas com o mesmo comitê. Outra opção seria testar o algoritmo proposto com outros comitês disponíveis na literatura. Poderiam ter testado a técnica proposta com outros comitês disponíveis na literatura para identificar se o desempenho da técnica modificada era melhor que o da técnica tradicional também quando comparado com outros modelos. Além disso, não foram apresentadas sugestões de melhoria para trabalhos futuros.

Em Shoily *et al.* (2019), foram utilizados quatro algoritmos (*Naive Bayes*, J48, k-NN e *Random Forest*) de aprendizagem de máquina para detectar o tipo de AVC. O conjunto de dados utilizado foi coletado a partir de registros de várias fontes, o que pode ter contribuído para não ser perfeitamente simétrico. Segundo os autores isso pode ter afetado o funcionamento do algoritmo *Naive Bayes*, já que o mesmo, apesar de ter apresentado bons resultados, não funcionou como esperado.

Em Yu *et al.* (2019), os autores propuseram um sistema de previsão do AVC utilizando como base a Escala de AVC do *National Institutes of Health* (NIH). No entanto, não foi possível identificar quais ferramentas foram utilizadas para o desenvolvimento e se o sistema é um protótipo ou se já foi desenvolvido, pois é especificada uma arquitetura para o sistema e feita a apresentação do modelo de aprendizagem.

Em Emon *et al.* (2020), os autores afirmam que uma das principais contribuições do trabalho é a proposta do classificador de votação ponderada. No entanto, não foi mencionado se o classificador foi desenvolvido pelos próprios autores, se foi uma adaptação de um método existente na literatura ou se foi um classificador disponível na literatura que foi utilizado como uma referência comparativa em relação a outros classificadores base. Seria importante fornecer uma explicação mais clara sobre a origem e desenvolvimento do classificador, esclarecendo se foi uma criação original do estudo ou se foi baseado em trabalhos anteriores. Isso ajudaria a contextualizar a inovação do classificador proposto e a avaliar sua relevância em relação a outros métodos existentes.

Em Induja e Raji (2019) e Fang, Xu e Liu (2020), os autores não especificaram quais ferramentas foram utilizadas para o desenvolvimento das soluções. Além disso, em Induja e Raji (2019) os autores não deixaram claro como foi realizado o processo de pré-processamento dos dados.

Em Hayashi *et al.* (2021), os autores apresentaram uma hipótese de que a utilização de algoritmos de diagnóstico de AVC pré-hospitalar usando aprendizado de máquina tinham um alto valor preditivo. O conjunto de dados utilizado consistia em pacientes adultos consecutivos com suspeita de AVC que foram inscritos em um estudo observacional multicêntrico em 12 hospitais no Japão. Os autores citaram como limitação que devido ao estudo ser multicêntrico, mas conduzida em uma única região do Japão, não ficou claro se o algoritmo teria alto valor preditivo em diferentes áreas com diferentes origens e generalização. Outro ponto que os autores destacaram foi a exclusão de pacientes pediátricos, que pode ter sido um fator limitante para o estudo. Outra limitação apontada pelos autores foi a busca pelo melhor desempenho em vez de limitar o número de preditores, visto que o desenvolvimento adicional de algoritmos com número limitado de preditores fortaleceria os resultados do estudo e poderia contribuir para implementações futuras.

Em Singh e Choudhary (2017), foi proposta uma abordagem de previsão de AVC utilizando dados do *Cardiovascular Health Study* (CHS). O conjunto de dados utilizado

consistia em 5.888 instâncias e mais de 600 recursos. No entanto, uma das limitações apontadas no conjunto de dados foi devido ao fato de ter uma grande quantidade de valores ausentes, com quase 60% das medições ausentes. Para isso, os autores com o objetivo de deixar o conjunto de dados adequado ao processo de mineração, removeram os registros duplicados, dados ausentes, dados ruidosos e inconsistentes na etapa de pré-processamento. Após o pré-processamento, o conjunto de dados ficou bastante reduzido com 357 recursos e 1824 instâncias. Além disso, o estudo não deixa claro quais as variáveis que foram utilizadas e para a apresentação dos resultados, poderiam ter comparado o resultados com outros algoritmos existentes na literatura e não somente com os algoritmos utilizados para o desenvolvimento da abordagem.

Para a questão específica **QE4: Como foi realizada a validação dessas soluções?**, os autores utilizaram métricas de avaliação. Entre as principais métricas identificadas nos trabalhos selecionados, destacaram-se: Matriz de Confusão, Acurácia, Especificidade, Precisão, *F1-Score*, *Recall*, *Receiver Operating Characteristic* (ROC) e a *Precision Recall Curve* (PRC). No Quadro 6 são apresentadas as métricas utilizadas pelos trabalhos juntamente com um quantitativo de estudos que as utilizaram. A partir do retorno dessas métricas os autores conseguiram mensurar o desempenho da solução proposta.

Quadro 6 – Métricas utilizadas na validação das soluções

ID	Métricas de avaliação
1	Acurácia, Especificidade, Precisão, <i>Receiver Operating Characteristic</i> (ROC)
2	Matriz de Confusão, Acurácia, Precisão, <i>F1-Score</i> , <i>Recall</i> , <i>Precision Recall Curve</i> (PRC)
3	Matriz de Confusão, Acurácia, Precisão, <i>F1-Score</i> , <i>Recall</i>
4	Acurácia, Precisão, <i>F1-Score</i> , <i>Recall</i>
5	Precisão, <i>Recall</i>
6	Matriz de Confusão, Acurácia, Precisão, <i>F1-Score</i> , <i>Recall</i>
7	Acurácia, Precisão, <i>F1-Score</i> , <i>Recall</i>
8	Acurácia, Especificidade, Precisão, <i>F1-Score</i> , <i>Recall</i> , <i>Receiver Operating Characteristic</i> (ROC)
9	Matriz de Confusão, Acurácia

Fonte: Autoria.

Em García-Temza *et al.* (2019), para avaliar o desempenho da técnica proposta, os autores empregaram o método de reamostragem de validação cruzada de 10 vezes, juntamente com seis métricas distintas. Essas métricas incluíram: acurácia, *recall*, *f1-score* e as áreas sob a curva *Receiver Operating Characteristic* (ROC) e *Precision Recall Curve* (PRC).

A utilização dessa abordagem de avaliação permitiu uma análise mais completa e robusta do desempenho da técnica proposta, considerando diferentes aspectos, como a

taxa de acerto geral, a capacidade de detectar corretamente casos positivos e negativos, a precisão geral e a capacidade de classificação em diferentes limiares de probabilidade.

Em Hakim *et al.* (2019), o desempenho da versão modificada do algoritmo de Bagging tradicional foi avaliado com base na precisão obtida ao utilizar as amostras e comparar essas precisões com um valor limite. Além disso, o sistema foi validado utilizando métricas adicionais, como *recall*, especificidade, acurácia e *F1-score*. Também foi utilizado o conceito de matriz de confusão para avaliar a classificação correta e incorreta das amostras.

Em Shoily *et al.* (2019), os autores validaram o modelo proposto por meio da utilização de métricas amplamente reconhecidas, como acurácia, precisão, *recall*, *F1-score* e matriz de confusão. Essas métricas fornecem uma avaliação abrangente do desempenho do modelo, permitindo analisar sua capacidade de classificar corretamente as amostras, bem como sua habilidade em identificar e recuperar casos positivos.

A utilização dessas métricas auxilia na compreensão do desempenho do modelo, possibilitando uma análise mais completa e detalhada de sua eficácia na tarefa proposta. Já em Induja e Raji (2019), para comprovar a precisão dos modelos, os autores fizeram uma comparação com trabalhos existentes, utilizando a precisão, acurácia, o *F1-score* e o *recall*.

Em Yu *et al.* (2019), para medir a precisão do experimento do sistema proposto, os autores levaram em consideração tanto o *recall* quanto a precisão como medidas de desempenho para validar o sistema. Essas métricas são amplamente utilizadas na avaliação de modelos e sistemas, pois fornecem uma visão abrangente da capacidade do sistema em recuperar corretamente as instâncias relevantes (*recall*) e em classificar corretamente as instâncias recuperadas (precisão).

Em Emon *et al.* (2020), o nível de precisão dos dez algoritmos foi avaliado por meio da utilização de diferentes tipos de algoritmos, com o objetivo de identificar o melhor modelo utilizando o classificador de votação ponderado. Para validar o modelo, os autores consideraram métricas como a matriz de confusão, precisão, *recall* e *F1-score*.

Em Fang, Xu e Liu (2020), os autores validaram sua abordagem utilizando métricas como acurácia, precisão, *recall* e *F1-score*. Já em Hayashi *et al.* (2021), o desempenho do modelo foi medido usando a curva AUROC, precisão, *recall* e *F1-score*. No estudo de Singh e Choudhary (2017), o modelo foi validado e analisado com base na matriz de confusão e na precisão, incluindo comparações com outros modelos da literatura.

Para avaliar a qualidade dos trabalhos selecionados foram aplicados os Critérios de Qualidade (Seção 3.3). Os resultados da avaliação, assim como o ordenação da qualidade, são apresentados na Tabela 2.

Tabela 2 – Avaliação de qualidade dos trabalhos selecionados.

ID	CQ1	CQ2	CQ3	Pontos
1	4	2	1	7
3	4	2	1	7
8	4	2	1	7
4	3	2	1	6
9	3	2	1	6
2	3	1	1	5
5	3	1	1	5
6	2	1	1	4
7	2	1	1	4

Fonte: Autoria.

Ao analisar os resultados dos critérios de qualidade, é possível perceber que os trabalhos de García-Temza *et al.* (2019), Shoily *et al.* (2019), e Hayashi *et al.* (2021) obtiveram a pontuação máxima de 7, o que indica que eles responderam todas as questões de pesquisa apresentadas na Seção 3.3, sua metodologia é intuitiva e eles utilizaram métricas para validar as soluções. Os trabalhos de Yu *et al.* (2019) e Singh e Choudhary (2017) alcançaram uma pontuação de 6, mostrando que eles responderam a maioria das questões de pesquisa, sua metodologia é parcialmente intuitiva e eles utilizaram métricas para validar as soluções.

Hakim *et al.* (2019) e Emon *et al.* (2020) obtiveram uma pontuação de 5, o que significa que eles responderam a maioria das questões de pesquisa, sua metodologia é parcialmente intuitiva e eles utilizaram métricas para validar as soluções. Já em Induja e Raji (2019) e Fang, Xu e Liu (2020) obtiveram uma pontuação de 4, mostrando que eles responderam a algumas questões de pesquisa, sua metodologia é parcialmente intuitiva e eles utilizaram métricas para validar as soluções. Essa análise permite ter uma visão geral sobre como os trabalhos se saíram nas questões propostas e na utilização de suas metodologias.

3.6 Considerações Finais

Esta RSL auxiliou na identificação de estudos científicos que utilizam métodos e técnicas de inteligência artificial mais precisamente de AM para auxiliar no diagnóstico de pacientes com AVC, principalmente no contexto de sinais indicativos e fatores de risco. De acordo com os resultados analisados foi possível identificar que: i) um conjunto de técnicas baseadas na aprendizagem de máquina vêm sendo utilizadas para a criação de modelos, a citar: *Random Forest*, SVM, Árvores de decisão, K-NN, *Naive Bayes*, Regressão Logística, XGBoost, Rede Neural e outros; ii) a linguagem de programação Python, juntamente com suas bibliotecas estão sendo utilizadas com frequência na análise e no desenvolvimento das soluções preditivos; iii) os trabalhos levaram em consideração diversas métricas para validarem suas propostas, a citar: matriz de confusão, acurácia, especificidade, *recall*, precisão, *f1-score* e outros; iv) em todos os estudos, os resultados foram pertinentes e podem contribuir para auxiliar no diagnóstico e prevenção do AVC.


4 Definição e Construção do Modelo de Predição

Neste capítulo, são apresentadas as etapas necessárias para a definição e criação do modelo de predição. Inicialmente, na Seção 4.1, são abordados os passos envolvidos nesse processo. Em seguida, na Seção 4.2, é descrita a base de dados utilizada nesta pesquisa. Posteriormente, são detalhados os procedimentos adotados no pré-processamento dos dados na Seção 4.3. Em seguida, na Seção 4.5, é apresentada uma análise detalhada dos pacientes que tiveram AVC. Nessa análise, são investigados os fatores de risco e os sinais indicativos relacionados a essa condição médica, com o objetivo de identificar possíveis similaridades entre os casos. Essa identificação de padrões relevantes dos pacientes com AVC é essencial para a construção do modelo de predição. Após a análise dos dados, descrevem-se as novas bases de dados geradas como resultado das etapas anteriores. Essas bases de dados refinadas e preparadas fornecem as informações necessárias para o desenvolvimento do modelo de predição. Por fim, na Seção 4.6, são apresentadas as considerações finais deste capítulo.

4.1 Descrição do Modelo de Predição

Para a construção do modelo de predição foram definidas as seguintes etapas: i) escolha da base de dados; ii) seleção dos atributos; iii) pré-processamento dos dados; iv) escolha do melhor algoritmo utilizando PyCaret; v) seleção de atributos utilizando a função *feature_importance*; vii) treinamento e teste do modelo; vii) predição do AVC utilizando as 3 bases geradas; viii) avaliação das métricas de desempenho a partir das bases; ix) seleção da base com melhores resultados e x) implementação do modelo. Na Figura 11 são apresentadas as etapas definidas para a construção do modelo preditivo.

Figura 11 – Etapas da criação do modelo preditivo.



Fonte: Autoria.

A base de dados consiste na organização dos dados, ou seja, valores quantitativos ou qualitativos referentes a um conjunto de itens, que permite uma recuperação eficiente dos dados (FERRARI; CASTRO, 2016). Para a realização deste trabalho foi utilizado uma base de dados pública, disponibilizada pelo Centro de Coordenação de Informações de Repositório de Espécimes Biológicos e Dados (BioLINCC)¹, um repositório de dados internacional do Instituto Nacional do Coração, Pulmão e Sangue (do inglês *National Heart, Lung, and Blood Institute*). A base de dados é composta por 5.888 instâncias e abrange mais de 600 atributos. Vale ressaltar que, para obter acesso a essa base, foi necessário solicitar a aprovação do Comitê de Ética. A pesquisa em questão recebeu a devida aprovação do Comitê de Ética para o uso desses dados nesta pesquisa.

Considerando a extensa variedade de atributos disponíveis, foi imprescindível realizar a seleção criteriosa daqueles que possuem maior relevância para o estudo em questão. A Seção 4.3 aborda em detalhes o processo adotado para essa seleção, oferecendo uma visão abrangente sobre o processo realizado.

A preparação ou pré-processamento de dados são técnicas voltadas para tornar os dados da base adequados para o uso de algoritmos de AM (FACELI *et al.*, 2021). Dentre as técnicas mais utilizadas pode-se citar: eliminação manual de atributos, integração de dados, balanceamento de dados e limpeza de dados (FACELI *et al.*, 2021). Essas técnicas foram aplicadas com o objetivo de melhorar a qualidade dos dados utilizados na pesquisa.

A seleção de algoritmos corresponde à seleção e aplicação dos algoritmos com o objetivo de inferir conhecimento (FACELI *et al.*, 2021). Neste trabalho, para essa etapa, optou-se pela utilização da biblioteca PyCaret para seleção de algoritmos. Nesse processo, primeiro é realizada a configuração padrão do ambiente de trabalho e realiza-se a preparação básica dos dados. Em seguida, cria um conjunto de modelos que inclui uma

¹ <https://biolincc.nhlbi.nih.gov/studies/chs/>

variedade de algoritmos, treina esses modelos e avalia seu desempenho usando métricas de avaliação. Depois, seleciona automaticamente o modelo que obteve o melhor desempenho e realiza uma busca automática de hiperparâmetros (configuração padrão) para otimizá-lo (ALI, 2020). A escolha do PyCaret foi feita devido à ampla versatilidade da biblioteca, que possibilita a execução de várias tarefas de aprendizado de máquina em um único experimento, sua facilidade de uso e sua capacidade de lidar bem com problemas multiclasse, como é o caso desta pesquisa (ALI, 2020).

Além disso, com o objetivo de identificar os atributos mais relevantes para o problema em questão, também optou-se por fazer a seleção dos atributos mais importantes para a classificação do AVC, permitindo a redução da dimensionalidade dos dados, facilitando a visualização e contribuindo para uma melhor capacidade de generalização do modelo (PAL; MITRA, 2004). Para isso, utilizou-se a função *feature_importance* do algoritmo *Random Forest*. Essa técnica permite avaliar a importância de cada atributo em relação à variável classificatória, auxiliando na identificação dos fatores mais relevantes para a ocorrência do AVC (PEDREGOSA *et al.*, 2011).

Com base na seleção dos atributos, decidiu-se remover os atributos WHOME09 (Dificuldades para andar pela casa), ATRFIB07 (Fibrilação atrial), NERV01 (Transtorno nervoso) e o KIDNEY01 (Doença renal), por apresentarem os valores de importância bem próximos de zero. Em seguida, foram criadas mais 3 bases de dados, totalizando 4 bases diferentes:

1. Base inicial: contém os 24 atributos originais mais o atributo classe.
2. Segunda base: contém os 21 atributos com maior importância, incluindo o atributo classe.
3. Terceira base: contém os 16 atributos com maior importância, incluindo o atributo classe.
4. Quarta base: contém os 11 atributos com maior importância, incluindo o atributo classe.

A partir dessas bases, a predição do AVC foi realizada, com o objetivo de identificar qual delas apresentava os melhores resultados, considerando as métricas avaliadas na Seção 2.6. Esse procedimento permitiu uma análise comparativa dos desempenhos das diferentes bases de dados, auxiliando na determinação da relevância dos atributos selecionados para a tarefa de predição do AVC.

A análise dos resultados por meio da utilização das métricas (Acurácia, Precisão, *Recall*, *F1-score*, Coeficiente kappa e AUC) busca avaliar o desempenho do modelo. A escolha das métricas utilizadas neste trabalho foram embasadas nas análises realizadas

no Capítulo 3. A utilização dessas métricas é importante para identificar possíveis inconsistências nos resultados e indicar a necessidade de ajustes nos parâmetros do modelo (FACELI *et al.*, 2021). Ao analisar essas métricas, foi possível obter *insights* valiosos sobre o desempenho do modelo e realizar as devidas melhorias, garantindo uma abordagem mais robusta e confiável em relação aos resultados finais.

Por fim, o modelo desenvolvido foi implementado utilizando o *Streamlit* para em seguida ser utilizado em uma aplicação Web que foi desenvolvida fazendo o uso do modelo. O código-fonte de toda a análise de dados, pré-processamento e criação do modelo apresentados neste trabalho encontra-se disponível em um repositório no Github² (SILVA, 2023). Nas seções a seguir, serão descritas em detalhes as etapas da metodologia utilizada neste trabalho.

4.2 Base de Dados

A base de dados utilizada neste estudo faz parte do *Cardiovascular Health Study* (CHS), um estudo longitudinal de base populacional de doença cardíaca coronária e acidente vascular cerebral em adultos com 65 anos ou mais (BIOLINCC, 2019). O CHS excluiu indivíduos com menos de 65 anos de idade, que não podiam dar consentimento ou responder a perguntas sem um substituto, residiam em um ambiente institucional, eram dependentes de cadeira de rodas ou estavam recebendo tratamento ativo para câncer (KAMEL *et al.*, 2021).

O estudo envolveu a participação de 5.888 indivíduos, que foram recrutados em quatro comunidades diferentes nos Estados Unidos. Esses participantes foram submetidos a uma série de exames clínicos detalhados para avaliar os marcadores de doença cardiovascular subclínica. Inicialmente, 5.201 participantes foram recrutados para o estudo. Posteriormente, em 1992, uma nova seleção foi adicionada, composta por 687 participantes. Esses indivíduos da nova seleção são predominantemente afro-americanos e foram recrutados em três dos quatro centros de campo.(BIOLINCC, 2019).

No estudo, havia um total de 2.962 mulheres e 2.239 homens que foram examinados anualmente entre 1989 e 1999. Além disso, uma seleção adicional composta por 256 homens e 431 mulheres foi examinada de 1992 a 1999. Os exames realizados incluíram uma série de procedimentos, como questionários sobre histórico médico, medição do índice tornozelo-braquial, ultrassonografias abdominal e carotídea, ecocardiogramas, eletrocardiogramas ambulatoriais, ressonância magnética cerebral, espirometria e fotografias da retina. As avaliações mais completas foram realizadas no início do estudo (linha de base) e novamente em 1992-1993, para avaliar mudanças nos marcadores de doença subclínica. O estudo CHS também realizou um acompanhamento detalhado para investigar eventos cardiovasculares,

² <https://github.com/>

como claudicação incidente, infarto do miocárdio, insuficiência cardíaca congestiva, acidente vascular cerebral e óbito (BIOLINCC, 2019).

Para este trabalho, foram utilizados os dados da linha de base que continham 5.888 instâncias e 642 atributos. Os dados³ existentes na base são divididos em: i) dados demográficos; ii) histórico de AVC na família; iii) sintomas e sinais, iv) fatores de risco e v) Medicação.

4.3 Pré-Processamento dos Dados

Para a realização do pré-processamento fez-se a utilização da linguagem de programação Python, fazendo uso das bibliotecas *scikit-learn*, *pandas*, *seboarn*, *matplotlib* e a ferramenta *Colaboratory* ou Colab do Google como ambiente de desenvolvimento.

Inicialmente optou-se pela remoção do código do identificador da base, pois não apresentava relevância para o estudo. Em seguida verificou-se a existência de valores duplicados aplicando o método *duplicated*, de modo que foram identificados 75 instâncias com informações duplicadas, nesse caso fez-se a remoção desses instâncias que continham valores duplicados.

Para embasar melhor o modelo, realizou-se análises das soluções apresentadas no Capítulo 3. Durante essas análises, identificou-se que, apesar dos estudos terem empregado atributos diferentes, existiam semelhanças notáveis entre os fatores de risco e os indicadores considerados nessas soluções. Com base nessa constatação, o Quadro 7 foi utilizado como referência. Este quadro apresenta os atributos mais frequentemente utilizados nos estudos analisados, que serviram como base para a seleção dos atributos mais relevantes para o trabalho.

³ Uma descrição detalhada dos dados encontra-se disponível no seguinte link: <<https://encurtador.com.br/gnr5>>.

Quadro 7 – Principais atributos utilizados nos estudos do capítulo 3.

