PONTIFÍCIA UNIVERSIDADE CATÓLICA DE MINAS GERAIS

Programa de Pós-Graduação em Informática

Thiago Henriques Nunes de Lima

EXTRAÇÃO DE CONHECIMENTO DE MÉTODOS CAIXA PRETA NO CONTEXTO DE DEPRESSÃO EM CRIANÇAS E ADOLESCENTES

Belo Horizonte

2020

Thiago Henriques Nunes de Lima

EXTRAÇÃO DE CONHECIMENTO DE MÉTODOS CAIXA PRETA NO CONTEXTO DE DEPRESSÃO EM CRIANÇAS E ADOLESCENTES

Dissertação apresentada ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Informática.

Orientador: Prof.^{a} Dr.^{a} Cristiane Neri Nobre

Belo Horizonte

2020

FICHA CATALOGRÁFICA
Elaborada pela Biblioteca da Pontifícia Universidade Católica de Minas Gerais

Lima, Thiago Henriques Nunes de
L732e Extração de conhecimento de métodos caixa preta no contexto de depressão em crianças e adolescentes / Thiago Henriques Nunes de Lima. Belo Horizonte, 2020.
94 f. : il.

Orientadora: Cristiane Neri Nobre

Dissertação (Mestrado) - Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Informática

1. Depressão em crianças. 2. Depressão. 3. Adolescentes. 4. Algoritmos computacionais. 5. Aprendizado do computador. 6. Support vector machines. 7. Redes neurais (Computação). 8. Mineração de dados (Computação). 9. Algorítmos genéticos. I. Nobre, Cristiane Neri. II. Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Informática. III. Título.

CDU: 681.3.03

Ficha catalográfica elaborada por Fabiana Marques de Souza e Silva - CRB 6/2086

Thiago Henriques Nunes de Lima

EXTRAÇÃO DE CONHECIMENTO DE MÉTODOS CAIXA PRETA NO CONTEXTO DE DEPRESSÃO EM CRIANÇAS E ADOLESCENTES

Dissertação apresentada ao Programa de Pós-Graduação em Informática como requisito parcial para qualificação ao Grau de Mestre em Informática pela Pontifícia Universidade Católica de Minas Gerais.

Prof.ª Dr.ª Cristiane Neri Nobre – PUC Minas

Prof. Dr. Luis Enrique Zárate – PUC Minas

Prof. Dr. Marcelo Azevedo Costa – UFMG

Belo Horizonte, 12 de Junho de 2020

AGRADECIMENTOS

Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código Financeiro 001. Os autores também agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico do Brasil (CNPq) e a Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG). O trabalho foi desenvolvido na Pontifícia Universidade Católica de Minas Gerais, PUC Minas, no laboratório de Inteligência Computacional Aplicada - LICAP.

RESUMO

A depressão é um distúrbio mental comum e é caracterizada por tristeza persistente e falta de interesse ou prazer em atividades que anteriormente eram gratificantes, além do distúrbio do sono e apetite, fadiga e baixa concentração. Os seus efeitos podem ser duradouros ou recorrentes e podem afetar a capacidade de uma pessoa viver a vida de uma forma gratificante. Segundo a Organização Mundial da Saúde, atualmente no mundo mais de 300 milhões de pessoas convivem com depressão. Este transtorno é resultado de uma complexa interação de fatores biológicos, psicológicos e sociais, e é conhecido por ter prognóstico e diagnóstico difíceis. Este trabalho teve como objetivo inicial realizar de uma revisão sistemática da literatura para a identificação do atual panorama da depressão. A partir dessa revisão, foi possível identificar os principais fatores relacionados à depressão citados na literatura, além da identificação dos métodos estatísticos e computacionais utilizados para o seu estudo. Também foi possível identificar algumas bases de dados disponíveis para o estudo da depressão, além dos principais instrumentos utilizados por profissionais para o seu diagnóstico, tais como o CDI (Children's Depression Inventory) e o YSR (Youth Self-Report). A partir deste levantamento inicial, este trabalho objetivou levantar características necessárias para identificar os principais fatores que contribuem para a depressão em crianças e adolescentes. Técnicas de aprendizado de máquina são cada vez mais utilizadas para classificar ou caracterizar perfis de doenças. Este trabalho apresenta um estudo sobre depressão entre crianças e adolescentes através da extração de conhecimento em classificadores de natureza caixa preta, como o SVM e Rede Neural *Multilayer Perceptron*, além do uso de algoritmos genéticos para a identificação de características relevantes à classificação. Através do *framework* SHAP, que extrai conhecimento de métodos caixa preta, são apresentadas explicações individualizadas sobre como os atributos influenciaram os resultados da classificação. Os seguintes atributos foram observados: sexo feminino, tempo despendido pelos pais com os filhos, a escolaridade da mãe da criança ou adolescente, autoestima, sentimentos de culpa, dentre outros fatores observados pelos instrumentos CDI e YSR.