Variável	Natureza	Nº de Estudos
Idade	Demográfico	7
Hipertensão	Fator de Risco	5
Gênero	Demográfico	4
Defeitos na visão	Sinal Indicativo	3
Doença cardíaca	Fator de Risco	3
Fumante	Sinal Indicativo	3
IMC	Fator de Risco	3
Paralisia de membros superiores	Sinal Indicativo	3
Paralisia facial	Sinal Indicativo	3
Arritmia Cardíaca	Fator de Risco	2
Colesterol	Fator de Risco	2
Diabetes	Fator de Risco	2
Dificuldades para falar	Sinal Indicativo	2
fibrilação atrial	Fator de Risco	2
Nível de glicose	Fator de Risco	2
Paralisia dos membros inferiores	Sinal Indicativo	2
Tontura	Sinal Indicativo	2
vômito	Sinal Indicativo	2
Confusão mental	Sinal Indicativo	1
Desconforto no peito	Fator de Risco	1
Desmaio	Sinal Indicativo	1
Dificuldades para respirar	Sinal Indicativo	1
Dor de cabeça	Sinal Indicativo	1
Fadiga	Sinal Indicativo	1
Fraqueza	Sinal Indicativo	1
Frequência cardíaca	Fator de Risco	1
Histórico Familiar	Fator de Risco	1
Perda de audição	Sinal Indicativo	1
Perda de equilíbrio	Sinal Indicativo	1
Perda de sensação	Sinal Indicativo	1

Fonte: Autoria.

Ao final da análise, foram selecionados 25 atributos relacionados a sinais indicativos e fatores de risco (incluindo o atributo classe), contando com 5125 instâncias. Os demais atributos não foram utilizados pois não apresentavam relevância para o presente trabalho. No Quadro 8 são apresentados os atributos selecionados.

Quadro 8 – Atributos resultantes após o pré-processamento

Atributo	Descrição
SUPSYS16	Pressão arterial sistólica (Numérico)
SUPDIA16	Pressão arterial diastólica (Numérico)
BEAT14	Frequência cardíaca (Numérico)
ATRFIB07	Fibrilação atrial (0 - Não; 1 - Sim)
DIABETES	Diabetes
BMI	IMC (Numérico)
FHSTK	Histórico de AVC na família (0 - Não; 1 - Sim)
HEAR01	Doença no pulmão (0 - Não; 1 - Sim)
NERV01	Transtorno nervoso (0 - Não; 1 - Sim)
KIDNEY01	Doença renal (0 - Não; 1 - Sim)
DIAG01	Diagnóstico com câncer (0 - Não; 1 - Sim)
HEART01	Doença cardíaca (0 - Não; 1 - Sim)
GEND01	Gênero (0 - Feminino ; 1 - Masculino)
SMOKE	Status fumante (0 - ; 1 - Nunca fumou; 2 - Ex-fumante; 3 - Fuma atualmente)
DIZZYP07	Tontura (0 - Não; 1 - Sim)
NAUSEP07	Náusea (0 - Não; 1 - Sim)
FATIGP07	Fadiga (0 - Não; 1 - Sim)
RECOGN08	Consegue ver bem o suficiente para reconhecer (0 - Não; 1 - Sim)
CHSTPN07	Dor/desconforto no peito (0 - Não; 1 - Sim)
LEGWLK07	Dor nas pernas ao andar (0 - Não; 1 - Sim)
PALPIP07	Palpitações (0 - Não; 1 - Sim)
CONVER08	Escuta bem para conversar (0 - Não; 1 - Sim)
LIFTNG09	Dificuldade para levantar (0 - Não; 1 - Sim; 2 - Não informado)
WHOME09	Dificuldades para andar pela casa (0 - Não; 1 - Sim)
STRKBASE	Classe para AVC (0 - Não; 1 - Sim; 2 - Indeterminado)

Fonte: Autoria.

Após isso, fez-se a verificação dos valores faltosos por meio da função *isnull* e verificou-se que dos 25 atributos selecionados, foi observado que 23 deles continham dados faltantes. Na variável classe “STRKBASE” foi identificado que existia apenas uma única instância com valor faltoso, a qual foi removida. Entre os demais atributos, o atributo “ATRFIB07” relacionado à fibrilação atrial foi identificado como tendo a maior quantidade de dados faltosos, com 1258 instâncias ausentes. Essa informação foi obtida por meio da função *isnull().sum().sort_values(ascending = False)*, que permitiu ordenar os atributos de acordo com a quantidade de valores faltosos.

Neste caso não fez a remoção desses valores e sim o tratamento dos dados, substituindo os valores faltosos pela mediana dos valores. Após a substituição dos valores faltosos da fibrilação atrial identificou-se que todos os outros valores faltosos também foram substituídos. A escolha dessa técnica se deu pelo fato de que a base de dados contém poucas instâncias, remover essas instâncias com dados faltosos, iria reduzir mais ainda a

base de dados.

Como a base de dados utilizada neste estudo, considera apenas pessoas com mais de 65 anos, a idade não foi levada em consideração. No entanto, é importante destacar que, embora o AVC seja mais comum em indivíduos acima de 60 anos, pode acontecer em qualquer idade, inclusive em crianças (CARVALHO *et al.*, 2019). Portanto, utilizar a idade como critério nessas condições poderia limitar o número de usuários que poderiam se beneficiar da ferramenta. É importante reconhecer o alcance do AVC em todas as idades e considerar métodos que sejam inclusivos e capazes de atender a diferentes perfis de pacientes.

Com isso, foi identificado que a variável classe “STRKBASE” estava desbalanceada. Segundo Azank e Gurgel (2020), esse desequilíbrio pode ser caracterizado pela baixa frequência de uma categoria em um conjunto de dados (classe minoritária), quando comparado com as outras categorias (classes majoritárias). Em muitos casos, isso resulta em um maior volume de informações sobre as categorias mais frequentes e menos informações sobre as categorias minoritárias. Esse desequilíbrio pode, em diversos casos, interferir no resultado dos algoritmos utilizados.


Uma forma de reduzir o viés causado pela diferença na proporção das categorias é equilibrar a quantidade de dados efetivamente utilizados, tentando igualar o número de instâncias entre as classes (AZANK; GURGEL, 2020). Há diversas maneiras para resolver o problema de dados desbalanceados, dentre elas: o método *NearMiss*, *Undersampling*, *Smote* e o *Oversampling*. O método *NearMiss* reduz a classe majoritária mantendo exemplos próximos à classe minoritária. *Undersampling* diminui aleatoriamente a quantidade de exemplos da classe majoritária. *Smote* cria dados sintéticos para a classe minoritária usando vizinhos próximos. *Oversampling* replica aleatoriamente dados da classe minoritária. Cada método tem sua utilidade e pode ser escolhido com base nas necessidades do problema (SANTANA, 2020; CHAWLA *et al.*, 2002).

Para este trabalho, fez-se a utilização da técnica *smote*, para fazer o balanceamento da variável classe. A escolha dessa técnica se deu pelo fato de que ela utiliza todo o conjunto de dados como entrada, mas aumenta apenas o número dos elementos minoritários. Para isso, são geradas novas instâncias com base nas características dos seus vizinhos mais próximos, obtendo assim, um número maior de elementos da classe minoritária e equilibrando as classes (CHAWLA *et al.*, 2002). Outras técnicas de redução da classe majoritária não seriam uma boa escolha, uma vez que o conjunto de dados é pequeno, essa redução iria deixar o conjunto de dados menor ainda. Ao final desses procedimentos obteve-se a Base25 contendo 14.646 instâncias e um total de 25 atributos.

4.4 Seleção de Recursos

A seleção de recursos tem por objetivo identificar e priorizar os atributos mais influentes no conjunto de dados, visando simplificar o modelo e melhorar sua eficácia na previsão (PEDREGOSA *et al.*, 2011). Para isso foi utilizada a função *feature_importance* do algoritmo *Random Forest*, que permitiu calcular a importância de cada atributo com base na diminuição média da impureza e na permutação de recursos (PEDREGOSA *et al.*, 2011). As importâncias dos atributos com base na diminuição média da impureza são fornecidas pelo atributo ajustado do *feature_importances* e são calculadas com a média e o desvio padrão do acúmulo da diminuição da impureza dentro de cada árvore (PEDREGOSA *et al.*, 2011). Na Figura 12 é apresentado o valor de importância para os atributos de acordo com a diminuição média da impureza.


Figura 12 – Importância dos atributos com a diminuição média da impureza.



Fonte: Autoria.

No entanto, as medidas de importância de recursos geradas por esse método podem ser influenciadas de forma inadequada para recursos de alta cardinalidade (aqueles com muitos valores exclusivos). Por isso também fez-se a utilização da importância dos atributos baseado na permutação de recursos que supera as limitações da importância baseada em impurezas. Este não têm um viés para recursos de alta cardinalidade e podem ser calculados em um conjunto de teste deixado de fora (PEDREGOSA *et al.*, 2011). Na Figura 13 é apresentado o valor de importância para os atributos de acordo com a permutação de recursos.

Figura 13 – Importância dos atributos com a permutação de recursos.



Fonte:Autoria.

Após a análise das importâncias geradas na Figura 13 foi realizada uma investigação sobre o desempenho do modelo levando em consideração a importância dos atributos. Com base nessa análise, foram criadas mais três bases de dados distintas. A primeira base de dados, chamada de Base21, foi composta pelos 20 atributos com maior importância, além do atributo classe. Essa seleção visou utilizar os atributos mais relevantes para a tarefa em questão. A segunda base de dados, denominada Base16, foi criada a partir dos 15 atributos com maior importância, juntamente com o atributo classe.

Essa redução no número de atributos buscou simplificar o modelo sem comprometer significativamente seu desempenho. Por fim, a terceira base de dados, chamada de Base11, consistiu nos 10 atributos mais importantes, acompanhados do atributo classe. Essa seleção ainda mais restrita teve o objetivo de identificar os atributos essenciais para a predição, buscando um modelo mais conciso e interpretável.

Ao criar essas diferentes bases de dados, foi possível explorar a relação entre a importância dos atributos e o desempenho do modelo, proporcionando uma análise mais detalhada e permitindo ajustes na complexidade e na eficácia do modelo de acordo com as necessidades do projeto. No Quadro 9 são apresentados os atributos que compõem cada uma das bases geradas.

Quadro 9 – Bases de dados geradas

Bases	Instâncias	Atributos	
Base25	14.646	25	GEND01, SUPSYS16, SUPDIA16, ATRFIB07, DIABETES, BMI, FHSTK, BEAT14, HEAR01, NERV01, KIDNEY01, DIAG01, HEART01, SMOKE, DIZZYP07, NAUSEP07, FATIGP07, RECOGN08, CHSTPN07, LEGWLK07, PALPIP07, CONVER08, LIFTNG09, WHOME09, STRKBASE
Base21	14.646	21	GEND01, SUPSYS16, SUPDIA16, DIABETES, BMI, FHSTK, BEAT14, HEAR01, NERV01, DIAG01, HEART01, SMOKE, DIZZYP07, FATIGP07, RECOGN08, CHSTPN07, LEGWLK07, PALPIP07, CONVER08, LIFTNG09, STRKBASE
Base16	14.646	16	GEND01, SUPSYS16, SUPDIA16, DIABETES, BMI, FHSTK, BEAT14, HEAR01, DIAG01, SMOKE, FATIGP07, RECOGN08, CHSTPN07, LEGWLK07, CONVER08, STRKBASE
Base11	14.646	11	SUPSYS16, SUPDIA16, DIABETES, BMI, FHSTK, HEAR01, DIAG01, FATIGP07, CHSTPN07, CONVER08, STRKBASE

Fonte: Autoria.

No Capítulo 6 serão detalhados os resultados obtidos e a análise de desempenho para cada uma das bases criadas.


4.5 Análise dos Dados

Para obter uma compreensão mais aprofundada da relação entre os dados para a classificação, foi realizada uma análise exploratória dos dados. Inicialmente, foi conduzida uma análise específica dos casos positivos de sinais indicativos e fatores de risco em relação à ocorrência do AVC. Nesse contexto, fez-se a proporção de casos positivos de AVC entre aqueles que apresentavam sinais indicativos (caso positivo) e fatores de risco (caso positivo), visando identificar quais deles têm uma relação mais significativa.

Dentre os sintomas investigados, alguns apresentaram uma relação mais significativa com a ocorrência de AVC, enquanto outros demonstraram ter uma relação menos pronunciada. Os sintomas que mais se associaram à ocorrência de AVC foram: dor nas pernas, dificuldade de comunicação relacionada à audição, fadiga, dor no peito, tontura e perda de percepção visual, especificamente na capacidade de reconhecer pessoas. Esses sintomas demonstraram estar mais fortemente ligados à presença de AVC nos casos analisados. Por outro lado, os sintomas de palpitações, mobilidade ao se locomover e


náusea apresentaram uma relação menos proeminente com a ocorrência de AVC, com uma frequência consideravelmente menor em comparação com os demais sintomas. As Figuras 14 e 15 ilustram visualmente essa relação entre a ocorrência de AVC e os sintomas indicados.

Figura 14 – Relação da ocorrência do AVC com os sinais indicativos.



Fonte:Autoria.


Figura 15 – Relação da ocorrência do AVC com os sinais indicativos.



Fonte:Autoria.


Em relação à ocorrência de AVC e os fatores de risco, foi observado que alguns fatores apresentaram uma associação mais forte com a incidência de AVC. Os fatores que mais se destacaram foram: doença cardíaca, diabetes, doença pulmonar, histórico familiar de AVC e transtornos nervosos. Esses fatores mostraram uma maior frequência de casos de AVC. Por outro lado, a presença de fibrilação atrial, câncer, tabagismo e doenças renais apresentaram uma relação menos proeminente com a ocorrência de AVC. A frequência de casos relacionados a esses fatores foi consideravelmente menor em comparação com os fatores mencionados anteriormente. As Figuras 16 e 17 ilustram visualmente essa relação entre a ocorrência de AVC e os fatores de risco mencionados.

Figura 16 – Relação da ocorrência do AVC com os fatores de risco.



Fonte: Autoria.

Figura 17 – Relação da ocorrência do AVC com os fatores de risco.



Fonte: Autoria.

Ao analisar a Figura 13 e comparar com as Figuras 14, 15, 16 e 17, é perceptível a relação existente entre os dados dada a importância desses atributos para o modelo.

4.6 Considerações Finais

Neste capítulo foram apresentadas as etapas necessárias para a criação do modelo de predição, qual o pré-processamento realizado e uma análise realizada nos dados. A partir dessa análise foi observado que sintomas, como dor nas pernas, dificuldade de comunicação relacionada à audição, fadiga, dor no peito, tontura e perda de percepção visual, apresentaram uma forte associação com a ocorrência de AVC. Com relação aos fatores de risco, foi identificado que doença cardíaca, diabetes, doença pulmonar, histórico familiar de AVC e transtornos nervosos, desempenham um papel significativo na incidência de AVC. No entanto, também observou-se que outros sintomas, como palpitações, mobilidade ao se locomover e náusea, assim como fatores de risco como fibrilação atrial, câncer, tabagismo e doenças renais, apresentaram uma menor relação com a ocorrência de AVC. No Capítulo 5 será apresentada a ferramenta de aprendizagem, e no Capítulo 6 são apresentados os resultados e a análise de desempenho obtidos ao utilizar diferentes bases de dados e o algoritmo *Random Forest* para a predição do AVC. Além disso, também serão apresentados os resultados de um teste de usabilidade realizado para avaliar a usabilidade e facilidade de uso da ferramenta.

5 Uma ferramenta para auxílio na classificação de pacientes em relação ao AVC

Este capítulo tem como objetivo apresentar a ferramenta proposta. Na Seção 5.1, é apresentada uma visão geral do sistema desenvolvido. Nessa seção, são abordados os principais aspectos da ferramenta, incluindo sua finalidade e funcionamento. Na Seção 5.2, é detalhada a modelagem da ferramenta inteligente de predição. Nessa etapa, são definidos os requisitos necessários para o desenvolvimento da ferramenta, apresentação dos diagramas que ilustram a estrutura e os fluxos de informações da ferramenta, além de compartilhar as telas que serão utilizadas pelos usuários (Seção 5.3).


5.1 Visão Geral

Conforme mencionado anteriormente, o AVC é uma doença que pode ocorrer de forma instantânea ou apresentar sinais antes de sua ocorrência. Devido a isso surge a necessidade de conhecer os sinais indicativos e fatores de risco que podem estar relacionados com a ocorrência do AVC. Nas Seções 2.1 e 2.2 foi apresentado sobre a importância da promoção da saúde e da prevenção de doenças, sejam elas primárias, secundárias, terciárias ou quaternárias, bem como a importância da identificação dos fatores de risco e sinais indicativos do AVC.

No capítulo 3, foram apresentados estudos científicos que fizeram uso de técnicas de inteligência artificial, para auxiliar em diagnósticos mais precisos e como essas soluções são promissoras para auxiliar em diagnósticos preventivos. Mediante a isso, surge a necessidade de uma ferramenta preditiva que seja capaz de auxiliar os profissionais da saúde no processo de tomada de decisão e identificar de forma rápida o risco de uma pessoa ter ou não um AVC.

A ferramenta proposta foi intitulada Stroke.IA, por se tratar de uma ferramenta inteligente para fazer a predição do AVC. A ferramenta tem como objetivo principal auxiliar os profissionais da saúde na identificação de pacientes propensos a terem AVC, baseando-se nos fatores de risco e sinais indicativos apresentados pelo paciente. A Figura 18 apresenta a arquitetura proposta para a ferramenta.

Figura 18 – Arquitetura da ferramenta proposta.



Fonte: Autoria.

1. A ferramenta recebe os dados do paciente (dados pessoais e quadro clínico).
2. O modelo recupera os dados armazenados no banco de dados e realiza o treinamento e teste do modelo.
3. Em seguida, a ferramenta utiliza os dados do paciente para realizar a classificação do AVC e apresenta tanto o resultado da classificação quanto a probabilidade associada. Isso é feito para auxiliar o profissional de saúde a compreender a decisão, embora a ênfase principal seja na classificação em si, a probabilidade associada também é apresentada para fornecer informações adicionais ao profissional de saúde.
4. Após isso, a ferramenta atualiza o banco de dados com os dados do paciente, incluindo a classificação do AVC.

A Seção 5.2, apresenta a descrição do modelo preditivo e a apresentação da modelagem da ferramenta proposta, respectivamente.

5.2 Descrição e Modelagem da Ferramenta

Iniciou-se a modelagem da ferramenta a partir da definição dos requisitos funcionais, que estabelecem as funcionalidades essenciais que o software deve incorporar para atender plenamente às necessidades dos usuários (SOMMERVILLE, 2011; VAZQUEZ; SIMÕES, 2016). No Quadro 10 são apresentados os requisitos funcionais propostos para a ferramenta.

Quadro 10 – Requisitos Funcionais.


Título	Descrição
RF001 - Visualizar dashboard.	A ferramenta deverá permitir a visualização gráfica de um <i>dashboard</i> , apresentando dados mais gerais sobre a classificação do AVC, como também dados específicos, por paciente selecionado.
RF002 - Exibir dados gerais.	A ferramenta deverá permitir a visualização gráfica para a classificação do AVC, em baixo, médio e alto risco, ou seja, os pacientes que apresentaram probabilidade positiva entre 0-33%, ficam como baixo risco, as probabilidades entre 34-66% ficam com médio risco, e entre 67-100% ficam com alto risco.
RF003 - Exibir dados por paciente.	A ferramenta deverá permitir a visualização gráfica individual por paciente, com a apresentação do histórico de consultas, com sua determinada classificação para os dias de atendimento.
RF004 - Visualizar pacientes.	A ferramenta deverá permitir a visualização de todos os pacientes cadastrados no sistema.
RF005 - Visualizar quadro clínico.	A ferramenta deverá permitir a visualização de todos os quadros clínicos cadastrados no sistema.
RF006 - Cadastrar paciente.	A ferramenta deverá permitir o cadastro dos dados pessoais do paciente a partir das seguintes informações: nome, endereço (número, rua, bairro, cidade, estado), telefone, CPF e profissão.
RF007 - Buscar paciente.	A ferramenta deverá permitir buscar um paciente por meio da utilização do CPF.
RF008 - Editar informações do paciente.	A ferramenta deverá permitir alteração dos dados do paciente, caso seja necessário realizar essa mudança.
RF009 - Cadastrar quadro clínico do paciente.	A ferramenta deverá permitir o cadastro dos fatores de risco e sinais indicativos do paciente a partir das seguintes informações: peso, altura, idade, nível de glicose, CPF do paciente, data do atendimento, sexo, pressão diastólica e sistólica, diabetes, AVC na família, frequência cardíaca, doença no pulmão, doença cardíaca, fadiga, tontura, status fumante, diagnóstico de câncer, palpitações, percepção visual, mobilidade, dor no peito, dor nas pernas, transtorno nervoso, comunicação e dificuldade para levantar.
RF010 - Gerar probabilidade paciente.	A ferramenta deverá realizar classificação do paciente sobre a probabilidade do paciente ter, não ter ou apresentar uma indeterminação sobre o AVC com base nos sinais indicativos e fatores de risco apresentados pelo paciente. Neste, o profissional da saúde terá a opção de salvar ou não a classificação gerada, dada a sua experiência e se a classificação condiz com o cenário real.
RF011 - Confirmar probabilidade.	A ferramenta deverá permitir que o profissional da saúde informe a classificação do paciente com base nos sinais indicativos e fatores de risco apresentados, e qual a probabilidade que dada a sua experiência aquele paciente tem para o AVC dada a classificação informada.

Fonte: Autoria.

Após a definição dos requisitos funcionais, fez-se a criação de um diagrama de casos de uso e a definição de um Diagrama Entidade-Relacionamento (DER). Essas representações visuais foram importantes para auxiliar na compreensão da interação entre os usuários e a ferramenta, assim como na estruturação das entidades e suas relações. Além disso, fez-se a implementação executável da ferramenta, transformando os requisitos e as representações visuais em uma ferramenta funcional.

De acordo Guedes (2018), o diagrama de casos de uso busca permitir compreender o comportamento externo do sistema por qualquer pessoa e apresentar o sistema pela perspectiva do usuário. Seu objetivo principal é apresentar uma visão geral das funcionalidades que o sistema deverá oferecer com relação aos requisitos. Consiste em dois itens principais, atores e casos de uso (GUEDES, 2018). Este trabalho tem como autor a representação de um profissional da saúde que irá utilizar os serviços e as funcionalidades. Na Figura 19 é apresentado o diagrama de casos de uso do STROKE.IA, que apresenta o profissional da saúde como ator principal e 11 casos de uso.

Figura 19 – Diagrama de casos de uso.



Fonte: Aatoria.

Após a criação do diagrama de casos de uso, partiu-se para a definição de um modelo de banco de dados para representar como será seu funcionamento. De acordo com Heuser (2009), um modelo de banco de dados consiste no detalhamento dos tipos de informações que podem ser armazenadas em um banco de dados. Assim, pode-se utilizar a modelagem de banco de dados para fazer esse detalhamento. Para isso, existem dois modelos principais: modelo conceitual e modelo lógico.

O modelo conceitual é o detalhamento do banco de dados desconsiderando a implementação, seu foco é apresentar os dados que serão armazenados no banco de dados. Uma


das formas de representação da modelagem conceitual é por meio da abordagem Entidade-Relacionamento representado graficamente através do Diagrama Entidade-Relacionamento (DER) (HEUSER, 2009).

Nessa abordagem o conceito de entidade está relacionado com os objetos da realidade que deseja-se manter informações no banco e os relacionamentos são caracterizados pelas relações existentes entre as entidades. Já o modelo lógico está relacionado com a descrição do banco de dados de forma mais abstrata, referente a definição das tabelas do banco propriamente ditas (HEUSER, 2009).

O banco de dados proposto consiste em quatro tabelas relacionais interconectadas e uma tabela adicional para armazenar e atualizar a base de dados. A Tabela “Admin” é responsável por armazenar informações do administrador, como senha, login, nome, e-mail e código. Neste trabalho, utilizou-se apenas um único administrador que foi cadastrado diretamente no banco de dados. A Tabela “Paciente” é responsável por armazenar os dados pessoais dos pacientes, incluindo nome, informações de endereço, profissão, telefone, código do paciente e código do profissional da saúde. O código do paciente e o código do profissional da saúde são usados para estabelecer uma referência entre o paciente e o profissional da saúde responsável pelo atendimento. Neste trabalho, foi realizado o cadastro de apenas um administrador na ferramenta. Esse administrador é responsável por gerenciar e acessar as funcionalidades e dados relacionados à aplicação proposta. O cadastro desse único administrador foi inserido diretamente no banco de dados durante o processo de implementação.

A Tabela “QuadroC” armazena dados relacionados ao peso, idade, altura, nível de glicose, data do atendimento, CPF do paciente, para relacionar o quadro clínico a um determinado paciente. Além disso, a Tabela “QuadroC” também armazena o código do profissional da saúde, a probabilidade, seja a gerada pela ferramenta ou à informada pelo profissional da saúde e os fatores de risco e sinais indicativos utilizados pelo modelo. Na Figura 20 é apresentado o diagrama DER proposto para o sistema.

Figura 20 – Diagrama Entidade-Relacionamento.



Fonte: Autoria.

No processo de treinamento do modelo, a base de dados utilizada estava no formato de planilha `xlsx`¹. Com o objetivo de trabalhar apenas com um tipo de dado e facilitar o tratamento dos dados, decidiu-se realizar a cópia da base para uma tabela no banco de dados. Essa abordagem permitiu centralizar o tratamento dos dados em uma única ferramenta e em um mesmo tipo de dados. É importante ressaltar que essa tabela criada para treinamento do modelo não possui relacionamentos com as outras tabelas do banco de dados. Seu propósito principal é armazenar os dados necessários para treinar o modelo e também ser atualizada com os novos dados dos pacientes que estiverem sendo classificados.

Finalizado o modelo DER, partiu-se para a codificação. Segundo Audy (2007), a codificação é a tradução dos artefatos do projeto para uma linguagem de máquina. Para a codificação foi utilizado a linguagem de programação Python, a IDE PyCharm e a biblioteca Streamlit. Como Sistema de Gerenciamento de Banco de Dados (SGBD), foi utilizado o PostgreSQL. A seguir serão apresentadas as telas desenvolvidas ².

¹ Formato de arquivo padrão para Excel (MICROSOFT, 2023).

² O código-fonte da ferramenta, encontra-se disponível em um repositório no Github (SILVA, 2023).

5.3 STROKE.IA - Uma Ferramenta para Auxílio na Classificação de Pacientes em Relação ao AVC

Na Figura 21 é apresentada a tela inicial da ferramenta³, que consiste na apresentação de dois gráficos, o primeiro representando os dados gerais de todas as classificações, e o segundo mais específico, representando os dados de classificação por paciente (classificações do paciente e as datas de atendimento), nesta estão relacionados aos requisitos RF001 (Visualizar *dashboard*), RF002 (Exibir dados gerais) e RF003 (Exibir dados por paciente).

Figura 21 – Tela inicial do sistema.



Fonte: Autoria.

A Figura 22 representa o requisito RF004 (Visualizar pacientes). Quando o profissional da saúde acessar a opção de pacientes, será possível visualizar todos os pacientes cadastrados no sistema. Nessa tela também é apresentada a opção de cadastrar e buscar um paciente. Ao selecionar a opção de “cadastrar paciente”, os dados pessoais do paciente (Figura 23) são apresentados, e representa o requisito RF006 (Cadastrar paciente). Ao selecionar a opção “Buscar paciente”, é apresentado um campo de busca, e em seguida, são apresentadas as informações do paciente, possibilitando a edição dos dados (Figura 24) e representam os requisitos RF007 (Buscar paciente) e RF008 (Editar informações do paciente).

³ Um vídeo demonstrando o funcionamento da ferramenta encontra-se disponível no link: <https://www.loom.com/share/e87ac032101a4f65a9db96cd3451b0e9?sid=80afb811-3dec-40d3-b904-4bc89b8931d8>

Figura 22 – Visualização de todos os pacientes.

Stroke predict

Início

Pacientes

Quadro clínico

Visualizar paciente

Cadastrar paciente

Buscar paciente

Carregar

Nome	CPF	Telefone	Profissão	Estado	Cidade
Adriana	1234	8498	Dev	RN	Encanto
Leonardo Jordan	99999999	987654	Enfermeiro	Rio Grande do Norte	Pau dos ferros
Naruto Uzumaki	123456	8888888	Hokage	RN	Encanto
Laise Lara Firmo Bandeira	08273418499	84 981080602	Enfermeira	RN	Encanto
Maria Florentina	123456789	000	Agricultora	RN	Encanto
luma juliana	12345	84 981179625	enfermeira	rn	encanto
José	1234562	8766577676	agricultor	RN	Encanto

Página 1/1

Fonte:Autoria.

Figura 23 – Cadastro dos dados pessoais do paciente.

Stroke predict

Início

Pacientes

Quadro clínico

Dados pessoais

Informações de endereço

Nome completo

Informe o nome completo

CPF

Informe o CPF

Telefone

Informe o telefone

Profissão

Informe a profissão

Estado

Informe o estado

Cidade

Informe o cidade

Bairro

Informe o bairro

Rua

Informe a rua

Nº

Informe o número da residência

Cadastrar

Fonte:Autoria.

Figura 24 – Edição e busca do paciente.

Stroke predict

Inicio

Pacientes

Quadro clínico

Visualizar paciente Cadastrar paciente **Buscar paciente**

Informe o CPF

1234 - +

Dados pessoais

Nome completo

Adriana

Telefone

8498

Profissão

Dev

Informações de endereço

Estado

RN

Cidade

Encanto

Bairro

São Luiz

Rua

Fonte:Autoria.

A Figura 25 apresenta a visualização de todos os quadros clínicos cadastrados e representa o requisito RF005 (Visualizar quadro clínico). Ao selecionar a opção “Cadastrar quadro clínico”, são apresentados os campos de cadastro do quadro clínico, no qual inicialmente é preciso informar o CPF do paciente, as informações relacionadas aos fatores de risco e sinais indicativos e representa o requisito RF009 (Cadastrar quadro clínico do paciente) (Figuras 26, 27 e 28). Também são apresentados os campos para que o profissional da saúde insira a classificação e a probabilidade do AVC para aquele paciente, dado sua experiência profissional. Ao final da página, são apresentados dois botões para a interação dos usuários: “Confirmar probabilidade” e “Gerar probabilidade”.

Figura 25 – Visualização de todos os quadros clínicos.

Stroke predict

Inicio

Pacientes

Quadro clínico

Visualizar Quadros clínicos Cadastrar Quadros clínicos

Carregar

CPF	Data do atendimento	Idade	Sexo	Classificação	Probabilidade
1234	03/05/2023	24	Feminino	Sim	80.0%
1234	03/05/2023	24	Feminino	Não	61.5%
99999999	25/01/2023	28	Feminino	Sim	80.0%
99999999	25/01/2023	28	Feminino	Não	93.5%
123456	06/03/2023	44	Feminino	Não	82.0%
123456	06/03/2023	44	Feminino	Não	85.0%
123456789	25/01/2023	34	Feminino	Indefinido	15.0%
123456789	25/01/2023	34	Feminino	Não	69.0%
12345	25/01/2023	70	Feminino	Sim	95.0%
12345	25/01/2023	70	Feminino	Não	88.0%

Página 1/2

Próxima

Fonte:Autoria.

Figura 26 – Cadastro do quadro clínico 1.

Stroke predict

Início

Pacientes

Quadro clínico

Visualizar Quadros clínicos Cadastrar Quadros clínicos

Selecione o nome e CPF do paciente

Leonardo Jordan - 99999999

Fatores de risco

CPF (campo obrigatório)

Digite o CPF apresentado acima

Data do atendimento

2023/01/25

Idade

0

Peso (em kg)

0,00

Altura (em m)

Sinais indicativos

Teve tontura?

☒ Sim

☐ Não

Teve fadiga?

☒ Sim

☐ Não

Consegue ver bem o suficiente?

☒ Sim

☐ Não

Teve dor ou desconforto no peito?

☒ Sim

☐ Não

Fonte:Autoria.

Figura 27 – Cadastro do quadro clínico 2.

Stroke predict

Início

Pacientes

Quadro clínico

90

☐ Não

Diabetes?

☐ Normal

☐ Diminuição da tolerância a glicose

☒ Diabetes

Tem histórico de AVC na família?

☒ Sim

☐ Não

Frequência cardíaca

100,00

Tem alguma doença no pulmão?

☒ Sim

☐ Não

Tem algum transtorno nervoso?

☒ Sim

Tem dificuldades para levantar?

☒ Sim

☐ Não

☐ Não informado

Probabilidade de AVC

Tem probabilidade AVC?

☒ Sim

☐ Não

☐ Indeterminado

Informe a probabilidade (Sim, não ou indeterminado)

80,00

Fonte:Autoria.

Figura 28 – Cadastro do quadro clínico 3.

Stroke predict

Início

Pacientes

Quadro clínico

Você apresenta sintomas?

☒ Sim
☐ Não

Informe o sexo do paciente

☒ Feminino
☐ Masculino

É fumante?

☒ Nunca fumou
☐ Ex-fumante
☐ Fuma atualmente

Confirmar probabilidade

Gerar probabilidade

Fonte: Autoria.

O botão “Confirmar probabilidade” permite salvar a classificação e probabilidade informada pelo profissional da saúde (Figura 27). Já o botão “Gerar probabilidade” permite que o usuário solicite a geração de uma nova classificação e probabilidade com base nas informações fornecidas. Esses botões fornecem uma interface intuitiva para que os usuários interajam com o sistema, realizando ações específicas de acordo com suas necessidades e objetivos. Através dessas funcionalidades, os usuários podem confirmar ou gerar novas probabilidades.

Caso o profissional da saúde deseje ele mesmo informar a classificação e probabilidade de AVC daquele paciente, é preciso inserir os dados da classificação e probabilidade e clicar no botão de “Confirmar probabilidade”. Assim, a ferramenta irá salvar os dados de classificação e probabilidade informados pelo profissional da saúde, juntamente com o restante das informações coletadas pelo quadro clínico e representa o requisito RF011 (Confirmar probabilidade).

Caso o profissional da saúde deseje que a própria ferramenta classifique e gere a probabilidade de AVC para aquele paciente, deve-se clicar no botão “Gerar probabilidade”. Ao clicar no botão é apresentado um modal com a classificação gerada e a probabilidade para a classe especificada. Dentre as possíveis classificações a ferramenta pode gerar a classificação “sim”, “não” ou “indeterminada” com suas respectivas probabilidades. A classificação “indeterminada” seria no caso que a ferramenta não conseguiu determinar se a classificação daquele paciente pertence a classe “sim” ou “não”. Na Figura 29 é apresentado o modal que representa a classificação e probabilidade gerada pela ferramenta e está relacionada com o requisito RF010 (Gerar probabilidade).

Figura 29 – Classificação do paciente gerada pelo sistema.

Formulário de Classificação do Paciente:

- Sexo: ☒ Feminino, ☐ Masculino
- É fumante?: ☒ Nunca fumou

Classificando o paciente

Baseando-se no quadro clínico apresentado o paciente tem **78,5** % de probabilidade de não ter um AVC.

Deseja salvar essa probabilidade?

Quadro Clínico cadastrado com sucesso!

Fonte:Autoria.

Além disso, também é apresentado o questionamento se o profissional deseja ou não salvar a classificação e probabilidade gerada, pois dada sua experiência, o profissional poderá identificar se os dados gerados condizem com a realidade. Neste sentido, caso opte por salvar, os dados serão armazenados na tabela quadro clínico e consequentemente a base de dados de treino e teste do modelo também é atualizada com os novos dados. Assim, à medida que novos quadros clínicos vão sendo criados e a base de dados é atualizada, a ferramenta também vai sendo treinada com novos dados e vai aprendendo, consequentemente realizando previsões mais corretas.

5.4 Considerações Finais

Neste capítulo, foram abordados os principais aspectos relacionados ao desenvolvimento da ferramenta proposta. Foram apresentados elementos fundamentais para o processo, como a definição dos requisitos, a elaboração de diagramas, a definição do banco de dados. Por fim, as telas da ferramenta desenvolvida foram apresentadas, proporcionando uma visão prática de como os usuários irão interagir e utilizar a ferramenta.

6 Resultados e Discussões

Neste capítulo é apresentado qual o algoritmo e base de dados que foram selecionados para serem avaliados em relação a predição do AVC. Em seguida, são apresentados os resultados alcançados na criação do modelo de predição do AVC (Seção 6.1). Após isso, é apresentada a realização da validação da ferramenta com os profissionais da saúde. Na sequência são ilustrados os resultados obtidos a partir dessa validação (Seção 6.2). Por fim, são discutidos os resultados alcançados (Seção 6.3).

6.1 Análise do Desempenho do Modelo Preditivo

Com o objetivo de otimizar o processo de seleção e avaliação dos algoritmos de AM a serem utilizados no desenvolvimento dos modelos, foi adotada a biblioteca PyCaret (ALI, 2020). Para isso, o PyCaret dispõe de um conjunto de 14 algoritmos pré-selecionados, sendo: *Gradient Boosting*, *Light Gradient Boosting Machine*, *Logistic Regression*, *Linear Discriminant Analysis*, *Ridge*, *Adaboost*, *Random Forest*, SVM, K-NN, *Extra Tree*, *Decision Tree*, *Naive Bayes*, *Quadratic Discriminant Analysis* e *Dummy*. Assim, utilizando esse conjunto de algoritmos, é possível avaliar o desempenho de cada algoritmo em relação a uma determinada base de dados de entrada. Com isso, é gerada uma saída que apresenta o ranking dos algoritmos com os melhores resultados nas métricas utilizadas para serem analisadas nesse trabalho: i) Acurácia; ii) Precisão; iii) *Recall*; iv) *F1-score*; v) AUC; e vi) Coeficiente kappa. Na Figura 30 é apresentado o ranking gerado pelo PyCaret.

Figura 30 – Ranking dos algoritmos gerados pelo PyCaret.

Model	
rf	Random Forest Classifier
et	Extra Trees Classifier
xgboost	Extreme Gradient Boosting
lightgbm	Light Gradient Boosting Machine
dt	Decision Tree Classifier
knn	K Neighbors Classifier
gbc	Gradient Boosting Classifier
ada	Ada Boost Classifier
lr	Logistic Regression
ridge	Ridge Classifier
lda	Linear Discriminant Analysis
svm	SVM - Linear Kernel
nb	Naive Bayes
qda	Quadratic Discriminant Analysis
dummy	Dummy Classifier

Fonte: Aatoria.

A partir desta definição, foi possível avaliar o desempenho do conjunto dos algoritmos da biblioteca PyCaret utilizando a base de dados Base25, com o objetivo de identificar qual desses algoritmos apresentava os melhores resultados 30. Mediante a isso, o algoritmo *Random Forest* se destacou por apresentar os melhores resultados. No Quadro 11 são apresentados os parâmetros do *Random Forest* utilizados na construção dos modelos de predição com a utilização da biblioteca PyCaret.

Quadro 11 – Parâmetros do modelo utilizando o PyCaret

Modelo	Parâmetro
RandomForestClassifier	bootstrap=True, ccp_alpha=0.0, class_weight=None, criterion='gini', max_depth=None, max_features='auto', max_leaf_nodes=None, max_samples=None, min_impurity_decrease=0.0, min_impurity_split=None, min_samples_leaf=1, min_samples_split=2, min_weight_fraction_leaf=0.0, n_estimators=100, n_jobs=1, oob_score=False, random_state=484, verbose=0, warm_start=False

Fonte: Aatoria.

Embora o algoritmo *Random Forest* tenha inicialmente apresentado bom desempenho, percebeu-se a oportunidade de melhorar ainda mais os resultados ajustando seus parâmetros. Para realizar essa otimização, fez-se a implementação do *Random Forest* com a biblioteca *scikit-learn*, desde a definição do conjunto de treinamento e teste até a avaliação das métricas. Assim, inicialmente fez-se a definição do conjunto de treinamento e teste utilizando a validação cruzada com $k = 10fold$. No Quadro 12 são apresentadas as modificações realizadas nos parâmetros do modelo.

Quadro 12 – Parâmetros do *Random Forest* utilizando o *scikit-learn*.

Algoritmo	Parâmetros
<i>Random Forest</i>	'criterion': 'entropy', 'max_depth': None, 'max_features': 'sqrt', 'min_samples_leaf': 10, 'min_samples_split': 2, 'n_estimators': 200, 'n_jobs': -1, 'random_state': 42

Fonte: Autoria.

Ao otimizar os parâmetros do modelo, é possível alcançar melhorias significativas no desempenho, eficiência e robustez do mesmo, tornando o modelo mais adequado para ser utilizado. Após a implementação dessas melhorias, foi realizada uma nova análise das métricas para a Base25, resultando melhorias nos resultados. O AUC atingiu 0,96, o coeficiente kappa registrou 0,82, e a acurácia, precisão, *f1-score* e *recall* alcançaram 89,43%. Na Tabela 3, apresentamos os detalhes dessas métricas.


Tabela 3 – Resultados da Base25

Base25					
AUC	Kappa	Acurácia	Precisão	<i>F1-Score</i>	<i>Recall</i>
0.96	0.82	89.43%	89.43%	89.43%	89.43%

Fonte: Autoria.

Após essa análise, foi obtida uma matriz de confusão contendo as seguintes informações: Para as 1492 amostras da classe 2 - indeterminada, 24 foram classificadas de forma errada como classe 1 - sim e 89 foram classificadas erroneamente como classe 0 - não. Para as 1485 amostras da classe 1 - sim, 77 foram classificadas erroneamente como classe 0 - não e 39 amostras foram classificadas erroneamente como classe 2 - indeterminada. Para as 1417 amostras da classe 0 - não, 154 amostras foram classificadas erroneamente como classe 1 - sim e 148 amostras foram classificadas erroneamente como classe 2 - indeterminada (Figura 31).

Figura 31 – Matriz de confusão para a Base25.



Fonte: Autoria.

Dada a seleção de recursos realizada utilizando a técnica de permutação de recursos (Figura 13), fez-se a criação de mais 3 bases de dados, considerando apenas os atributos com maior importância. A definição das bases criadas foi apresentada na Seção 4.3.

Na Tabela 4 são apresentados os resultados das métricas analisadas para a Base21, com AUC de 0,97, coeficiente kappa com 0,84, acurácia, precisão, *f1-score* e o *recall* com 90,74%. O que mostra uma melhoria com relação às métricas, quando comparado com as métricas da Base25 principalmente com relação a acurácia, precisão, *f1-Score* e o *recall*.


Tabela 4 – Resultados da Base21.

Base21					
AUC	Kappa	Acurácia	Precisão	<i>F1-Score</i>	<i>Recall</i>
0.97	0.84	90.74%	90.74%	90.74%	90.74%

Fonte: Autoria.

Na Figura 32 é apresentada a matriz de confusão para a Base21. Nessa matriz, podemos observar as seguintes informações: Das 1492 amostras da classe 2 - indeterminada, 18 amostras foram classificadas erroneamente como classe 1 e 68 amostras foram classificadas erroneamente como classe 0. Com relação à classe 1 - sim, das 1485 amostras, 30 foram classificadas de forma errada como classe 2 - indeterminada e 72 amostras foram classificadas erroneamente como classe 0 - não. Com relação às 1417 amostras da classe 0 - não, 146 foram classificadas erroneamente como classe 1 - sim e 138 amostras foram classificadas erroneamente como classe 2 - indeterminada.

Figura 32 – Matriz de confusão da Base21.



Fonte: Autoria.

Na Tabela 5 são apresentados os resultados das métricas analisadas para a Base16, com AUC com 0,97 o coeficiente kappa com 0,83, acurácia, precisão, *f1-score* e o *recall* com 90,50%. Ao comparar com os resultados apresentados na Base21, é notório que a acurácia, precisão, *f1-score* e o *recall* foram menores quando comparados com a Base21.


Tabela 5 – Resultados da Base16.

Base16					
AUC	Kappa	Acurácia	Precisão	<i>F1-Score</i>	<i>Recall</i>
0.97	0.83	90.50%	90.50%	90.50%	90.50%

Fonte: Autoria.

Na Figura 33 é apresentada a matriz de confusão para a Base16. Nessa matriz, é possível observar as seguintes informações: das 1492 amostras da classe 2 - indeterminada, 20 amostras foram classificadas erroneamente como classe 1 e 72 amostras foram classificadas erroneamente como classe 0. Com relação à classe 1 - sim, das 1485 amostras, 25 foram classificadas de forma errada como classe 2 - indeterminada e 79 amostras foram classificadas erroneamente como classe 0 - não. Com relação às 1417 amostras da classe 0 - não, 151 foram classificadas erroneamente como classe 1 - sim e 135 amostras foram classificadas erroneamente como classe 2 - indeterminada.

Figura 33 – Matriz de confusão para a Base16.



Fonte: Autoria.

Na Tabela 6 são apresentados os resultados das métricas analisadas para a Base11, com o AUC com 0,96, coeficiente kappa com 0,81, acurácia, precisão, *f1-score* e *recall* de 88,94%. Na Tabela 3, são apresentados os resultados das métricas.


Tabela 6 – Resultados da Base11.

Base11					
AUC	Kappa	Acurácia	Precisão	<i>F1-Score</i>	<i>Recall</i>
0.96	0.81	88.94%	88.94%	88.94%	88.94%

Fonte: Autoria.