Palavras-chave: Aprendizado de máquina. Crianças e adolescentes. Depressão. Extração de conhecimento. SHAP.

ABSTRACT

Depression is a common mental disorder, characterized by persistent sadness and a lack of interest or pleasure in activities that were previously rewarding, including sleep and appetite disturbance, fatigue, and low concentration. Its effects can be long-lasting or recurrent and can affect a person's ability to live life in a rewarding way. According to the World Health Organization, more than 300 million people worldwide are living with depression today. This disorder is the result of a complex interplay of biological, psychological and social factors, and is known to have a difficult prognosis and diagnosis. This work had as its initial objective to carry out a systematic review of the literature to identify the current panorama of depression. From this review, it was possible to identify the main factors related to depression mentioned in the literature and the identification of statistical and computational methods used for its study. It was also possible to identify some databases available for the study of depression, in addition to the main instruments used by professionals for their diagnoses, such as the CDI (Children's Depression Inventory) and the YSR (Youth Self-Report). From this initial survey, this study aimed to raise characteristics necessary to identify the main factors that contribute to depression in children and adolescents. Machine learning techniques are increasingly used to classify or characterize disease profiles. This paper presents a study on depression among children and adolescents through the extraction of knowledge in black box classifiers, such as SVM and Neural Network *Multilayer Perceptron*, in addition to the use of genetic algorithms to identify characteristics relevant to classification. Through the *framework* SHAP, which extracts knowledge from black-box methods, individual explanations are presented on how the attributes influenced the classification results. The following attributes were observed: female gender, time spent by parents with their children, schooling of the child's or adolescent's mother, self-esteem, feelings of guilt, among other factors observed by the CDI and YSR instruments.

Keywords: Machine Learning. Children and adolescents. Depression. Knowledge extraction. SHAP.

LISTA DE FIGURAS

FIGURA 1 – Número de pessoas com depressão por país. 25

FIGURA 2 – Número de pessoas com depressão no Brasil em qualquer idade e sexo. 26

FIGURA 3 – Número total de pessoas de todas as idades com depressão no Brasil, diferenciadas por sexo. 27

FIGURA 4 – Percentual de pessoas brasileiras de 18 anos ou mais de idade que referem diagnóstico de depressão por profissional de saúde mental no ano de 2013 agrupados por região. 27

FIGURA 5 – Percentual de pessoas brasileiras de 18 anos ou mais de idade que referem diagnóstico de depressão por profissional de saúde mental no ano de 2013 agrupadas por estados. 28

FIGURA 6 – Informações sobre a depressão no mundo 29

FIGURA 7 – Processo KDD. 32

FIGURA 8 – Representação de um hiperplano ótimo separando duas classes. 32

FIGURA 9 – Arquitetura de uma rede neural. 34

FIGURA 10 – Interpretação Global e Local. 35

FIGURA 11 – Abordagem SHAP. 42

FIGURA 12 – Fatores relacionados à depressão. 48

FIGURA 13 – Critérios para o diagnóstico de depressão entre os principais instrumentos de investigação da doença. 56