Na Figura 34 é apresentado a matriz de confusão para a Base11, na qual das 1492 amostras da classe 2 - indeterminada, 18 amostras foram erroneamente classificadas como classe 1 - sim e 68 amostras foram erroneamente classificadas como classe 0 - não. Com relação à classe 1 - sim, das 1485 amostras, 30 foram erroneamente classificadas como classe 2 - indeterminada e 72 amostras foram erroneamente classificadas como classe 0 - não. Com relação às 1417 amostras da classe 0 - não, 146 foram erroneamente classificadas como classe 1 - sim e 138 amostras foram erroneamente classificadas como classe 2 - indeterminada. Observando esses resultados, é possível constatar que as amostras da classe 0 - não apresentaram a maior quantidade de classificações errôneas em relação às outras classes.

Figura 34 – Matriz de confusão Base11.



Fonte:Autoria.

Comparando os resultados das métricas, a Base21 apresentou o melhor desempenho com relação as métricas analisadas. Isso indica que a Base21 obteve uma classificação mais precisa e equilibrada em comparação com as outras bases. Além disso, por fim, com o objetivo de identificar se a Base21 apresentaria o algoritmo *Random Forest* como o melhor algoritmo usando a biblioteca PyCaret, realizou-se novamente a análise da Base21 com a biblioteca PyCaret, e os resultados confirmaram que o algoritmo *Random Forest* continuou sendo o que apresentou os melhores resultados. Com base nisso, essa foi a base de dados utilizada no desenvolvimento da ferramenta preditiva.

6.2 Análise de Desempenho e Usabilidade da Ferramenta Preditiva

Para este trabalho, o propósito do teste de usabilidade foi avaliar problemas e aspectos para melhoria da interface do STROKE.IA. No entanto, devido ao tempo, foi necessário realizar uma adaptação do teste de usabilidade, de modo a permitir a realização do teste, mas sem um ambiente e ações controladas. Para isso o teste consistiu em 3 etapas: i) questionário pré-teste, ii) realização das tarefas propostas e iii) entrevista pós-teste.

6.2.1 Questionário pré-teste

O teste foi realizado no formato presencial em um hospital da cidade de Encanto-RN, com exceção de um participante que o teste foi realizado em sua residência. O teste ocorreu entre os dias 1 e 12 de abril de 2023 de acordo com a disponibilidade dos participantes e com duração de aproximadamente 30 minutos por participante. Os quais estavam dentro do público alvo definido para a ferramenta. Contou com a participação de 5 usuários,

respeitando o mínimo de participantes recomendados. Estes foram recrutados por meio de ligações para identificar a disponibilidade e o interesse em participar do teste.

Com isso, antes de iniciar a execução do teste, os participantes foram conduzidos a responderem um questionário sobre o perfil, com o objetivo de identificar qual o perfil de trabalho deles. As perguntas consistiam em identificar: i) área de especialização; ii) tempo de atuação na área; iii) experiência direta no atendimento de pacientes com AVC; iv) com base na sua experiência deles, quais fatores de risco são mais relevantes para o desenvolvimento de um AVC; v) os sintomas mais comuns que um paciente apresenta quando tem um AVC; vi) se já atendeu um paciente que estava relativamente bem e teve um AVC dias ou meses depois; e vii) qual a opinião dos participantes sobre a possibilidade de determinar a probabilidade de um paciente sofrer um AVC com base em seus sinais indicativos e fatores de risco. O Quadro 13 apresenta as perguntas relacionadas ao questionário pré-teste.

Quadro 13 – Questionário sobre o perfil do participante


Qual é a sua área de especialização?	Clínica Médica
	Pediatria
	Cardiologia
	Dermatologia
	Ginecologia
	Neurologia
	Outra
Por quanto tempo você tem atuado nessa área?	Menos de 1 ano
	Entre 1 e 3 anos
	Entre 4 e 6 anos
	Entre 7 e 9 anos
	Mais de 10 anos
	Outro
Você já teve experiência direta no atendimento de pacientes com AVC?	Sim
	Não
Com base na sua experiência, quais fatores de risco são mais relevantes para o desenvolvimento de um AVC?	Hipertensão arterial
	Doenças cardíacas
	Diabetes
	Colesterol elevado
	Tabagismo
	Obesidade
	Outros
Quais são os sintomas mais comuns que um paciente apresenta quando tem um AVC?	Fraqueza súbita em um lado do corpo, incluindo braço, perna ou face.
	Dormência súbita em um lado do corpo, incluindo braço, perna ou face.
	Confusão súbita, dificuldade para falar ou entender a fala.
	Perda súbita de visão em um ou ambos os olhos.
	Tontura súbita, perda de equilíbrio ou coordenação.
	Dor de cabeça súbita, intensa e sem explicação aparente.
	Dificuldade súbita para andar, perda de equilíbrio ou coordenação.
	Outro
Você já atendeu um paciente que estava relativamente bem e teve um AVC dias ou meses depois?	Sim
	Não
Na sua opinião, é possível determinar a probabilidade de um paciente sofrer um AVC com base em seus sinais indicativos e fatores de risco?	Aberta

Fonte: Autoria.

Com base na análise dos dados preenchidos, foi identificado que dos 5 participantes, 3 trabalham na área de Enfermagem, 1 na área de Saúde Mental e 1 na área de Terapia Intensiva. Com relação ao tempo de atuação, 2 participantes têm entre 1 e 3 anos, 2 estão entre 4 e 6 anos e apenas um deles tem mais de 10 anos de experiência. Além disso, todos os participantes relataram ter experiência direta no atendimento de pacientes com AVC.

Com relação às perguntas voltadas aos fatores de risco que apresentaram maior relevância para a ocorrência do AVC, bem como os sinais e sintomas mais comuns. Com base nas respostas obtidas foi possível identificar as seguintes informações: i) 5 participantes afirmaram que a hipertensão arterial pode ser uma condição percebida como um fator de risco significativo para o AVC; ii) 3 participantes mencionaram a relevância de doenças cardíacas, destacando a importância dessa condição como um possível fator de risco para o AVC; iii) 4 participantes marcaram a diabetes como relevante, ressaltando a associação dessa doença crônica com um maior risco de AVC. iv) 3 participantes marcaram o colesterol elevado, o que sugere a relevância dessa condição como um fator de risco para o AVC; v) 4 participantes marcaram o tabagismo, destacando o hábito do tabagismo como um fator de risco adicional para o desenvolvimento de um AVC; e vii) 3 participantes marcaram a obesidade, o que destaca a relação entre o excesso de peso e o risco aumentado de AVC. A Figura 35 apresenta esses fatores de risco considerados mais relevantes pelos participantes para a ocorrência do AVC.

Figura 35 – Fatores de risco mais relevantes para à ocorrência do AVC.



Fonte: Autoria.

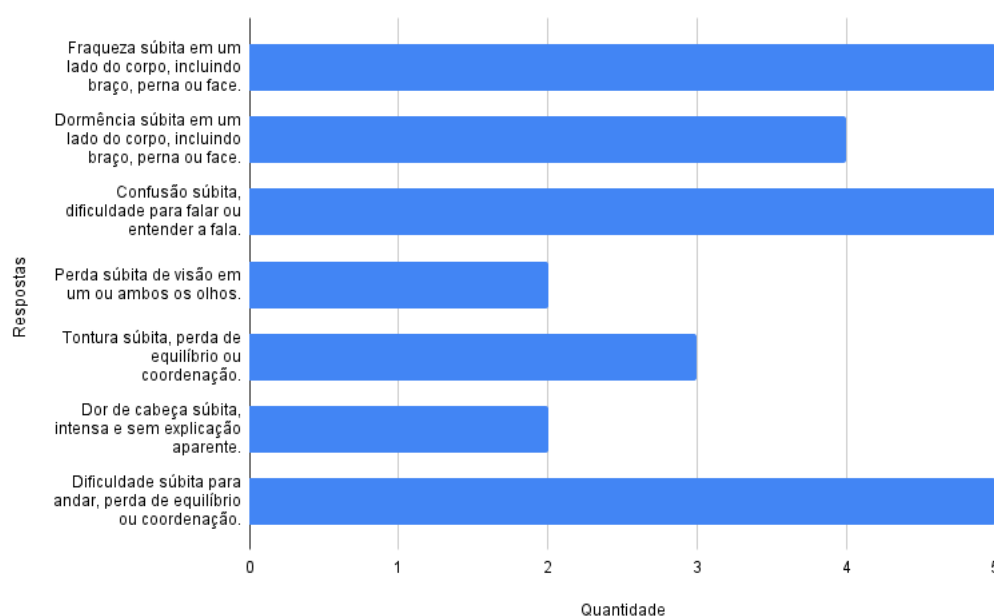
Com base nos dados coletados no questionário com relação a apresentação dos sintomas mais comuns para a ocorrência do AVC estão: 5 participantes consideraram fraqueza súbita em um lado do corpo, incluindo braço, perna ou face, como relevantes para a ocorrência do AVC; 4 participantes assinalaram que a dormência súbita em um lado do corpo, incluindo braço, perna ou face é um sintoma relevante para a ocorrência do AVC.

Com relação a confusão súbita, dificuldade para falar ou entender a fala, 5 participantes indicaram que são sintomas relevantes para a ocorrência do AVC. Esses sintomas são considerados altamente relevantes pelos participantes. 2 participantes assinalaram que a perda súbita de visão em um ou ambos os olhos são um sintoma relevante para a ocorrência do AVC. Embora menos participantes tenham marcado esse sintoma, ainda é considerado como um possível indicador de AVC.

No que diz respeito a tontura súbita, perda de equilíbrio ou coordenação, 3 participantes consideraram como sintomas relevantes para a ocorrência do AVC. Esse sintoma foi percebido com menos frequência em comparação com outros sintomas mencionados anteriormente. 2 participantes marcaram a dor de cabeça súbita, intensa e sem explicação aparente como um sintoma relevante para a ocorrência do AVC.

Com relação a dificuldade súbita para andar, perda de equilíbrio ou coordenação, 5 participantes relataram que são sintomas relevantes para a ocorrência do AVC. Esse sintoma foi considerado um dos mais importantes pelos participantes da pesquisa. Esses dados fornecem informações sobre a percepção dos participantes em relação aos sintomas mais relevantes para a ocorrência do AVC. A Figura 36 apresenta os sintomas considerados mais comuns pelos participantes para a ocorrência do AVC.

Figura 36 – Sintomas mais comuns relacionados à ocorrência do AVC.



Fonte: Autoria.

Com relação ao atendimento de pacientes que inicialmente estavam relativamente bem e posteriormente tiveram um AVC, foram identificados os seguintes pontos: dos 5 participantes, 3 afirmaram ter realizado atendimentos a pacientes nessas circunstâncias, o

que indica que já tiveram experiência com casos desse tipo. Por outro lado, 2 participantes informaram ainda não terem realizado atendimentos semelhantes. Além disso, com relação a opinião deles sobre a possibilidade de determinar a probabilidade de um paciente sofrer um AVC com base em seus sinais indicativos e fatores de risco, ambos informaram que sim e que a depender do estilo de vida e fatores de risco com o avançar da idade a probabilidade aumenta e a partir disso é possível iniciar algumas condutas. Esses dados sugerem que uma parte significativa dos participantes teve contato direto com pacientes que sofreram um AVC após um período em que aparentavam estar bem de saúde. Essa experiência pode contribuir para uma melhor compreensão e abordagem no atendimento a pacientes em risco de AVC ou que apresentem sintomas iniciais sutis.

O objetivo das perguntas foi coletar a percepção dos profissionais da saúde sobre os principais fatores de risco e sinais indicativos relacionados ao AVC, com base em sua experiência e área de atuação. Além disso, buscou-se identificar a relação entre esses fatores de risco e sinais indicativos e a ocorrência posterior do AVC em pessoas inicialmente saudáveis. Assim, por meio dessas informações, foi possível obter *insights* valiosos sobre os fatores de risco mais prevalentes e os sinais indicativos que mais se manifestam nos pacientes com AVC, bem como sua relação com a ocorrência do AVC em indivíduos anteriormente considerados saudáveis.

6.2.2 Teste de usabilidade

Para realizar o teste de usabilidade, foi realizada uma análise da interface, visando abranger todas as funcionalidades da ferramenta. Com base nessa análise, foram criadas tarefas que guiavam os participantes durante a utilização da ferramenta. As tarefas foram projetadas para incluir todos os requisitos apresentados no Quadro 10 e refletir os principais fluxos de trabalho esperados na ferramenta. O roteiro do teste foi cuidadosamente elaborado, incluindo 7 tarefas contextualizadas em 6 cenários diferentes. Esse roteiro foi impresso e entregue aos participantes. No Quadro 14 são apresentadas as tarefas do roteiro.

Quadro 14 – Roteiro de tarefas na avaliação da ferramenta

Cenário 1	Ao chegar no hospital municipal de Encanto/RN para realizar mais um plantão, você irá utilizar o sistema para atender os pacientes. Considere que chegou um paciente e você irá utilizar o sistema para realizar o atendimento.
Tarefa 1	Utilize o sistema para coletar os dados desse paciente. Antes de preencher os campos, por favor diga em voz alta o que pretende fazer.
Tarefa 2	Visualize se os dados do paciente foram cadastrados.
Cenário 3	Após preencher os campos com as informações do paciente e salvá-las no sistema, ele informou que errou o nome do bairro onde mora. Nesse caso, é importante fazer a correção o mais rápido possível para evitar possíveis problemas no atendimento.
Tarefa 3	Informe o paciente cujo bairro foi informado incorretamente e faça a correção. Após fazer a correção, volte para a tela de listagem de pacientes e verifique se o nome do bairro foi atualizado corretamente.
Cenário 4	Após ter cadastrado as informações básicas do paciente, é hora de registrar o quadro clínico dele.
Tarefa 4	Utilize o sistema para realizar o cadastro do quadro clínico desse cliente, e com base em sua experiência, determine a probabilidade dele sofrer um AVC.
Cenário 5	Agora, você deseja que o próprio sistema gere a probabilidade desse paciente sofrer um AVC.
Tarefa 5	Utilize o sistema para realizar o cadastro do quadro clínico desse cliente, utilizando o sistema para gerar probabilidade do paciente sofrer um AVC.
Cenário 6	Você concluiu o atendimento anterior e forneceu as orientações necessárias ao paciente. Em seguida, um segundo paciente chegou. Esse paciente já havia sido atendido outras vezes.
Tarefa 6	Utilize o sistema para verificar o histórico de atendimentos anteriores desse paciente e avaliar sua probabilidade de AVC.
Tarefa 7	Utilize o sistema para visualizar as estatísticas gerais das probabilidades de AVC de todos os pacientes cadastrados.

Fonte: Autoria.

Na execução do teste de usabilidade, primeiramente, o condutor dirigiu-se até o local determinado (hospital e residência), e em seguida, instruiu os participantes na realização das tarefas. Os cenários apresentaram um contexto e informações necessárias para a compreensão das tarefas. Os participantes não receberam orientações escritas ou faladas sobre como usar a interface, sendo responsáveis por realizar o mapeamento entre os objetivos das tarefas e sua realização.

Em seguida, o participante recebeu o roteiro impresso e foi convidado a realizar as tarefas utilizando o STROKE.IA. Ele foi informado que poderia desistir de alguma tarefa em qualquer momento, se assim desejasse. Durante a condução do teste, utilizou-se uma adaptação da metodologia *think aloud*, na qual o participante é solicitado a falar em voz

alta sobre seus pensamentos e raciocínios enquanto executa as tarefas. Esse método tem como objetivo obter *insights* sobre a forma como o participante resolve problemas e toma decisões (JASPERS *et al.*, 2004). Durante o teste, o participante foi orientado a expressar em voz alta seus pensamentos, incluindo o motivo de cada ação realizada. O condutor do teste registrou os pontos de destaque enquanto o participante falava em voz alta. Esses pontos de destaque incluíam:

- **P1: Participante 1**

- Houve a observação da falta de um campo específico para inserir o número do SUS, sendo sugerido também a busca do paciente por esse número e a troca do CPF pelo número do SUS no quadro clínico. Outra sugestão anotada, envolve a visualização e edição dos pacientes, onde foi apontada a dificuldade de identificar onde encontrar essa opção, além da sugestão de incluir a visualização do histórico diretamente na lista de pacientes.
- No que diz respeito à usabilidade, foi sugerida a troca do nome do botão “Carregar” por “Recarregar lista de pacientes”. Também foram mencionadas sugestões de ajustes nos termos utilizados, como substituir “escutar bem para conversar” por “alteração na fala” e “ver bem o suficiente” por “alterações visuais”. Algumas sugestões se referem à inclusão de informações adicionais e especificações, como especificar se a glicose é em jejum ou não, deixar mais claro o nível de glicose sanguínea relacionado à diabetes e incluir a frequência cardíaca com a indicação de “bpm”. Além disso, foi sugerido incluir dor nos membros inferiores.
- Outras sugestões envolvem melhorias na interface, como eliminar o zero dos campos, incluir a opção de “dificuldade de locomoção” e adicionar outra opção para “fraqueza nos membros gerais”. Também foi sugerida a inserção de uma opção de busca na listagem e a separação da probabilidade do sistema e do profissional no gráfico para evitar confusões.

- **P2: Participante 2**

- Sugeriu adicionar a opção de cadastrar um paciente na tela de início. Também foi sugerido inserir um campo específico para o número do SUS durante o cadastro, bem como utilizar o número do SUS como documento identificador principal.
- Outro ponto anotado foi com relação a listagem do paciente, em que o P2 sugeriu ao clicar em um paciente na listagem, apresentar as informações relevantes imediatamente. Incluir também uma barra de busca na listagem de pacientes e permitir a busca por nome e data. Além disso, mostrar as probabilidades relacionadas ao AVC de forma unificada, abrangendo tanto as probabilidades do sistema quanto as do profissional de saúde.

- **P2: Participante 3**

- Assim como o P2, o P3 sugeriu a possibilidade de cadastrar um paciente diretamente na página inicial, tornando o processo mais ágil e intuitivo. Além disso, incluir um campo específico para inserir o número do SUS durante o cadastro, facilitando a identificação do paciente. Também sugeriu para a listagem do paciente permitir a seleção do paciente, possibilitando um acesso rápido às informações relacionadas a ele. Para facilitar a visualização das medidas de pressão arterial, sugeriu agrupar as medidas diastólica e sistólica em uma única entrada.
- Outro ponto anotado foi tornar as linhas da listagem clicáveis. Na listagem do quadro clínico, foi sugerido incluir o nome e o documento de identificação do paciente, facilitando a identificação. Outra sugestão anotada foi adicionar um campo específico para registrar informações sobre a medicação do paciente, fornecendo um local adequado para esses dados.

- **P2: Participante 4**

- Sugeriu permitir o cadastro do paciente diretamente na página inicial, proporcionando maior agilidade no processo. Além disso, sugeriu-se a inclusão do número do SUS no cadastro, ampliando as informações disponíveis.
- Ao iniciar a realização das tarefas o P4 confundiu o cadastro do paciente com o *dashboard*. O mesmo sugeriu trocar a cor do botão de cadastro e alterar na edição para melhor visibilidade e inserir mais *feedbacks* para orientar os usuários durante o uso do sistema. Também sugeriu inserir uma funcionalidade de busca por nome e CPF nas listagens. Além disso, a terminologia “quadro clínico” pode ser substituída por um termo mais abrangente e informativo.
- Outras sugestões incluem a possibilidade de selecionar a data atual ao inserir a data do atendimento, a utilização de unidades de medida adequadas, como “dl” para glicose e “mmHg” para pressão arterial, a adição de valores relacionados ao pré-diabetes na seleção de diabetes e o agrupamento dos problemas de saúde relacionados a transtornos nervosos em uma seção específica.
- No que se refere à exibição de probabilidades e ao gráfico, foi sugerido priorizar a opção de gerar a probabilidade como a primeira apresentada e melhorar a legibilidade e usabilidade das cores dos botões. Além disso, sugeriu-se no gráfico, mostrar apenas a probabilidade do “sim” para uma visualização mais clara.

- **P2: Participante 5**

- Sugeriu inserir na listagem de pacientes, a data de nascimento, proporcionando uma visão mais completa das informações dos pacientes. Além disso, sugeriu

melhorar a funcionalidade de edição, uma vez que foi mencionado que não foi tão intuitivo editar a partir da busca. É necessário aprimorar essa experiência, tornando o processo de edição mais simples e acessível para os usuários.

6.2.3 Entrevista pós-teste

Depois de realizar as tarefas, os participantes expuseram suas opiniões, interpretações e sugestões sobre o uso da ferramenta, respondendo às seguintes perguntas na entrevista pós-teste, alguns optaram por eles mesmo escreverem, outros o condutor do teste foi anotando. As respostas desta entrevista estão apresentadas no Quadro 15. Além disso, como durante a realização das tarefas, os participantes do teste foram falando pontos de melhorias e que estão apresentadas anteriormente, alguns participantes não responderam algumas perguntas da entrevista, informando que já haviam falado anteriormente, e como estava tudo sendo anotado, todas as sugestões foram mapeadas.

Quadro 15 – Entrevista pós-teste.

	O que você achou da experiência de uso do sistema?	De que você gostou no sistema?	De que você NÃO gostou no sistema?	O que você acha que poderia melhorar ou incluir no sistema?
P1	“Um pouco confuso, creio que deva reorganizar melhor os menus e seus conteúdos. No mais, apresenta interface limpa e agradável.”	“Gostei da objetividade da coleta de dados clínicos do paciente.”	“Dificuldade de buscar de paciente cadastrado. Acredito que esse processo pode ser simplificado, deixando-o mais intuitivo.”	“Mudar algumas terminações para que se alinhe com a linguagem da área da saúde e organizar o conteúdo dos menus.”
P2	“Excelente, inovador e de muitos benefícios para o serviço da saúde.”	“Tudo, principalmente da rapidez no cálculo da probabilidade de ter um AVC.”	“Gostei de tudo, só pequenas mudanças sugeridas.”	Não respondeu
P3	“Inovador, prático e de grande valia tanto para o paciente quanto para o profissional.”	“Tudo. Todas as informações são válidas e necessárias.”	Não respondeu	Não respondeu
P4	“Não é difícil de usar.”	“Simplicidade.”	“O fato do sistema ser iniciante.”	Não respondeu
P5	“Bem útil na avaliação da probabilidade do paciente ter ou não um AVC. E o acompanhamento do quadro clínico durante o tratamento do mesmo.”	“Bem completo em informações sobre o quadro do paciente.”	Não respondeu	Não respondeu

Fonte: Autoria.

6.3 Discussões dos resultados

Ao utilizar a função *feature-importance* para determinar a importância dos atributos com a permutação de recursos, foi identificado que alguns atributos da Base25 não apresentaram tanta importância como o WHOME09 (Dificuldades para andar pela casa), ATRFIB07 (Fibrilação atrial), NERV01 (Transtorno nervoso) e o KIDNEY01 (Doença renal) e foram removidos da base.

Assim, com o objetivo de avaliar se o desempenho do modelo poderia ser aprimorado, foram criadas três novas bases de dados contendo diferentes conjuntos de atributos. Uma base de dados foi criada com os 20 atributos mais relevantes, outra com 15 atributos e uma terceira com 10 atributos, ambas com o atributo classe. Essa abordagem permitiu investigar quais atributos possuem maior impacto no modelo, visando identificar a combinação ideal para alcançar melhores resultados.

Após isso, com a utilização da biblioteca PyCaret, foi identificado que o algoritmo *Random Forest* foi o que apresentou melhores resultados quando comparado com outros algoritmos da mesma biblioteca, no entanto percebeu-se a oportunidade de melhorar ainda mais os resultados ajustando seus parâmetros. Para realizar essa otimização, fez-se a implementação do *Random Forest* com a biblioteca *scikit-learn*. Com isso, por meio da análise dos resultados gerados, foi possível identificar que a Base21 foi a que apresentou os melhores resultados principalmente com relação a acurácia, *recall*, *f1-score* e precisão.

Na Tabela 4 é possível perceber esses resultados em que o valor AUC com um valor de 0.97, indica que o modelo tem uma alta capacidade de distinguir corretamente entre as classes, sugerindo um bom poder de classificação. O Coeficiente kappa, com um valor de 0,84, mostra uma concordância substancial entre as previsões do modelo e os valores reais, indicando um bom desempenho de classificação. A acurácia, precisão, *f1-score* e *recall*, com valores de 90,74% para cada uma dessas métricas, sugere que o modelo está tendo um bom desempenho em termos de previsões corretas, tanto em termos de classificação geral (acurácia) quanto em relação a cada classe individualmente (precisão, *f1-score* e *recall*).

Em resumo, esses resultados indicam que o modelo está apresentando um bom desempenho geral, com uma boa capacidade de classificação, concordância e baixo erro. O modelo é consistente em suas previsões e tem uma boa taxa de previsões corretas, tanto em termos gerais quanto para cada classe separadamente. Devido a isso, este foi o modelo utilizado para ser implementado na ferramenta para realizar a classificação dos pacientes com tendência a terem um AVC, dado os resultados apresentados.

No Capítulo 3 foi identificado que o trabalho de Singh e Choudhary (2017) utilizava o mesmo conjunto de dados. Dessa forma, ao realizar um comparativo do trabalho em questão com o trabalho de Singh e Choudhary (2017) que propuseram uma abordagem de previsão de AVC, é notório algumas similaridades, a citar: devido a existência de muitos

atributos e poucas instâncias, bem como a muita quantidade de valores faltosos, tornou o pré-processamento difícil de ser realizado, uma vez que foi necessário a remoção de uma boa parte dos atributos, visto que os mesmos não tinham relação com o presente trabalho. Isso é justificável pelo fato de que a base de dados faz parte de um estudo longitudinal e envolve muitos outros parâmetros além dos relacionados aos AVC.

No trabalho de Singh e Choudhary (2017) optou-se pela remoção dos valores duplicados e ausentes, o que resultou em uma redução significativa das instâncias. No entanto, essa abordagem não foi adotada neste trabalho, pois foi identificada um atributo específico com a maior quantidade de valores ausentes. Portanto, o foco foi dado ao tratamento desses valores faltantes para esse atributo em particular, em vez de remover as instâncias que apresentavam valores ausentes em outros atributos. Essa decisão foi tomada para preservar o máximo de dados disponíveis e evitar uma redução drástica no tamanho da amostra.

Uma diferença entre o trabalho de Singh e Choudhary (2017) e o presente estudo consiste na aplicação dos métodos utilizados. Embora ambos os estudos abordem a temática do AVC, a forma como os métodos foram aplicados podem variar. No estudo de Singh e Choudhary (2017) pode-se observar uma abordagem específica para a análise e predição do AVC, utilizaram o algoritmo de Árvore de Decisão para redução da dimensionalidade e Rede Neural criação do modelo. Para validar a proposta, os autores só utilizaram duas métricas, a matriz de confusão e a acurácia, o que pode limitar a análise dos resultados do modelo quando comparado às métricas de outros modelos. Além disso, não foram apresentadas as técnicas para desbalanceamento dos dados, o que pode ter influenciado para os resultados do modelo.

No presente estudo, foram adotadas outras abordagens, como a utilização da biblioteca PyCaret sendo um diferencial, por meio da análise que a biblioteca faz para a seleção e avaliação dos modelos de aprendizado de máquina. Além disso, foi realizada uma análise detalhada dos atributos e das métricas de avaliação, buscando identificar a melhor configuração de modelos para a predição do AVC.

Ao realizar esse comparativo, pode-se observar que o modelo proposto neste trabalho apresenta diferenças em relação ao estudo realizado por Singh e Choudhary (2017), principalmente em relação à aplicação dos métodos de pré-processamento e criação do modelo. Essas diferenças podem estar relacionadas à escolha de abordagens específicas para lidar com os dados, bem como às etapas de modelagem e avaliação adotadas em cada estudo.

Com relação à validação da ferramenta por meio de um teste de usabilidade com profissionais da saúde, foram identificadas sugestões de melhorias para o cadastro, apresentação das informações e componentes visuais. Essas sugestões contribuirão para aprimorar a experiência do usuário e tornar a ferramenta mais intuitiva e eficiente.

Assim, com base nas sugestões de melhoria fornecidas pelos participantes, foi possível identificar algumas similaridades entre os pontos mencionados. Algumas das principais similaridades são: a maioria dos participantes sugeriram a possibilidade de cadastrar um paciente na página inicial, tornando o processo mais ágil e intuitivo. Também houve sugestões para incluir um campo específico para o número do SUS durante o cadastro, facilitando a identificação do paciente.

Na listagem de pacientes e visualização de informações, a maioria dos participantes também sugeriram, como tornar as linhas clicáveis para facilitar o acesso às informações. Também foi sugerido mostrar as informações relevantes de um paciente imediatamente ao selecioná-lo na listagem. Melhorias na interface e usabilidade, também foram sugeridas, principalmente com relação a ajustes nos termos utilizados, como substituir termos como “escutar bem para conversar” e “ver bem o suficiente” por descrições mais claras e específicas.

Também foi mencionada a importância de tornar a interface mais intuitiva e incluir *feedbacks* para orientar os usuários durante o uso do sistema. Também foi sugerido especificar se a glicose é medida em jejum ou não, além de melhorar a clareza das informações relacionadas à diabetes, como o nível de glicose sanguínea.

Houve também sugestões para incluir unidades de medida adequadas, como “dl” para glicose e “mmHg” para pressão arterial. Além disso, surgiram outras sugestões, como incluir a funcionalidades de busca, tanto por nome quanto por CPF, para facilitar a localização de pacientes específicos. Melhorar a exibição de probabilidades, incluindo a separação das probabilidades do sistema e do profissional no gráficos da página inicial.

Essas são algumas das similaridades identificadas com base nos pontos mencionados pelos participantes. Com relação a entrevista pós-teste, foram identificados outros pontos, como por exemplo a boa aceitação e experiência de uso do sistema, mesmo com sugestões de melhorias.

7 Conclusões

A utilização de sistemas inteligentes na área da saúde pode contribuir para o processo de tomada de decisão, uma vez que esses sistemas podem ser utilizados para auxiliar em diagnósticos mais precisos e no tratamento de doenças mais graves como o AVC. O AVC pode manifestar-se de diversas formas sendo necessário e importante a identificação de fatores de risco e sinais indicativos que possam influenciar para a ocorrência do AVC.

Com isso, a partir da realização deste trabalho foi possível: i) analisar a ocorrência do AVC dado os sinais indicativos e fatores de risco apresentados e desenvolver um modelo de predição com essa perspectiva; ii) avaliar os atributos que apresentavam maior relevância para a ocorrência do AVC; iii) avaliar um total de 14 algoritmos de aprendizado de máquina durante o desenvolvimento do modelo; iv) criar e implementar uma ferramenta inteligente fazendo uso do modelo criado; v) alimentar a base de teste sempre que um novo quadro clínico for cadastrado possibilitando que a ferramenta continue aprendendo mesmo com novos dados inseridos.

Com uma análise realizada nos dados, foi possível perceber que problemas na comunicação, dor nas pernas, fadiga e dor no peito são os sintomas que apresentaram uma maior relação com a ocorrência do AVC. Com relação aos fatores de risco, a doença no pulmão, doença cardíaca, diabetes e AVC na família foram os que apresentaram maior incidência para a ocorrência do AVC.

Foram definidas 4 bases de teste para identificar qual delas apresentou os melhores resultados. Com isso, a partir da etapa de treinamento e teste, foi observado que o algoritmo *Random Forest* obteve os melhores resultados juntamente com a Base21 alcançando uma acurácia de 90,74% e AUC de 0,97.

Foi realizado o desenvolvimento de uma aplicação web, de modo que possibilitasse auxiliar o profissional da saúde a identificar pessoas propensas a terem um AVC. A mesma foi validada por meio de um teste de usabilidade que contou com a participação de 5 pessoas que trabalhavam e exerciam atividades na área da saúde. Como resultado dessa avaliação, a ferramenta proposta se mostrou bastante usual para o contexto da saúde, mesmo com pontos de melhoria necessários a serem realizados.

No entanto, dentre as limitações apresentadas é importante destacar que o conjunto de dados utilizado contém uma quantidade muito grande de valores faltosos, o que dificultou o processo de pré-processamento dos dados. A quantidade de atributos também influenciou, pois como continham informações não somente do AVC foi necessário realizar uma redução muito grande dos atributos. Além disso, foi enfrentado o desbalanceamento de dados, que embora tenham sido tratados, também pode ter influenciado nas etapas de treinamento e

teste.

Além disso, devido à base de dados fazer parte de um estudo muito maior, a documentação das atributos é muito extensa e de difícil entendimento, uma vez que a sua identificação estava limitada a fichas médicas e própria interpretação. Isso também contribuiu para a demora na finalização do pré-processamento e também na criação do modelo, visto a dificuldade em identificar a variável classificatória.

Outra limitação foi na disponibilização da ferramenta. Como a base de dados utilizada para teste, passou pelo Comitê de Ética e não tinha permissão para ser disponibilizada de forma pública, caso fosse realizada a disponibilização da ferramenta na web, esses dados também deveriam ser consumidos em nuvem e poderiam de alguma forma serem acessados. Mediante a isso, impossibilitou a disponibilização da ferramenta em todos os meios disponíveis.

Na realização do teste, também é possível identificar outra limitação, pois como não foi possível fazer a disponibilização, tornou-se necessário levar a máquina com a ferramenta até o local onde o participante estava para o que o mesmo conseguisse testar, deixando dependente de uma máquina a realização do teste. Além disso, com relação ao modelo, o mesmo ainda precisa de muitos aperfeiçoamentos, pois para alguns casos ainda está realizando predições erradas.

Como trabalhos futuros, pretende-se: i) aprimorar o pré-processamento da base a partir da utilização de outros métodos ou a partir da aquisição dos dados criar uma própria base de dados; ii) verificar a utilização de outros algoritmos e comitês de aprendizado; iii) disponibilizar a ferramenta para todos os meios disponíveis e iv) realizar melhorias na ferramenta, como: criar a opção de login e cadastro de um profissional da saúde, isso irá possibilitar o acompanhamento direto do paciente ao profissional da saúde que o atendeu. Adicionar o cadastro de paciente logo na página inicial, adicionar o número do SUS no cadastro do paciente. Inserir uma busca nas listagens, deixar as linhas das listagens clicáveis de modo a possibilitar a visualização das informações presentes. Realizar a substituição de alguns termos genéricos para termos mais técnicos que os profissionais da saúde já estão acostumados a utilizar. Além disso, também serão realizadas melhorias estéticas nos componentes da interface, possibilitando uma melhor experiência e uma interface mais agradável.

Referências

- AGNER, L. *Ergodesign e arquitetura de informação: trabalhando com o usuário*. [S.l.]: Quartet, 2009. Citado na página 41.
- ALI, M. *PyCaret: An open source, low-code machine learning library in Python*. [S.l.], 2020. PyCaret version 1.0. Disponível em: <<https://www.pycaret.org>>. Citado 4 vezes nas páginas 34, 35, 57 e 81.
- ALMEIDA, L. M. d. Da prevenção primordial à prevenção quaternária. *Revista Portuguesa de Saúde Pública*, Universidade Nova de Lisboa, Escola Nacional de Saúde Pública, v. 23, n. 1, p. 91–96, 2005. Citado na página 23.
- AUDY, J. L. N. *Desenvolvimento distribuído de software*. [S.l.]: Elsevier, 2007. Citado na página 74.
- AVC, A. B. *O que é AVC?* 2021. Disponível em: <<https://abavc.org.br/index.php/sobre-o-avc/>>. Citado na página 26.
- AZANK, F.; GURGEL, G. K. *Dados Desbalanceados — O que são e como lidar com eles*. 2020. <https://medium.com/turing-talks/dados-desbalanceados-o-que-o-que-sao-e-como-evita-los-43df4f49732b>. Citado na página 62.
- AZEVEDO, L. C. P. d. *et al. Medicina intensiva : abordagem prática*. [S.l.]: Barueri, SP : Manoler, 2013. Citado 3 vezes nas páginas 27, 28 e 29.
- BERNARDO, T. T. *et al. Hemorragia cerebral intraparenquimatosa em paciente com doença de christmas*. *Revista Científica da Faculdade de Medicina de Campos*, v. 12, n. 3, 2017. Citado na página 27.
- BIOLINCC, B. S. D. R. I. C. C. *Cardiovascular Health Study (CHS)*. 2019. Recuperado de: <<https://biolincc.nhlbi.nih.gov/studies/chs/>>. Citado 2 vezes nas páginas 58 e 59.
- BORGES, L. E. *Python para desenvolvedores: aborda Python 3.3*. [S.l.]: Novatec Editora, 2014. Citado na página 39.
- BRASIL, M. d. S. *Cadernos de atenção primária - rastreamento*. Secretaria de Atenção à Saúde, Departamento de Atenção Básica., 2010. Citado 2 vezes nas páginas 23 e 24.
- BRASIL, M. d. S. *Diretrizes de atenção à reabilitação da pessoa com acidente vascular cerebral*. Secretaria de Atenção à Saúde. Departamento de Ações Programáticas Estratégicas, 2013. Citado 4 vezes nas páginas 17, 18, 24 e 25.
- BVS, B. V. e. S. M. d. S. *AVC - Acidente Vascular Cerebral*. 2015. <https://bvsm.sau.gov.br/avc-acidente-vascular-cerebral/>. Elaborada em agosto de 2006 e revisada em dezembro de 2015. Citado 2 vezes nas páginas 17 e 25.
- CAMARGO, N. A. d. *Orientações multidisciplinares para pacientes pós AVC [recurso eletrônico]*. Botucatu: Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Medicina, 2019. Disponível em: <<https://avc.org.br/wp-content/uploads/2021/08/Manual-pos-AVC-UNESP.pdf>>. Citado na página 24.

- CAMPBELL, B. C. V.; KHATRI, P. Stroke. *The Lancet*, Elsevier BV, v. 396, n. 10244, p. 129–142, jul 2020. Disponível em: <[http://dx.doi.org/10.1016/S0140-6736\(20\)31179-X](http://dx.doi.org/10.1016/S0140-6736(20)31179-X)>. Citado na página 17.
- CARVALHO, V. P. *et al.* Perfil clínico-epidemiológico de pacientes com acidente vascular cerebral. *Revista Saúde e Desenvolvimento*, v. 13, n. 15, 2019. Citado na página 62.
- CASTRO, L. N. d.; FERRARI, D. G. *Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações*. [S.l.]: São Paulo: Saraiva, 2016. Citado na página 31.
- CHAWLA, N. V. *et al.* Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, v. 16, p. 321–357, 2002. Citado na página 62.
- CILUMBRIELLO, N. P. S. *et al.* Avaliação heurística e teste de usabilidade para software de design de interiores. *Revista Ibérica de Sistemas e Tecnologias de Informação*, Associação Ibérica de Sistemas e Tecnologias de Informacao, n. E17, p. 90–101, 2019. Citado na página 41.
- CZERESNIA, D.; FREITAS, C. M. D. *Promoção da saúde: conceitos, reflexões, tendências*. [S.l.]: SciELO-Editora FIOCRUZ, 2009. Citado na página 23.
- DATASCIENCE. *Melhores bibliotecas Python para aprendizagem de máquinas*. 2021. <https://datascience.eu/pt/programacao/melhores-bibliotecas-python-para-aprendizagem-de-maquinas/>. Citado na página 33.
- DRESCH, A.; LACERDA, D. P.; JÚNIOR, J. A. V. A. *Design science research: método de pesquisa para avanço da ciência e tecnologia*. [S.l.]: Bookman Editora, 2015. Citado 2 vezes nas páginas 21 e 42.
- EMON, M. U. *et al.* Performance analysis of machine learning approaches in stroke prediction. In: *2020 4th International Conference on Electronics, Communication and Aerospace Technology (ICECA)*. [S.l.: s.n.], 2020. p. 1464–1469. Citado 4 vezes nas páginas 46, 50, 52 e 53.
- FACELI, K. *et al.* *Inteligência Artificial—uma abordagem de aprendizado de máquina*. [S.l.: s.n.], 2021. Citado 7 vezes nas páginas 21, 31, 35, 36, 37, 56 e 58.
- FANG, G.; XU, P.; LIU, W. Automated ischemic stroke subtyping based on machine learning approach. *IEEE Access*, v. 8, p. 118426–118432, 2020. Citado 4 vezes nas páginas 46, 50, 52 e 53.
- FERRARI, D. G.; CASTRO, L. N. d. *Introdução a mineração de dados*. [S.l.]: Saraiva Educação SA, 2016. Citado 5 vezes nas páginas 21, 33, 36, 37 e 56.
- FOUNDATION, P. S. *Python*. 2023. Acessado em 05 de junho de 2023. Disponível em: <<https://www.python.org/>>. Citado na página 40.
- GARCÍA-TEMZA, L. *et al.* Comparison of different machine learning approaches to model stroke subtype classification and risk prediction. In: *2019 Spring Simulation Conference (SpringSim)*. [S.l.: s.n.], 2019. p. 1–10. Citado 4 vezes nas páginas 46, 49, 51 e 53.
- GÉRON, A. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. [S.l.]: Alta Books, 2019. Citado 3 vezes nas páginas 31, 32 e 36.

GUEDES, G. T. *UML 2-Uma abordagem prática*. [S.l.]: Novatec Editora, 2018. Citado na página 72.

HAKIM, M. A. *et al.* An efficient modified bagging method for early prediction of brain stroke. In: *2019 International Conference on Computer, Communication, Chemical, Materials and Electronic Engineering (IC4ME2)*. [S.l.: s.n.], 2019. p. 1–4. Citado 5 vezes nas páginas 29, 46, 49, 52 e 53.

HAYASHI, Y. *et al.* A prehospital diagnostic algorithm for strokes using machine learning: a prospective observational study. 2021. Citado 4 vezes nas páginas 46, 50, 52 e 53.

HEUSER, C. A. *Projeto de banco de dados: Volume 4 da Série Livros didáticos informática UFRGS*. [S.l.]: Bookman Editora, 2009. Citado 2 vezes nas páginas 72 e 73.

INDUJA, S.; RAJI, C. Computational methods for predicting chronic disease in healthcare communities. In: *2019 International Conference on Data Science and Communication (IconDSC)*. [S.l.: s.n.], 2019. p. 1–6. Citado 4 vezes nas páginas 46, 50, 52 e 53.

JASPERS, M. W. *et al.* The think aloud method: a guide to user interface design. *International journal of medical informatics*, Elsevier, v. 73, n. 11-12, p. 781–795, 2004. Citado na página 94.

JETBRAINS. *PyCharm Quick Start Guide*. 2023. Última modificação em 03 de maio de 2023. Disponível em: <<https://www.jetbrains.com/help/pycharm/quick-start-guide.html>>. Citado na página 40.

JUNIOR, G. B. V. *et al.* Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. *Revista CPAQV-Centro de Pesquisas Avançadas em Qualidade de Vida/ Vol*, v. 14, n. 2, p. 2, 2022. Citado 2 vezes nas páginas 37 e 38.

KAMEL, H. *et al.* Cardiac mechanics and incident ischemic stroke: the cardiovascular health study. *Scientific reports*, Nature Publishing Group UK London, v. 11, n. 1, p. 17358, 2021. Citado na página 58.

KAZMI, H. *et al.* Towards data-driven energy communities: A review of open-source datasets, models and tools. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 148, p. 111290, 2021. Citado na página 38.

KITCHENHAM, B. Procedures for performing systematic reviews. *Keele, UK, Keele University*, v. 33, n. 2004, p. 1–26, 2004. Citado na página 42.

KITCHENHAM, B.; CHARTERS, S. Guidelines for performing systematic literature reviews in software engineering. Citeseer, 2007. Citado na página 42.

MA, C. e. T. *Qual a diferença entre o AVC e AVE?* 2021. <https://cursorr10sp.net/qual-a-diferenca-entre-o-avc-e-ave/>. Citado na página 24.

MACHADO, L.; VERGARA, L.; FERREIRA, E. Métodos de avaliação de usabilidade: características e aplicações. *Anais [3º CONEPRO-SUL]*, 2014. Citado na página 41.

MATOS, D. Gradio vs streamlit vs dash vs flask – deploy de modelos de machine learning em python. fevereiro 2021. Disponível em: <<https://www.cienciaedados.com/gradio-vs-streamlit-vs-dash-vs-flask-deploy-de-modelos-de-machine-learning-em-python/>>. Citado na página 38.

- MESCHIA, J. F. *et al.* Guidelines for the primary prevention of stroke: a statement for healthcare professionals from the american heart association/american stroke association. *Stroke*, Am Heart Assoc, v. 45, n. 12, p. 3754–3832, 2014. Citado 2 vezes nas páginas 17 e 18.
- MICROSOFT. *Formatos de Arquivos com Suporte no Excel*. 2023. <<https://support.microsoft.com/pt-br/office/formatos-de-arquivos-com-suporte-no-excel-0943ff2c-6014-4e8d-aaea-b83d51d46247>>. Citado na página 74.
- MINHAVIDA. *AVC (derrame cerebral): sintomas, causas e sequelas*. 2021. Disponível em: <<https://www.minhavidade.com.br/saude/temas/avc>>. Citado 3 vezes nas páginas 26, 27 e 28.
- MIRANDA, M. *Acidente Vascular Cerebral*. 2023. <<https://avc.org.br/pacientes/acidente-vascular-cerebral/>>. Acesso em 15 de julho de 2023. Citado na página 18.
- MITCHELL, T. M. *Machine learning*. [S.l.]: Nova York: McGraw-Hill, 1997. Citado na página 31.
- NASCIMENTO, A. I. R. *et al.* Contribuições da tecnologia da informação e comunicação na saúde pública. Novas tecnologias aplicadas à saúde: desenvolvimento de sistemas dinâmicos: conceitos, aplicações e utilização de técnicas inteligentes e regulação, 2019. Citado na página 17.
- OLIPHANT, T. E. *et al.* *A guide to NumPy*. [S.l.]: Trelgol Publishing USA, 2006. v. 1. Citado na página 39.
- OLIVEIRA, J. *Design de Produto: Uma visão Product-Led sobre design de produtos digitais*. 2. ed. Florianópolis: Amazon Serviços de Varejo do Brasil Ltda, 2021. 200 p. ISBN 978-65-00-24175-4. Citado na página 41.
- OLIVEIRA, W. C. G. d. *et al.* Sistema multiagente fuzzy para monitoramento e avaliação. Novas tecnologias aplicadas à saúde: desenvolvimento de sistemas dinâmicos: conceitos, aplicações e utilização de técnicas inteligentes e regulação, 2019. Citado 2 vezes nas páginas 18 e 29.
- PAL, S. K.; MITRA, P. *Pattern recognition algorithms for data mining*. [S.l.]: CRC press, 2004. Citado na página 57.
- PANDIAN, J. D. *et al.* Prevention of stroke: a global perspective. *The Lancet*, Elsevier, v. 392, n. 10154, p. 1269–1278, 2018. Citado na página 18.
- PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado 3 vezes nas páginas 35, 57 e 63.
- PostgreSQL. *PostgreSQL: The World's Most Advanced Open Source Relational Database*. 2023. <<https://www.postgresql.org/>>. Citado na página 40.
- PRESSMAN, R.; MAXIM, B. *Engenharia de Software-8ª Edição*. [S.l.]: McGraw Hill Brasil, 2016. Citado na página 22.
- PYTHON. *Python Documentation*. 2023. <<https://docs.python.org/>>. Accessed on 2023-05-29. Citado na página 39.

- QUILICI-GONZALEZ, J. A.; ZAMPIROLI, F. de A. *Sistemas inteligentes e mineração de dados*. [S.l.]: Santo André: Triunfal Gráfica e Editora, 2014. Citado 2 vezes nas páginas 17 e 29.
- RAMAKRISHNAN, R.; GEHRKE, J. *Sistemas de gerenciamento de banco de dados-3*. [S.l.]: AMGH Editora, 2008. Citado na página 40.
- REZENDE, S. O. *Sistemas inteligentes: fundamentos e aplicações*. [S.l.]: Editora Manole Ltda, 2005. Citado 2 vezes nas páginas 29 e 30.
- RUSSELL, S. J.; NORVIG, P. *Inteligência artificial. Tradução Regina Célia Simille*. [S.l.]: Elsevier, 2013. Citado 4 vezes nas páginas 30, 31, 32 e 33.
- SANTANA, R. *Lidando com Classes Desbalanceadas – Machine Learning*. 2020. <https://minerandodados.com.br/lidando-com-classes-desbalanceadas-machine-learning/>. Citado na página 62.
- SARANGPURE, N. *et al.* Automating the machine learning process using pycaret and streamlit. In: IEEE. *2023 2nd International Conference for Innovation in Technology (INOCON)*. [S.l.], 2023. p. 1–5. Citado na página 34.
- SENGUPTA, A. *Advances in multivariate statistical methods*. [S.l.]: World scientific, 2009. v. 4. Citado na página 38.
- SHOILY, T. I. *et al.* Detection of stroke disease using machine learning algorithms. In: *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. [S.l.: s.n.], 2019. p. 1–6. Citado 4 vezes nas páginas 46, 50, 52 e 53.
- SILVA, M. A. F. *STROKE.IA - Uma ferramenta para auxílio na classificação de pacientes em relação ao AVC*. [S.l.], 2023. Disponível em: <<https://github.com/adriana12/STROKE.IA.git>>. Citado 2 vezes nas páginas 58 e 74.
- SINGH, M. S.; CHOUDHARY, P. Stroke prediction using artificial intelligence. In: *2017 8th Annual Industrial Automation and Electromechanical Engineering Conference (IEMECON)*. [S.l.: s.n.], 2017. p. 158–161. Citado 6 vezes nas páginas 46, 50, 52, 53, 98 e 99.
- SOMMERVILLE, I. *Engenharia de Software. ed. 9ª, ISBN 9788579361081*. [S.l.]: São Paulo, Pearson, 2011. Citado 2 vezes nas páginas 22 e 70.
- STREAMLIT. *Streamlit: The fastest way to build custom ML tools*. 2021. <<https://www.streamlit.io/>>. Citado na página 38.
- TALEB, A. R. A. *et al.* Application of data mining techniques to predict length of stay of stroke patients. In: *2017 International Conference on Informatics, Health Technology (ICIHT)*. [S.l.: s.n.], 2017. p. 1–5. Citado na página 18.
- TURSYNOVA, A. *et al.* Artificial intelligence in stroke imaging. In: *2021 11th International Conference on Cloud Computing, Data Science Engineering (Confluence)*. [S.l.: s.n.], 2021. p. 41–45. Citado na página 18.
- VAZQUEZ, C. E.; SIMÕES, G. S. *Engenharia de Requisitos: software orientado ao negócio*. [S.l.]: Brasport, 2016. GS Search. Citado na página 70.

- VIERA, A. J.; GARRETT, J. M. *et al.* Understanding interobserver agreement: the kappa statistic. *Fam med*, v. 37, n. 5, p. 360–363, 2005. Citado na página 37.
- WHO, W. H. O. *Milestones in health promotion: Statements from global conferences*. 2009. Citado na página 23.
- WHO, W. H. O. *The top 10 causes of death*. 2020. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>>. Citado 2 vezes nas páginas 25 e 26.
- WIERINGA, R. J. *Design Science Methodology for Information Systems and Software Engineering*. 1. ed. [S.l.]: Springer-Verlag Berlin Heidelberg, 2014. Citado na página 19.
- YU, J. *et al.* Semantic analysis of nih stroke scale using machine learning techniques. In: *2019 International Conference on Platform Technology and Service (PlatCon)*. [S.l.: s.n.], 2019. p. 1–5. Citado 4 vezes nas páginas 46, 50, 52 e 53.
- YU, J. *et al.* Ai-based stroke disease prediction system using real-time electromyography signals. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 10, n. 19, p. 6791, 2020. Citado na página 18.

APÊNDICE A – Descrição dos atributos da base

Data Set Name: base1final.sas7bdat

Num	Variable	Type	Len	Label
1	IDNO	Num	6	PARTICIPANT ID NUMBER
2	GEND01	Num	3	GENDER
3	MARIT01	Num	3	MARITAL STATUS
4	OCCUP01	Num	3	LIFE OCCUPATION
5	CUROC01	Num	3	CURRENT OCCUPATION
6	INCOME01	Num	3	INCOME GROUP
7	HEALT01	Num	3	GENERAL HEALTH
8	RLHLTH01	Num	3	HEALTH COMPARED TO OTHERS
9	BED01	Num	3	BED DAYS IN LAST 2 WEEKS
10	LUNG01	Num	3	LUNG DISEASE,EMPHYSEMA,OR BRONCHITIS
11	NERV01	Num	3	NERVOUS OR EMOTIONAL DISORDER
12	HIBP01	Num	3	HIGH BLOOD PRESSURE
13	HEAR01	Num	3	HEARING PROBLEMS
14	VISION01	Num	3	VISION PROBLEMS
15	KIDNEY01	Num	3	KIDNEY DISEASE
16	HEART01	Num	3	HEART DISEASE
17	DIAB01	Num	3	DIABETES
18	ARTH01	Num	3	ARTHRITIS
19	STROKE01	Num	3	STROKE
20	DIAG01	Num	3	EVER DIAGNOSED WITH CANCER
21	SMOKE101	Num	3	SMOKED IN LIFETIME
22	SMOKE201	Num	3	SMOKED CIGARETTES LAST 30 DAYS
23	MILE01	Num	3	WALK A 1/2 MILE W/O DIFFICULTY
24	STEPS01	Num	3	WALK UP 10 STEPS W/O DIFFICULTY
25	BED101	Num	3	GET OUT OF BED/CHAIR
26	HOME01	Num	3	WALK AROUND YOUR HOME
27	FEEL03	Num	3	HOW DO YOU FEEL ABOUT LIFE AS A WHOLE
28	SATISF03	Num	3	HOW SATISFIED WITH PURPOSE OF LIFE
29	LONELY03	Num	3	WHEN LONELY,THERE ARE PEOPLE CAN TALK TO
30	TALK03	Num	3	I OFTEN MEET/TALK WITH FAMILY OR FRIENDS
31	SICK03	Num	3	IF SICK,CAN FIND SB. HELP W/ DAILY CHORE
32	PROBS03	Num	3	KNOW SB. CAN TURN TO W/ PERSONAL PROBLEM
33	TRUST03	Num	3	TRUST AT LEAST ONE PERSON'S ADVICE
34	HOUSE03	Num	3	HARD TO FIND SB CARE HOUSE WHEN OUT TOWN
35	SCORE03	Num	8	SOCIAL SUPPORT SCORE
36	RELATI03	Num	3	SEE HOW MANY RELATIVES ONCE A MONTH

Num	Variable	Type	Len	Label
37	BETRLT03	Num	3	HOW OFTEN SEE RELATIVE WITH MOST CONTACT
38	CLOSE03	Num	3	HOW MANY RELATIVES DO YOU FEEL CLOSE TO
39	CLSFRD03	Num	3	HOW MANY CLOSE FRIENDS DO YOU HAVE
40	SEEFR103	Num	3	HOW MANY OF THESE YOU SEE ONCE A MONTH
41	SEEFR203	Num	3	HOW OFTEN SEE FRIEND WITH MOST CONTACT
42	DCSN303	Num	3	HAVE SB CAN TALK TO ABOUT IMPORT. DECIS
43	DCSN203	Num	3	PEOPLE TALK TO YOU ABOUT IMPORT.DECISION
44	RELYON03	Num	3	SB RELY ON YOU DO STH FOR THEM EACH DAY
45	HLPSHP03	Num	3	HELP SB WITH THINGS LIKE SHOPPING,ETC.
46	LIVE03	Num	3	DO YOU LIVE ALONE OR WITH OTHER PEOPLE
47	NETSCR03	Num	8	SOCIAL NETWORK SCORE
48	WALK04	Num	3	WALKING FOR EXERCISE IN LAST 2 WEEKS
49	WALKFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - WALK
50	WALKTM04	Num	4	TIME(MIN.) - WALK
51	WALKMO04	Num	3	MONTHS PER YEAR - WALK
52	CHOR04	Num	3	MODERNATELY STRENUOUS HOUSEHOLD CHORES
53	CHORFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - CHORE
54	CHORTM04	Num	4	TIME(MIN.) - CHORE
55	CHORMO04	Num	3	MONTHS PER YEAR - CHORE
56	MOW04	Num	3	MOWING LAWN IN PAST 2 WEEKS
57	MOWFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - MOW
58	MOWTM04	Num	4	TIME(MIN.) - MOW
59	MOWMO04	Num	3	MONTHS PER YEAR - MOW
60	RAKE04	Num	3	RAKING LAWN IN PAST 2 WEEKS
61	RAKEFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - RAKE LAWN
62	RAKETM04	Num	4	TIME(MIN.) - RAKE LAWN
63	RAKEMO04	Num	3	MONTHS PER YEAR - RAKE LAWN
64	GRDN04	Num	3	GARDENING IN PAST 2 WEEKS
65	GRDNFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - GARDEN
66	GRDNTM04	Num	4	TIME(MIN.) - GARDEN
67	GRDNMO04	Num	3	MONTHS PER YEAR - GARDEN
68	HIKE04	Num	3	HIKING IN PAST 2 WEEKS
69	HIKEFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - HIKING
70	HIKETM04	Num	4	TIME(MIN.) - HIKING
71	HIKEMO04	Num	3	MONTHS PER YEAR - HIKING
72	BIKE04	Num	3	BIKING IN PAST 2 WEEKS
73	BIKEFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - BIKING
74	BIKETM04	Num	4	TIME(MIN.) - BIKING
75	BIKEMO04	Num	3	MONTHS PER YEAR - BIKING

Num	Variable	Type	Len	Label
76	EXCY04	Num	3	EXERCISE CYCLE IN PAST 2 WEEKS
77	EXCYFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - EXER CYCLE
78	EXCYTM04	Num	4	TIME(MIN.) - EXER CYCLE
79	EXCYMO04	Num	3	MONTHS PER YEAR - EXER CYCLE
80	DANC04	Num	3	DANCING IN PAST 2 WEEKS
81	DANCFR04	Num	3	FREQUENCY IN PAST 2 WEEKS -DANCING
82	DANCTM04	Num	4	TIME(MIN.) -DANCING
83	DANCMO04	Num	3	MONTHS PER YEAR - DANCING
84	AERO04	Num	3	AEROBICS/AEROBIC DANCE IN PAST 2 WEEKS
85	AEROFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - AEROBICS
86	AEROTM04	Num	3	TIME(MIN.) - AEROBICS
87	AEROMO04	Num	3	MONTHS PER YEAR - AEROBICS
88	BOWL04	Num	3	BOWLING IN PAST TWO WEEKS
89	BOWLFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - BOWLING
90	BOWLTM04	Num	4	TIME(MIN.) - BOWLING
91	BOWLMO04	Num	3	MONTHS PER YEAR - BOWLING
92	GOLF04	Num	3	GOLF IN PAST TWO WEEKS
93	GOLFFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - GOLF
94	GOLFTM04	Num	4	TIME(MIN.) - GOLF
95	GOLFMO04	Num	3	MONTHS PER YEAR - GOLF
96	EXER04	Num	3	CALISTHENICS/GEN EXERCISE IN LAST 2 WEEK
97	EXERFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - CALISTHENICS
98	EXERTM04	Num	4	TIME(MIN.) - CALISTHENICS
99	EXERMO04	Num	3	MONTHS PER YEAR - CALISTHENICS
100	SWIM04	Num	3	SWIMMING IN PAST TWO WEEKS
101	SWIMFR04	Num	3	FREQUENCY IN PAST 2 WEEKS - SWIMMING
102	SWIMTM04	Num	4	TIME(MIN.) - SWIMMING
103	SWIMMO04	Num	3	MONTHS PER YEAR - SWIMMING
104	OTH104	Num	3	OTHER ACTIVITY(1)
105	OTH1FR04	Num	3	FREQUENCY IN PAST 2 WEEKS - OTHER (1)
106	OTH1TM04	Num	4	TIME(MIN.) - OTHER (1)
107	OTH1MO04	Num	3	MONTHS PER YEAR - OTHER (1)
108	OTH204	Num	3	OTHER ACTIVITY(2)
109	OTH2FR04	Num	3	FREQUENCY IN PAST 2 WEEKS - OTHER (2)
110	OTH2TM04	Num	4	TIME(MIN.) - OTHER (2)
111	OTH2MO04	Num	3	MONTHS PER YEAR - OTHER (2)
112	BLOCK04	Num	4	BLOCKS WALKED LAST WEEK
113	PACE04	Num	3	USUAL PACE TO WALK OUTSIDE HOME
114	FLIGHT04	Num	4	FLIGHTS UP STAIRS IN PAST WEEK

Num	Variable	Type	Len	Label
115	SEAT04	Num	3	HRS SPENT EACH DAY SEATED OR LYING DOWN
116	ACTIV104	Num	3	PHYSICAL ACTIVITY LEVEL BEFORE 65
117	ACTIV204	Num	3	PHYSICAL ACTIVITY LEVEL AFTER 65
118	WLKCHN04	Num	3	HAS WALKING BRISKLY CHANGED
119	GDNCHN04	Num	3	HAS GARDENING CHANGED
120	CHRCHN04	Num	3	HAS HOUSEHOLD CHORES CHANGED
121	CHN104	Num	3	HAS OTHER ACT (1) CHANGED
122	CHN204	Num	3	HAS OTHER ACT (2) CHANGED
123	CHN304	Num	3	HAS OTHER ACT (3) CHANGED
124	CHN404	Num	3	HAS OTHER ACT (4) CHANGED
125	DIE05	Num	3	SOMEONE CLOSE TO YOU DIE IN LAST 6 MONTH
126	ILL05	Num	3	SB. CLOSE TO YOU HAD ILLNESS LAST 6 MON.
127	WORSE05	Num	3	IMPORTANT RELATIONSHIP BECOME SIG. WORSE
128	FINANC05	Num	3	SIG. FINANCES CHANGE IN LAST 6 MONTHS
129	FNNCIN05	Num	3	WAS THE FINANCES CHANGE POSITIVE OR NEG.
130	ROB05	Num	3	BEEN ASSAULTED OR ROBBED LAST 6 MONTHS
131	SICK05	Num	3	HAVE YOU BEEN CARING FOR A SICK/DISABLED
132	JOB05	Num	3	HAVE YOU LOST /CHANGED JOBS LAST 6 MONTH
133	BORN05	Num	3	HAVE YOU HAD A GRANDCHILD BORN LAST 6 MO
134	HAPPEN05	Num	3	OTHER SIGNIFICANT EVENT
135	HPNIN05	Num	3	WAS IT POSITIVE OR NEGATIVE
136	RETIRE05	Num	3	WAS IT DUE TO RETIREMENT
137	BOTHER05	Num	3	BOTHERED BY THINGS THAT USUALLY DON'T
138	TROUBL05	Num	3	TROUBLE KEEPING MIND ON WHAT WAS DOING
139	EFFORT05	Num	3	FELT EVERYTHING DONE WAS EFFORT
140	DEPRES05	Num	3	FELT DEPRESSED
141	FUTURE05	Num	3	FELT HOPEFUL ABOUT FUTURE
142	FEAR05	Num	3	FELT FEARFUL
143	SLEEP05	Num	3	SLEEP RESTLESS
144	HAPPY05	Num	3	HAPPY
145	LONLY05	Num	3	FELT LONELY
146	GETGO05	Num	3	COULD NOT GET GOING
147	DEPSCR05	Num	8	DEPRESSION SCALE TOTAL
148	LESCR05	Num	3	LIFE EVENTS SCORE
149	MI07	Num	3	MYOCARDIAL INFARCTION OR HEART ATTACK
150	MIHOSP07	Num	3	BEEN HOSPITALIZED FOR MI
151	HRTFLR07	Num	3	CONGESTIVE HEART FAILURE
152	CHFHS07	Num	3	BEEN HOSPITALIZED FOR CHF
153	CLAUD07	Num	3	HISTORY OF INTERMITTENT CLAUDICATION

Num	Variable	Type	Len	Label
154	CLHSP07	Num	3	BEEN HOSPITALIZED FOR CLAUDICATION
155	ANGINA07	Num	3	ANGINA
156	ANGHSP07	Num	3	BEEN HOSPITALIZED FOR ANGINA
157	BP07	Num	3	HIGH BLOOD PRESSURE
158	VALVE07	Num	3	RHEUMATIC HEART OR HEART VALVE PROBLEMS
159	DIABET07	Num	3	DIABETES
160	ATRFIB07	Num	3	ATRIAL FIBRILLATION
161	CLTLEG07	Num	3	DEEP VENOUS THROMBOSIS/BLOOD CLOT IN LEG
162	CLTLUN07	Num	3	PULMONARY EMBOLUS/BLOOD CLOTS IN LUNGS
163	CURCUL22	Num	3	OTHER HEART OR CIRCULATION PROBLEMS
164	BPSSUR07	Num	3	CORONARY BYPASS SURGERY
165	CAROTI07	Num	3	CAROTID ENDARTERECTOMY
166	SITE07	Num	3	SITE OF CAROTID ENDARTERECTOMY
167	ABTLEG07	Num	3	BYPASS PROCEDURE ON THE ARTERIES OF LEGS
168	ANEURY07	Num	3	A REPAIR OF AN AORTIC ANEURYSM
169	CORART07	Num	3	AN ANGIOPLASTY OF THE CORONARY ARTER(IES
170	EXTART07	Num	3	ANGIOPLASTY OF LOWER EXTREMITY ARTERIES
171	CHSTPN07	Num	3	EVER HAD PAIN/DISCOMFORT IN YOUR CHEST
172	HURRY07	Num	3	DO YOU GET IT WHEN YOU WALK UPHILL/HURRY
173	ORDPAC07	Num	3	GET WHEN WALK AT ORDINARY PACE ON LEVEL
174	TODO07	Num	3	WHAT DO YOU DO IF GET IT WHILE WALKING
175	STDSTL07	Num	3	IF YOU STAND STILL,WHAT HAPPENS TO IT
176	SOON07	Num	3	HOW SOON IS IT RELIEVED
177	STERNU07	Num	3	PAIN IN STERNUM(UPPER OR MIDDLE)
178	STERNL07	Num	3	PAIN IN STERNUM(LOWER)
179	CHEST07	Num	3	PAIN IN LEFT ANTERIOR CHEST
180	ARM07	Num	3	PAIN IN LEFT ARM
181	OTHER07	Num	3	PAIN IN OTHER PLACE
182	CHTPN07	Num	3	SEVERE PAIN ACROSS THE FRONT OF CHEST
183	CHTDRO7	Num	3	DID YOU SEE DOCTOR BECAUSE OF THIS PAIN
184	CHTDRS	Num	3	IF YES, WHAT DID YOUR DOCTOR SAY IT WAS
185	PILLOW07	Num	3	SLEEP ON 2/MORE PILLOWS TO HELP BREATHE
186	AWAKEN07	Num	3	AWAKENED AT NIGHT BY TROUBLE BREATHING
187	SWELL07	Num	3	SWELLING OF YOUR FEET OR ANKLES
188	CMDAY07	Num	3	COME ON DURING THE DAY AND GO DOWN NIGHT
189	LEGWLK07	Num	3	DO YOU GET PAIN IN EITHER LEG ON WALKING
190	SIT07	Num	3	BEGIN WHEN YOU ARE STANDING STILL/SIT
191	CALF07	Num	3	DO YOU GET THIS PAIN IN YOUR CALF/CALVES
192	WLKHRY07	Num	3	DO YOU GET IT IF YOUR WALK UPHILL/HURRY

Num	Variable	Type	Len	Label
193	LEGPC07	Num	3	GET IF WALK AT ORDINARY PACE ON LEVEL
194	LGDIS07	Num	3	EVER DISAPPEAR WHILE YOU ARE WALKING
195	LEGDO07	Num	3	WHAT DO YOU DO IF GET IT WHILE WALKING
196	LEGSTD07	Num	3	IF YOU STAND STILL,WHAT HAPPENS TO IT
197	LEGSN07	Num	3	HOW SOON
198	LEGHSP07	Num	3	HOSPITALIZED FOR THIS PROBLEM IN LEGS
199	BRN07	Num	3	ATTACKS OF BRONCHITIS
200	BRNDR07	Num	3	WAS IT CONFIRMED BY A DOCTOR
201	BRNT07	Num	3	AT WHAT AGE WAS YOUR FIRST ATTACK
202	CRNC07	Num	3	CHRONIC BRONCHITIS
203	BRNCHV07	Num	3	DO YOU STILL HAVE IT
204	BRNCDR07	Num	3	WAS IT CONFIRMED BY A DOCTOR
205	BRNCT07	Num	3	AT WHAT AGE DID IT START
206	PNE07	Num	3	PNEUMONIA
207	PNEDR07	Num	3	WAS IT CONFIRMED BY A DOCTOR
208	PNET07	Num	3	AT WHAT AGE WAS YOUR FIRST ATTACK
209	HAY07	Num	3	HAY FEVER
210	HAYDR07	Num	3	WAS IT CONFIRMED BY A DOCTOR
211	HAYT07	Num	3	AT WHAT AGE DID IT START
212	EPH07	Num	3	EMPHYSEMA
213	EPHH07	Num	3	DO YOU STILL HAVE IT
214	EPHDR07	Num	3	WAS IT CONFIRMED BY A DOCTOR
215	EPHT07	Num	3	AT WHAT AGE WAS YOUR FIRST ATTACK
216	ATH07	Num	3	ASTHMA
217	ATHH07	Num	3	DO YOU STILL HAVE IT
218	ATHDR07	Num	3	WAS IT CONFIRMED BY A DOCTOR
219	ATHT07	Num	3	AT WHAT AGE DID IT START
220	ATHST07	Num	3	AT WHAT AGE DID IT STOP
221	ILL07	Num	3	ANY OTHER CHEST ILLNESS
222	OPT07	Num	3	ANY CHEST OPERATIONS
223	INJ07	Num	3	ANY CHEST INJURIES
224	COUGH07	Num	3	DO YOU USUSLLY HAVE A COUGH
225	COUGHN07	Num	3	COUGH AS MUCH AS 4 TO 6 TIMES A DAY
226	CHGGET07	Num	3	COUGH ON GETTING UP/FIRST THING IN MORN.
227	CGHDAY07	Num	3	COUGH DURING THE REST OF THE DAY/NIGHT
228	CGHMON07	Num	3	COUGH ON MOST DAYS FOR 3 MONTHS
229	CGHYR07	Num	3	FOR HOW MANY YRS HAVE YOU HAD THIS COUGH
230	PHL07	Num	3	BRING UP PHLEGM FROM YOUR CHEST
231	PHLN07	Num	3	BRING UP TWICE A DAY,4/MORE DAYS A WEEK

Num	Variable	Type	Len	Label
232	PHLG07	Num	3	BRING UP ON GETTING UP
233	PHLR07	Num	3	BRING UP DURING THE REST OF DAY/AT NIGHT
234	PHLF07	Num	3	BRING UP ON MOST DAYS FOR 3 MONTHS
235	PHLL07	Num	3	HOW MANY YEARS YOU HAVE TROUBLE WITH IT
236	WZYD07	Num	3	CHEST SOUND WHEEZY/WHISTLING HAVING COLD
237	WZYA07	Num	3	CHEST SOUND WHEEZY/WHISTLING AFTER COLDS
238	WZYDN07	Num	3	WHEEZY/WHISTLING MOST DAYS OR NIGHTS
239	WZYL07	Num	3	FOR HOW MANY YEARS HAS THIS BEEN PRESENT
240	WZYBR07	Num	3	WHEEZING MADE YOU SHORT OF BREATH
241	WZYAT07	Num	3	HOW OLD WERE YOU WHEN HAD FIRST ATTACK
242	WZYAF07	Num	3	HAVE YOU HAD 2 OR MORE SUCH EPISODES
243	WZYAM07	Num	3	REQUIRED MEDICINE/TREATMENT FOR ATTACKS
244	BRTSHT07	Num	3	SHORT OF BREATH WHEN HURRY ON THE LEVEL
245	BRTWLK07	Num	3	WALK SLOWER THAN PEOPLE OF YOUR AGE
246	BRTSTP07	Num	3	STOP FOR BREATH WHEN WALKING AT OWN PACE
247	BRTHRD07	Num	3	STOP FOR BREATH AFTER WALKING 100 YARDS
248	BRTDRS07	Num	3	TOO BREATHLESS TO LEAVE THE HOUSE
249	B RTP07	Num	3	PRESENT BREATHLESS/SHORT OF BREATH
250	BRTI07	Num	3	INCREASE IN BREATHLESS/SHORT OF BREATH
251	PALPIP07	Num	3	PRESENT PALPITATIONS
252	PALPII07	Num	3	INCREASE IN PALPITATIONS
253	DIZZYP07	Num	3	PRESENT DIZZINESS
254	DIZZYI07	Num	3	INCREASE IN DIZZINESS
255	FATIGP07	Num	3	PRESENT FATIGUE
256	FATIGI07	Num	3	INCREASE IN FATIGUE
257	WEAKP07	Num	3	PRESNET WEAKNESS
258	WEAKI07	Num	3	INCREASE IN WEAKNESS
259	NAUSEP07	Num	3	PRESENT NAUSEA
260	NAUSEI07	Num	3	INCREASE IN NAUSEA
261	INDIGP07	Num	3	PRESENT INDIGESTION
262	INDIGI07	Num	3	INCREASE IN INDIGESTION
263	CHESTP07	Num	3	PRESENT CHEST PAIN
264	CHESTI07	Num	3	INCREASE CHEST PAIN
265	ABDOMP07	Num	3	PRESENT UPPER ABDOMINAL PAIN
266	ABDOMI07	Num	3	INCREASE IN UPPER ABDOMINAL PAIN
267	FEVERP07	Num	3	PRESENT FEVER
268	FEVERI07	Num	3	INCREASE IN FEVER
269	ACHESP07	Num	3	PRESENT MUSCLE ACHES
270	ACHESI07	Num	3	INCREASE IN MUSCLE ACHES

Num	Variable	Type	Len	Label
271	DIARRP07	Num	3	PRESENT DIARRHEA
272	DIARRI07	Num	3	INCREASE IN DIARRHEA
273	SEEDR07	Num	3	H'YOU SEEN A DOCTOR IN THE LAST 2 WEEKS
274	WEIGHT08	Num	3	GAINED/LOST MORE THAN 10 LBS LAST YEAR
275	DIET08	Num	3	WAS DIET A MAJOR FACTOR
276	ILL08	Num	3	WAS SURGERY/ILLNESS/MEDIC A MAJOR FACTOR
277	EXER08	Num	3	WAS EXERCISE A MAJOR FACTOR
278	WGTEEN08	Num	3	IN EARLY TEENS, HEAVIER THAN AVERAGE
279	SMOKE08	Num	3	EVER SMOKED MORE THAN 100 CIGARETTES
280	SMK3008	Num	3	HAVE YOU SMOKED IN LAST 30 DAYS
281	SMKAGE08	Num	3	HOW OLD WHEN YOU STARTED TO SMOKE
282	STOP08	Num	3	HOW OLD WERE WHEN YOU STOPPED SMOKING
283	AMOUNT08	Num	4	HOW MANY DID YOU SMOKE PER DAY ON AVER.
284	ANYONE08	Num	3	DOES ANYONE LIVING WITH YOU SMOKE
285	SLEEP08	Num	3	ARE YOU SLEEPY IN THE DAYTIME
286	GROGGY08	Num	3	DO YOU FEEL GROGGY IN THE MORNING
287	SNORE08	Num	3	HAS ANYONE COMPLAINED ABOUT YOUR SNORING
288	BREATH08	Num	3	IN SLEEP,STOP BREATH A WHILE THEN SNORE
289	TRBLSL08	Num	3	DO YOU HAVE TROUBLE FALLING ASLEEP
290	WAKEUP08	Num	3	DO YOU WAKE UP SERVERAL TIMES AT NIGHT
291	STAYSL08	Num	3	DO YOU USUALLY WAKE UP FAR TOO EARLY
292	DRIVE08	Num	3	CAN YOU SEE WELL ENOUGH TO DRIVE
293	TV08	Num	3	CAN YOU SEE WELL ENOUGH TO WATCH TV
294	RECOGN08	Num	3	CAN YOU SEE WELL ENOUGH TO RECOGNIZE
295	READ08	Num	3	CAN YOU SEE WELL ENOUGH TO READ NEWSPAPE
296	TELE08	Num	3	CAN YOU HEAR WELL ENOUGH TO USE TELEPHON
297	RADIO08	Num	3	HEAR WELL ENOUGH TO LISTEN TO RADIO
298	CONVER08	Num	3	HEAR WELL ENOUGH TO CARRY CONVERSATION
299	MENOPS08	Num	3	HOW OLD WERE YOU AT YOUR MENOPAUSE
300	HYSTR08	Num	3	HAVE YOU EVER HAD A HYSTERECTOMKY
301	SURGER08	Num	3	HOW OLD WERE YOU WHEN YOU HAD THE SURGER
302	OVARY08	Num	3	HAVE YOU EVER HAD A OVARY REMOVED
303	NOVARY08	Num	3	HOW MANY OVARIES WERE REMOVED
304	AGEOVA08	Num	3	AT WHAT AGE DID YOU HAVE THIS DONE
305	PREMAR08	Num	3	HAVE YOU EVER TAKEN PREMARIN
306	STRPRM08	Num	3	AT WHAT AGE DID YOU START
307	STPPRM08	Num	3	AT WHAT AGE DID YOU STOP
308	ESTROG08	Num	3	HAVE YOU EVER TAKEN OTHER ESTROGENS
309	WHMILE09	Num	3	DO YOU HAVE DIFFICULTY WALKING 1/2 MILE

Num	Variable	Type	Len	Label
310	WHMDIF09	Num	3	HOW MUCH DIFFICULTY DO YOU HAVE
311	WHMTIM09	Num	3	FOR HOW LONG HAVE YOU HAD DIFFICULTY
312	WHODIF09	Num	3	HOW MUCH DIFFICULTY DO YOU HAVE
313	WHOTIM09	Num	3	FOR HOW LONG HAVE YOU HAD DIFFICULTY
314	BEDDIF09	Num	3	HOW MUCH DIFFICULTY DO YOU HAVE
315	BEDTIM09	Num	3	FOR HOW LONG HAVE YOU HAD DIFFICULTY
316	STEPS09	Num	3	HAVE DIFFICULTY WALKING UP 10 STEPS
317	STPDIF09	Num	3	HOW MUCH DIFFICULTY DO YOU HAVE
318	STPTIM09	Num	3	FOR HOW LONG HAVE YOU HAD DIFFICULTY
319	LIFTNG09	Num	3	HAVE DIFFICULTY LIFTING
320	LFTDIF09	Num	3	HOW MUCH DIFFICULTY DO YOU HAVE
321	LFTTIM09	Num	3	FOR HOW LONG HAVE YOU HAD DIFFICULTY
322	LFTEXT09	Num	3	WHICH EXTREMITY CAUSES THE DIFFCULTY
323	REACH09	Num	3	HAVE DIFFICULTY REACHING OUT
324	RCHDIF09	Num	3	HOW MUCH DIFFICULTY DO YOU HAVE
325	RCHTIM09	Num	3	FOR HOW LONG HAVE YOU HAD DIFFICULTY
326	RCHEXT09	Num	3	WHICH EXTREMITY CAUSES THE DIFFCULTY
327	GRIPNG09	Num	3	HAVE DIFFICULTY GRIPPING WITH HANDS
328	GRPDIF09	Num	3	HOW MUCH DIFFICULTY DO YOU HAVE
329	GRPTIM09	Num	3	FOR HOW LONG HAVE YOU HAD DIFFICULTY
330	GRPEXT09	Num	3	WHICH EXTREMITY CAUSES THE DIFFCULTY
331	BMEDIN11	Num	3	PILLS OR INHALERS FOR BREATHING PROBS.
332	BETA11	Num	3	BETA BLOCKER PILL FOR HIGH BLOOD PRESS.
333	SMKHR11	Num	3	SMOKE DURING THE PAST HOUR
334	CAFFHR11	Num	3	CAFFEINE DRINK DURING PAST 4 HOURS
335	RSPINF11	Num	3	RESPIRATORY INFECTION IN PAST 3 WEEKS
336	BLEED12	Num	3	BLEED OR BRUISE EASILY
337	CLOT12	Num	3	DISORDER RELATED TO BLOOD CLOTTING
338	FAINT12	Num	3	FAINTING SPELLS WHILE HAVING BLOOD DRAWN
339	DIABET12	Num	3	DIABETES
340	INSUL12	Num	3	TAKE INSULIN
341	FAST12	Num	3	FASTING
342	GLUC12	Num	3	GLUCOSE TOLERANCE TEST INDICATOR
343	CUFF14	Num	3	CUFF SIZE
344	PSYSTO14	Num	4	PALPATED SYSTOLIC
345	ZERO14	Num	3	MAXIMUM ZERO LEVEL
346	INFLAT14	Num	4	MAXIMUM INFLATION LEVEL
347	BEAT14	Num	3	HEART RATE (30 SECONDS)
348	SYS114	Num	4	FIRST SYSTOLIC READING

Num	Variable	Type	Len	Label
349	DIA114	Num	4	FIRST DIASTOLIC READING
350	SYS0114	Num	3	ZERO LEVEL
351	SYSC114	Num	4	CORRECTED FIRST SYSTOLIC READING
352	DIAC114	Num	4	CORRECTED FIRST DIASTOLIC READING
353	SYS214	Num	4	SECOND SYSTOLIC READING
354	DIA214	Num	4	SECOND DIASTOLIC READING
355	SYS0214	Num	3	ZERO LEVEL
356	SYSC214	Num	4	CORRECTED SECOND SYSTOLIC READING
357	DIAC214	Num	4	CORRECTED SECOND DIASTOLIC READING
358	PALP15	Num	4	PALPATED SYSTOLIC BLOOD PRESSURE
359	MAXINF15	Num	4	MAXIMAL INFLATION LEVEL
360	BRACH115	Num	4	BRACHIAL BLOOD PRESSURE FIRST READING
361	RTIB115	Num	4	R. POSTERIOR TIBIAL B. P. FIRST READING
362	LTIB115	Num	4	L. POSTERIOR TIBIAL B. P. FIRST READING
363	LTIB215	Num	4	L. POSTERIOR TIBIAL B. P. SECOND READING
364	RTIB215	Num	4	R. POSTERIOR TIBIAL B. P. SECOND READING
365	BRACH215	Num	4	BRACHIAL BLOOD PRESSURE SECOND READING
366	PALP16	Num	4	PALPATED SYSTOLIC BLOOD PRESSURE
367	MAXINF16	Num	4	MAXIMAL INFLATION LEVEL
368	SUPPUL16	Num	3	SUPINE READING: 30 SECOND HEART RATE
369	HOUR116	Num	3	(SUPINE READING)HOUR MEASUREMENT TAKEN
370	MIN116	Num	3	(SUPINE READ)MINUTE MEASUREMENT TAKEN
371	SUPSYS16	Num	4	(SUPING READING)BLOOD PRESSURE:SYSTOLIC (mm Hg)
372	SUPDIA16	Num	4	(SUPING READING)BLOOD PRESSURE:DIASTOLIC (mm Hg)
373	DIZZY16	Num	3	FEEL DIZZINESS/LIGHTHEADEDNESS/FAINTNESS
374	STDPUL16	Num	3	STANDING READING: 30 SECOND HEART RATE
375	HOUR316	Num	3	(STAND READING)HOUR MEASUREMENT TAKEN
376	MIN316	Num	3	(STAND READ)MINUTE MEASUREMENT TAKEN
377	STDSYS16	Num	4	(STAND READING)BLOOD PRESSURE:SYSTOLIC (mm Hg)
378	STDDIA16	Num	4	(STAND READING)BLOOD PRESSURE:DIASTOLIC (mm Hg)
379	DONE17	Num	3	MEASURED WALK, GAIT TEST: TEST DONE
380	TIME17	Num	3	TIME, IN SECONDS, TO WALK 15 FEET
381	PAINHD17	Num	3	PAIN IN WRIST OR HANDS
382	SURGHD17	Num	3	SURGERY ON HANDS
383	HAND117	Num	3	HAND TESTED
384	DYNAM117	Num	3	POSITION OF DYNAMOMETER
385	TRY117	Num	8	1ST GRIP STRENGTH (1) KG
386	TRY217	Num	8	1ST GRIP STRENGTH (2) KG
387	TRY317	Num	8	1ST GRIP STRENGTH (3) KG

Num	Variable	Type	Len	Label
388	HAND217	Num	3	HAND TESTED
389	DYNAM217	Num	3	POSITION OF DYNAMOMETER
390	TRY21I17	Num	8	2ND GRIP STRENGTH (1) KG
391	TRY22I17	Num	8	2ND GRIP STRENGTH (2) KG
392	TRY23I17	Num	8	2ND GRIP STRENGTH (3) KG
393	LUNG17	Num	3	BILATERAL RALES NOT CLEAR COUGH
394	SYSTOL17	Num	3	SYSTOLIC MURMUR
395	DIASTO17	Num	3	DIASTOLIC MURMUR
396	FOSSAR17	Num	3	RIGHT-SUPRACLAVICULAR FOSSA
397	JAWR17	Num	3	RIGHT-ANGLE OF JAW(CAROTID BRUITS)
398	INTENR17	Num	3	INTENSITY
399	FOSSAL17	Num	3	LEFT-SUPRACLAVICULAR FOSSA
400	JAWL17	Num	3	LEFT-ANGLE OF JAW(CAROTID BRUITS)
401	INTENL17	Num	3	INTENSITY
402	EDEMA17	Num	3	PITTING ANKLE EDEMA
403	STD117	Num	3	SAFE TO STAND UP WITHOUT USING ARMS
404	STDT17	Num	3	COULD YOU TRY TO STAND UP W/O USING ARMS
405	RSN117	Num	3	CODE THE REASON TASK WAS NOT PERFORMED
406	NRISE117	Num	3	NUMBER OF ATTEMPTS TO RISE
407	RISE117	Num	3	CODE FOR RISES
408	STD517	Num	3	SAFE TO STAND UP W/O USING ARMS 5 TIMES
409	HRATEB17	Num	3	HEART RATE(30 SEC) PRIOR TO CHAIR STANDS
410	NRISE517	Num	3	NUMBER OF COMPLETED CHAIR RISES
411	HRATEA17	Num	3	HEART RATE(30 SEC) AFTER CHAIR STANDS
412	NSEC17	Num	3	NUMBER OF SECONDS TO COMPLETE CHAIRSTAND
413	CHAIR17	Num	3	CHAIR HEIGHT
414	OTHER17	Num	3	OTHER PHYSICAL FINDINGS/COMMENTS
415	ADL	Num	3	ACTIV OF DAILY LIVING SCORE
416	IADL	Num	3	INSTRUMENTAL IADL SCORE
417	UES	Num	3	UPPER EXTREMITY SCORE
418	ROSEIC	Num	3	INTERMITTENT CLAUDICATION BY ROSE QUESTI
419	ROSEANG	Num	3	ANGINA BY ROSE QUESTIONNAIRE
420	AVZMSYS	Num	8	AVE ZERO MUDDLER SYSTOLIC BP (mm Hg)
421	AVZMDIA	Num	8	AVE ZERO MUDDDLER DIASTOLIC BP (mm Hg)
422	DOMGRIP	Num	8	GRIP STRENGTH, DOMINANT HAND
423	NDOMGRIP	Num	8	GRIP STRENGTH, NON-DOMINANT HAND
424	SMOKE	Num	3	SMOKING STATUS
425	PKYRS	Num	8	PACK YEARS SMOKED
426	ANGBASE	Num	3	ANGINA STATUS AT BASELINE

Num	Variable	Type	Len	Label
427	CHFBASE	Num	3	CHF STATUS AT BASELINE
428	CLDBASE	Num	3	CLAUD STATUS AT BASELINE
429	MIBASE	Num	3	MI STATUS AT BASELINE
430	STRKBASE	Num	3	STROKE STATUS AT BASELINE
431	TIABASE	Num	3	TIA STATUS AT BASELINE
432	ASPIRIN	Num	3	ASPIRIN USE > 2 DAYS IN 2 WKS
433	IHYPER	Num	3	CALC. ISO SYS HTN
434	CHD	Num	3	SELF-RPT MI/ANG,CABG,ANP
435	CBD	Num	3	SELF-RPT STROKE,TIA CAR ENDAR
436	DIABETES	Num	3	CALC. DIAB STATUS
437	BRONCH	Num	3	BRONCHITIS DX BY DOCTOR
438	EMPHYSEM	Num	3	EMPHYSEMA DX BY DOCTOR
439	PNEUMON	Num	3	PNEUMONIA DX BY DOCTOR
440	CURASTHM	Num	3	CURRENT ASTHMA DX BY DOC
441	YRSQUIT	Num	3	YRS SINCE QUIT SMOKE
442	MIAGE	Num	3	MIN AGE OF SIB MI
443	BRACH	Num	8	AVE BRACH FOR AAI
444	RTIB	Num	8	AVE RIGHT TIBIAL BP
445	LTIB	Num	8	AVE LEFT TIBIAL BP
446	RTAAI	Num	8	RIGHT ANKLE-ARM INDEX (%)
447	LTAAI	Num	8	LEFT ANKLE-ARM INDEX (%)
448	AAI	Num	8	MIN ANKLE ARM RATIO (%)
449	ORTH	Num	3	ORTHOSTATIC HYPOTENSION
450	SEASON	Num	3	SEASON ENROLLED
451	SMKAMT	Num	3	SMOKE AMOUNT
452	COG	Num	3	COGNITIVE FUNCTION CATEGORY
453	CLBLMOD	Num	3	CLD MODIFIED BL STAT
454	CHFSYMPT	Num	3	NUMBER OF CHF SYMPTOMS
455	KCAL2	Num	8	TOTAL KCALS -- NO CHORES
456	EXINTEN	Num	3	EXERCISE INTENSITY
457	YEAR10	Num	3	WHAT IS THE YEAR
458	SEASON10	Num	3	WHAT SEASON OF THE YEAR IS IT
459	DATE310	Num	3	WHAT IS THE DATE
460	WEEK10	Num	3	WHAT IS THE DAY OF THE WEEK
461	MONTH10	Num	3	WHAT IS THE MONTH
462	STATE10	Num	3	WHAT STATE ARE WE IN
463	COUNTY10	Num	3	WHAT COUNTY ARE WE IN
464	CITY10	Num	3	WHAT (CITY/TOWN) ARE WE IN
465	FLOOR10	Num	3	WHAT FLOOR OF THE BUILDING ARE WE ON

Num	Variable	Type	Len	Label
466	ADDRES10	Num	3	WHAT IS THIS ADDRESS/NAME OF THIS PLACE
467	APPLE110	Num	3	REPEAT 'APPLE'
468	TABLE110	Num	3	REPEAT 'TABLE'
469	PENNY110	Num	3	REPEAT 'PENNY'
470	SUB110	Num	4	SUBTRACT 7 FROM 100 - ANSWER
471	SUBER110	Num	3	SUBTRACT 7 FROM 100
472	SUB210	Num	3	SUBTRACT 7 FROM 93 - ANSWER
473	SUBER210	Num	3	SUBTRACT 7 FROM 93
474	SUB310	Num	3	SUBTRACT 7 FROM 86 - ANSWER
475	SUBER310	Num	3	SUBTRACT 7 FROM 86
476	SUB410	Num	3	SUBTRACT 7 FROM 79 - ANSWER
477	SUBER410	Num	3	SUBTRACT 7 FROM 79
478	SUB510	Num	3	SUBTRACT 7 FROM 72 - ANSWER
479	SUBER510	Num	3	SUBTRACT 7 FROM 72
480	SPELL110	Num	3	D IN THE WORD 'WORLD'
481	SPELL210	Num	3	L IN THE WORD 'WORLD'
482	SPELL310	Num	3	R IN THE WORD 'WORLD'
483	SPELL410	Num	3	O IN THE WORD 'WORLD'
484	SPELL510	Num	3	W IN THE WORD 'WORLD'
485	APPLE210	Num	3	REPEAT 'APPLE' AGAIN
486	TABLE210	Num	3	REPEAT 'TABLE' AGAIN
487	PENNY210	Num	3	REPEAT 'PENNY' AGAIN
488	WATCH10	Num	3	NAME THE WATCH
489	PENCIL10	Num	3	NAME THE PENCIL
490	PHRASE10	Num	3	REPEAT A PHRASE
491	READ10	Num	3	READ WORDS ON CARD THEN DO WHAT IT SAYS
492	DO110	Num	3	TAKES PAPER IN RIGHT
493	DO210	Num	3	FOLDS PAPER IN HALF
494	DO310	Num	3	PUTS PAPER DOWN ON LAP
495	WRITE10	Num	3	WRITE ANY COMPLETE SENTENCE ON THE PAPER
496	DRAW10	Num	3	COPY THE DRAWING ON THE SAME PAPER
497	PROBS10	Num	3	SPECIAL PROBLEMS
498	RAWSCR10	Num	3	SUM OF SCORES IN ITEMS 1 THROUGH 12
499	MAXSCR10	Num	3	SUM OF MAXIMUM SCORES FOR SCORED TASKS
500	CORSCR10	Num	3	CORRECTED SCORE
501	DIGIT10	Num	3	DIGIT SUBSTITUTION INDICATOR
502	DIGCOR10	Num	3	NUMBER OF SYMBOLS CORRECTLY CODED
503	DIGERR10	Num	3	NUMBER OF SYMBOLS INCORRECTLY CODED
504	SCOR3510	Num	3	COG. FUNCT. 35 POINT SCORE

Num	Variable	Type	Len	Label
505	MODMM10	Num	8	CALCULATED 100 POINT SCORE
506	BSA	Num	8	Body Surface Area
507	UNTRAN06	Num	3	NUMBER UNABLE TO TRANSCRIBE
508	ASPR06	Num	3	ASPIRIN/ASPIRIN-CONTAINING MEDICINES
509	DAYASP06	Num	3	DAYS TOOK THIS MEDICINE IN LAST TWO WEEK
510	FSHOIL06	Num	3	CODLIVER OIL/OTHER FISH-OIL SUPPLEMENTS
511	DAYFSH06	Num	3	DAYS TOOK THIS MEDICINE IN LAST TWO WEEK
512	ANTHST06	Num	3	ANTIHISTAMINES(COLD PILLS,ALLERGY PILLS)
513	SLPILL06	Num	3	SLEEPING PILLS
514	LAXATV06	Num	3	LAXATIVES
515	CALC06	Num	3	CALCIUM SUPPLEMENTS
516	FLUSH06	Num	3	FLU SHOT IN THE LAST YEAR
517	RACE01	Num	3	RACE
518	AGE2	Num	3	AGE IN 2-YEAR CATEGORIES
519	EDUC	Num	3	EDUCATION
520	HISP01	Num	3	HISPANIC ORIGIN
521	NONME101	Num	3	NONMELANOMA SKIN CANCER
522	PRGNT	Num	3	HOW MANY TIMES HAVE YOU BEEN PREGNANT
523	LIVBTH	Num	3	HOW MANY LIVE BIRTHS HAVE YOU HAD
524	WGT50	Num	4	WHAT WAS YOUR USUAL WEIGHT AT AGE 50
525	WEIGHT	Num	8	WEIGHT - LBS
526	BMI	Num	8	BODY MASS INDEX
527	STHT	Num	8	STANDING HEIGHT - CM
528	SITHT	Num	8	ADJUSTED SITTING HEIGHT - CM
529	WAIST	Num	8	WAIST CIRCUMFERENCE - CM
530	HIP	Num	8	HIP CIRCUMFERENCE - CM
531	PERMISS	Num	3	permission to release data
532	ANBLMOD	Num	3	ANG MODIFIED BL STAT
533	CHBLMOD	Num	3	CHF MODIFIED BL STAT
534	CHDBLMOD	Num	3	CHD BL MODIFIED STATUS
535	MIBLMOD	Num	3	MI MODIFIED BL STAT
536	STBLMOD	Num	3	STK MODIFIED BL STAT
537	TIBLMOD	Num	3	TIA MODIFIED BL STAT
538	FHHA	Num	3	Family History of heart attack
539	FHSTK	Num	3	Family History of stroke
540	DIABADA	Num	3	ADA Diabetic Status
541	HYPER	Num	3	CALC. HTN STATUS
542	HEARPROB	Num	3	HEARING PROBLEM
543	VISPROB	Num	3	VISION PROBLEM

Num	Variable	Type	Len	Label
544	WHOME09	Num	3	HAVE DIFFICULTY WALKING AROUND HOME
545	BED09	Num	3	HAVE DIFFICULTY GETTING OUT OF BED,CHAIR
546	KCAL	Num	8	TOTAL KCALS PHYSICAL ACTIVITY
547	NOMEDS06	Num	3	# of medications
548	A2A06	Num	3	Taking Medication? ANGIOTENSIN TYPE 2 ANTAGONISTS
549	A2AD06	Num	3	Taking Medication? COMBINATIONS OF ANGIOTENSIN II ANTAGONISTS PLUS DIURETICS
550	ACE06	Num	3	Taking Medication? ACE INHIBITORS WITHOUT DIURETICS
551	ACED06	Num	3	Taking Medication? ACE INHIBITORS WITH DIURETICS
552	ADPI06	Num	3	Taking Medication? INHIBITORS OF ADP-INDUCED PLATELET AGGREGATION
553	AGDI06	Num	3	Taking Medication? ALPHA-GLUCOSIDASE INHIBITORS
554	ALPHA06	Num	3	Taking Medication? ALPHA-BLOCKERS WITHOUT DIURETICS
555	ALPHAD06	Num	3	Taking Medication? ALPHA-BLOCKERS WITH DIURETICS
556	ALZH06	Num	3	Taking Medication? ACETYLCHOLINE ESTERASE INHIBITORS FOR ALZH
557	AMLOD06	Num	3	Taking Medication? AMLODIPINE
558	ANAR1A06	Num	3	Taking Medication? ANTI-ARRHYTHMICS, CLASS 1A
559	ANAR1B06	Num	3	Taking Medication? ANTI-ARRHYTHMICS, CLASS 1B
560	ANAR1C06	Num	3	Taking Medication? ANTI-ARRHYTHMICS, CLASS 1C
561	ANAR306	Num	3	Taking Medication? ANTI-ARRHYTHMICS, CLASS 3
562	ANTPSY06	Num	3	Taking Medication? ANTI-PSYCHOTIC MEDICATIONS
563	ANYACE06	Num	3	Taking Medication? ANY ACE OR ACED
564	ANYBETA06	Num	3	Taking Medication? ANY BETA OR BETAD
565	ANYDIUR06	Num	3	Taking Medication? ANY DIUR, BETAD, VASOD, OR ACED
566	ANYVASO06	Num	3	Taking Medication? ANY VASO OR VASOD
567	ASA06	Num	3	Taking Medication? ASPIRIN FROM 280804 (ANTI-INFLAM AGENTS)
568	BASQ06	Num	3	Taking Medication? BILE-ACID SEQUESTRANTS
569	BENZOD06	Num	3	Taking Medication? BENZODIAZEPINES
570	BETA06	Num	3	Taking Medication? BETA-BLOCKERS WITHOUT DIURETICS
571	BETAD06	Num	3	Taking Medication? BETA-BLOCKERS WITH DIURETICS
572	BGND06	Num	3	Taking Medication? BIGUANIDES
573	CCB06	Num	3	Taking Medication? ANY CALCIUM-CHANNEL BLOCKER = CCIR OR CCBSR OR CCBT
574	CCBIR06	Num	3	Taking Medication? IMMEDIATE-RELEASE CCBS = NIFIR OR DIHIR OR VERIR OR DLTIR
575	CCBSR06	Num	3	Taking Medication? SLOW-RELEASE CCBS = NIFSR OR DIHSR OR VERSR OR DLTSR OR AMLOD
576	CCBT06	Num	3	Taking Medication? T-TYPE CALCIUM-CHANNEL BLOCKER
577	COX206	Num	3	Taking Medication? COX-2 INHIBITORS (NSAID AGENTS); SEPARATE FROM NSAID VARIABLE
578	DIG06	Num	3	Taking Medication? DIGITALIS PREPARATIONS
579	DIHIR06	Num	3	Taking Medication? IMMEDIATE-RELEASE DIHYDROPYRIDINES OTHER THAN NIFEDIPINE
580	DIHSR06	Num	3	Taking Medication? SLOW-RELEASE DIHYDROPYRIDINES OTHER THAN NIFEDIPINE OR AMLOPIDINE

Num	Variable	Type	Len	Label
581	DIURET06	Num	3	Taking Medication? ANY DIURETIC
582	DLTIR06	Num	3	Taking Medication? IMMEDIATE-RELEASE DILTIAZEM
583	DLTSR06	Num	3	Taking Medication? SLOW-RELEASE DILTIAZEM
584	DPP4I06	Num	3	Taking Medication? DIPEPTIDYL-PEPTIDASE-IV INHIBITORS
585	EDD06	Num	3	Taking Medication? ERECTILE DYSFUNCTION DRUGS
586	ESTRGN06	Num	3	Taking Medication? ESTROGENS, EXCLUDING VAGINAL CREAMS
587	FIBR06	Num	3	Taking Medication? FIBRATES
588	GOUT06	Num	3	Taking Medication? GOUT TREATMENTS
589	H2B06	Num	3	Taking Medication? H-2 BLOCKERS
590	HCTZ06	Num	3	Taking Medication? THIAZIDE DIURETICS WITHOUT K-SPARING AGENTS
591	HCTZK06	Num	3	Taking Medication? THIAZIDE DIURETICS WITH K-SPARING AGENTS
592	HPRNS06	Num	3	Taking Medication? HEPARINS
593	HTNMED06	Num	3	Taking Medication? ANY ANTI-HYPERTENSIVE MEDICATION
594	INSLN06	Num	3	Taking Medication? INSULINS
595	IPRTR06	Num	3	Taking Medication? ANTICHOLINERGICS + COMBINATION WITH BETA2-AGONIST
596	ISTRD06	Num	3	Taking Medication? INHALED STEROIDS FOR ASTHMA
597	KBLKR06	Num	3	Taking Medication? K-CHANNEL BLOCKERS TO ENHANCE INSULIN SECRETION FOR DIABETICS
598	KCL06	Num	3	Taking Medication? POTASSIUM SUPPLEMENTS
599	KSPR06	Num	3	Taking Medication? POTASSIUM-SPARING AGENTS ALONE
600	LIPID06	Num	3	Taking Medication? ANY LIPID-LOWERING MEDICATION
601	LOOP06	Num	3	Taking Medication? LOOP DIURETICS
602	MAOI06	Num	3	Taking Medication? MAO INHIBITORS
603	MLPD06	Num	3	Taking Medication? MISCELLANEOUS LIPID-LOWERING DRUGS
604	NDRIS06	Num	3	Taking Medication? NOREPINEPHRINE-DOPAMINE REUPTAKE INHIBITOR
605	NIAC06	Num	3	Taking Medication? NIACIN AND NICOTINIC ACID
606	NIFIR06	Num	3	Taking Medication? IMMEDIATE-RELEASE NIFEDIPINE
607	NIFSR06	Num	3	Taking Medication? SLOW-RELEASE NIFEDIPINE
608	NSAID06	Num	3	Taking Medication? NON-STEROIDAL ANTI-INFLAMMATORY AGENTS, EXCLUDING ASPIRIN
609	NTCA06	Num	3	Taking Medication? NON-TRICYCLIC ANTIDEPRESSANTS OTHER THAN MAOI
610	NTG06	Num	3	Taking Medication? NITRATES
611	OAIA06	Num	3	Taking Medication? ORAL ANTI-INFLAMMATORY ASTHMA DRUGS (LEUKOTRIENE RECEPTOR ANTAGONISTS AND INHIBITORS OF LIPO-OXYGENASE)
612	OHGA06	Num	3	Taking Medication? ORAL HYPOGLYCEMIC AGENTS
613	OSTRD06	Num	3	Taking Medication? ORAL STEROIDS
614	OTCH2B06	Num	3	Taking Medication? OVER-THE-COUNTER H-2 BLOCKERS
615	PDEI06	Num	3	Taking Medication? PHOSPHODIESTERASE INHIBITORS
616	PPI06	Num	3	Taking Medication? PROTON PUMP INHIBITORS
617	PRGSTN06	Num	3	Taking Medication? PROGESTINS

Num	Variable	Type	Len	Label
618	PRKNSN06	Num	3	Taking Medication? DRUGS USED TO TREAT PARKINSON
619	PRMRN06	Num	3	Taking Medication? PREMARIN (CONJUGATED ESTROGENS)
620	PROB06	Num	3	Taking Medication? PROBUCOL
621	PVDL06	Num	3	Taking Medication? PERIPHERAL VASODILATORS, EXCLUDE DIPYRIDAMOLE
622	SARIS06	Num	3	Taking Medication? SEROTONIN ANTAGONIST AND REUPTAKE INHIBITOR
623	SLF106	Num	3	Taking Medication? FIRST GENERATION SULFONYLUREAS
624	SLF206	Num	3	Taking Medication? SECOND GENERATION SULFONYLUREAS
625	SNRIS06	Num	3	Taking Medication? SEROTONIN-NOREPINEPHRINE REUPTAKE INHIBITORS
626	SSRIS06	Num	3	Taking Medication? SELECTIVE SEROTONIN REUPTAKE INHIBITORS
627	STTN06	Num	3	Taking Medication? HMG COA REDUCATACE INHIBITORS (STATINS)
628	SYMPH06	Num	3	Taking Medication? SYMPATHOMIMETICS, ORAL AND INHALED
629	TCA06	Num	3	Taking Medication? TRICYLIC ANTI-DEPRESSANTS
630	TCAP06	Num	3	Taking Medication? TRI-CYCLIC ANTI-DEPRESSANTS PLUS ANTI-PSYCHOTICS COMBINATIONS
631	THRY06	Num	3	Taking Medication? THYROID AGENTS
632	THZD06	Num	3	Taking Medication? THIAZOLIDINEDIONES
633	UAZQTD06	Num	3	Taking Medication? DEFINITE ECG QT INTERVAL-ALTERING MEDICATION
634	UAZQTP06	Num	3	Taking Medication? POSSIBLE ECG QT INTERVAL-ALTERING MEDICATION
635	URCOS06	Num	3	Taking Medication? URICOSURICS
636	VASO06	Num	3	Taking Medication? VASODILATORS, A MIXED GROUP
637	VASOD06	Num	3	Taking Medication? VASODILATORS WITH DIURETICS, A MIXED GROUP
638	VERIR06	Num	3	Taking Medication? IMMEDIATE-RELEASE VERAPAMIL
639	VERSR06	Num	3	Taking Medication? SLOW-RELEASE VERAPAMIL
640	WARF06	Num	3	Taking Medication? ORAL ANTICOAGULANTS INCLUDING WARFARIN, COUMADIN, AND ANISINDIONE
641	WTLS06	Num	3	Taking Medication? WEIGHT LOSS DRUGS
642	XOI06	Num	3	Taking Medication? XANTHINE OXIDASE INHIBITORS

APÊNDICE B – Roteiro do teste

Sistema Stroke - Roteiro do teste

Início do teste

Bom dia. Tudo bem? Obrigado por aceitar participar desta pesquisa.

Sobre a avaliação do sistema Stroke

O Stroke é um sistema inteligente baseado em inteligência artificial¹, desenvolvido para auxiliar no diagnóstico de pacientes que possam vir a sofrer AVC, em especial na prevenção de fatores de risco e sinais indicativos. Ele utiliza algoritmos² avançados para analisar dados e auxiliar os profissionais de saúde a classificarem a probabilidade de um paciente sofrer um AVC.

Instruções

A avaliação se dividirá em três partes:

- Primeiro, farei algumas perguntas sobre seu perfil
- Depois, vou pedir para que você faça algumas tarefas usando o sistema
- Por último, vou pedir para que você responda algumas perguntas sobre o uso que você terá feito no sistema.

Como esta é a primeira versão do sistema, ainda há algumas limitações que precisam ser corrigidas. Por exemplo, em algumas situações, é necessário clicar várias vezes em um botão para que funcione corretamente. Além disso, ao inserir a primeira informação no cadastro, o sistema retorna para uma tela de listagem, mas é possível retornar para a funcionalidade desejada. Esses problemas serão solucionados em futuras atualizações.

Questionário sobre o perfil do participante

- Qual é a sua área de especialização?
 - ☐ Clínica Médica
 - ☐ Pediatria
 - ☐ Cardiologia
 - ☐ Dermatologia
 - ☐ Ginecologia
 - ☐ Neurologia
 - ☐ Outra _____
 - Por quanto tempo você tem atuado nessa área?
-

¹ Inteligência artificial é a capacidade dos computadores de aprender e executar tarefas complexas de forma autônoma, como reconhecer imagens e tomar decisões, sem a necessidade de programação manual.

² Algoritmos são sequências de instruções bem definidas e estruturadas, que são projetadas para resolver um problema ou realizar uma tarefa específica em um computador.

- ☐ Menos de 1 ano
- ☐ Entre 1 e 3 anos
- ☐ Entre 4 e 6 anos
- ☐ Entre 7 e 9 anos
- ☐ Mais de 10 anos
- ☐ Outro: _____
- Você já teve experiência direta no atendimento de pacientes com AVC?
 - ☐ Sim
 - ☐ Não
- Com base na sua experiência, quais fatores de risco são mais relevantes para o desenvolvimento de um AVC?
 - ☐ Hipertensão arterial
 - ☐ Doenças cardíacas
 - ☐ Diabetes
 - ☐ Colesterol elevado
 - ☐ Tabagismo
 - ☐ Obesidade
 - ☐ Outros: _____
- Quais são os sintomas mais comuns que um paciente apresenta quando tem um AVC?
 - ☐ Fraqueza súbita em um lado do corpo, incluindo braço, perna ou face.
 - ☐ Dormência súbita em um lado do corpo, incluindo braço, perna ou face.
 - ☐ Confusão súbita, dificuldade para falar ou entender a fala.
 - ☐ Perda súbita de visão em um ou ambos os olhos.
 - ☐ Tontura súbita, perda de equilíbrio ou coordenação.
 - ☐ Dor de cabeça súbita, intensa e sem explicação aparente.
 - ☐ Dificuldade súbita para andar, perda de equilíbrio ou coordenação.
 - ☐ Outro: _____
- Você já atendeu um paciente que estava relativamente bem e teve um AVC dias ou meses depois?
 - ☐ Sim
 - ☐ Não
- Na sua opinião, é possível determinar a probabilidade de um paciente sofrer um AVC com base em seus sinais indicativos e fatores de risco?

Sobre as tarefas

- Agora, vamos realizar algumas tarefas com o sistema que estamos avaliando.
- Por favor, pense alto enquanto realiza as tarefas, compartilhando suas dificuldades e dúvidas durante o processo.
- Se você não conseguir concluir uma tarefa ou quiser desistir, avise-me imediatamente para que possamos prosseguir.

Cenários de uso

- Estatísticas de AVC.
- Cadastre um novo paciente no sistema.
- Utilize o sistema para buscar informações de um paciente já cadastrado.
- Edite as informações de um paciente existente no sistema.
- Crie um quadro clínico para um paciente e utilize o sistema para gerar a probabilidade do paciente sofrer um AVC.
- Crie um quadro clínico para um paciente e, com base em sua experiência, determine a probabilidade do paciente sofrer um AVC.

Tarefas

Ao chegar no hospital municipal de Encanto/RN para realizar mais um plantão, você irá utilizar o sistema Stroke para atender os pacientes. Considere que chegou um paciente e você irá utilizar o sistema stroke para realizar o atendimento.

Tarefa 1: Utilize o sistema para coletar os dados desse paciente. Antes de preencher os campos, por favor diga em voz alta o que pretende fazer.

Tarefa 2: Visualize se os dados do paciente foram cadastrados. (Observação: Pode ser necessário recarregar a tela para conseguir ver os pacientes cadastrados.)

Após preencher os campos com as informações do paciente e salvá-las no sistema, ele informou que errou o nome do bairro onde mora. Nesse caso, é importante fazer a correção o mais rápido possível para evitar possíveis problemas no atendimento.

Tarefa 3: Informe o paciente cujo bairro foi informado incorretamente e faça a correção. Após fazer a correção, volte para a tela de listagem de pacientes e verifique se o nome do bairro foi atualizado corretamente.

Após ter cadastrado as informações básicas do paciente, é hora de registrar o quadro clínico dele.

Tarefa 4: Utilize o sistema para realizar o cadastro do quadro clínico desse cliente, e com base em sua experiência, determine a probabilidade dele sofrer um AVC.

Agora, você deseja que o próprio sistema gere a probabilidade desse paciente sofrer um AVC.

Tarefa 5: Utilize o sistema para realizar o cadastro do quadro clínico desse cliente, utilizando o sistema para gerar probabilidade do paciente sofrer um AVC.

Você concluiu o atendimento anterior e forneceu as orientações necessárias ao paciente. Em seguida, um segundo paciente chegou. Esse paciente já havia sido atendido outras vezes.

Tarefa 6: Utilize o sistema para verificar o histórico de atendimentos anteriores desse paciente e avaliar sua probabilidade de AVC.

Tarefa 7: Utilize o sistema para visualizar as estatísticas gerais das probabilidades de AVC de todos os pacientes cadastrados.

Entrevista após observação de uso do sistema

- O que você achou da experiência de uso do sistema?
- De que você gostou no sistema?
- De que você NÃO gostou no sistema?
- O que você acha que poderia melhorar ou incluir no sistema?