FIGURA 14 – Metodologia adotada no trabalho. 58

FIGURA 15 – Combinação de atributos que compõem a base de dados. 59

FIGURA 16 – Etapas realizadas do pré-processamento da base de dados. 65

FIGURA 17 – Distribuição do CDI Soma 66

FIGURA 18 – Número de indivíduos em que o CDI Soma é maior que o percentil . . 67

FIGURA 19 – Representação de três indivíduos. 69

FIGURA 20 – Impacto dos atributos mais relevantes para a classificação das instâncias do conjunto de testes utilizando o classificador SVM. Para cada atributo, a dispersão vertical representa pontos de dados com o mesmo valor SHAP para esse atributo. Valores SHAP mais altos significam maior probabilidade de uma previsão de classe positiva (HIGH). 75

FIGURA 21 – Impacto dos atributos mais relevantes para a classificação das instâncias do conjunto de testes utilizando o classificador *Multi-layer Perceptron*. Para cada atributo, a dispersão vertical representa pontos de dados com o mesmo valor SHAP para esse atributo. Valores SHAP mais altos significam maior probabilidade de uma previsão de classe positiva (HIGH). 76

FIGURA 22 – Experimentos. *Fitness* (*f-Measure*) e diversidade conforme a população evolui através de gerações. Os resultados são a média de 10 execuções. 78

FIGURA 23 – Frequências dos 20 atributos mais utilizados pelo AG nos experimentos. 80

FIGURA 24 – Atributos comuns relevantes para a classificação identificados pelo SHAP para o classificador *Multi-layer Perceptron* e o classificador SVM e atributos encontrados pelo AG através da seleção de características. 81

LISTA DE TABELAS

TABELA 1 – Número de artigos mantidos após cada uma das três fases de filtragem da revisão. 46

TABELA 2 – Descrição, tipo e possíveis valores dos atributos demográficos. 60

TABELA 3 – Descrição, tipo e valores permitidos dos atributos sociais. 61

TABELA 4 – Descrição, tipo e valores permitidos dos atributos que representam as questões do CDI. 62

TABELA 5 – Descrição e tipo dos atributos referente ao questionário YSR. 63

TABELA 6 – Descrição das outras questões consideradas importantes pela comunidade de saúde mental. 63

TABELA 7 – Valores mínimo, máximo e média dos atributos numéricos. 64

TABELA 8 – Número de instâncias por classe para os conjuntos de treinamento e teste 68

TABELA 9 – Métricas de avaliação dos modelos, em porcentagem 73

TABELA 10 – Avaliação dos modelos nos dados de teste, valores em porcentagem . . 74

TABELA 11 – Atributos selecionados pelo algoritmo genético. 79

LISTA DE QUADROS

QUADRO 1 – Critérios diagnósticos para o Transtorno Depressivo. 30
QUADRO 2 – Bases de dados utilizados para obter os trabalhos para a realização da SLR. 45
QUADRO 3 – Artigos selecionados pela pesquisa 47
QUADRO 4 – Principais métodos computacionais utilizados no contexto da depressão. 50
QUADRO 5 – Bases de dados disponíveis sobre depressão 54
QUADRO 6 – Parâmetros dos experimentos utilizados pelo AG. 70

LISTA DE ABREVIATURAS E SIGLAS

BDI *Beck Depression Inventory*

CART *Classification and Regression Trees*

CDI *Children's Depression Inventory*

CID Classificação Internacional de Doença

DSM *Diagnostic and Statistical Manualof Mental Disorders*

HAM-D *Hamilton Depression Rating Scale*

KDD *Knowledge Discovery in Database*

OMS Organização Mundial da Saúde

PHQ *Patient Health Questionnaire*

RIPPER *Repeated Incremental Pruning to Produce Error Reduction*

RNA Rede Neural Artificial

SBCAS Simpósio Brasileiro de Computação Aplicada à Saúde

SHAP SHapley Additive exPlanations

SUS Sistema Único de Saúde

SVM *Support Vector Machine*

TDAH Transtorno de Déficit de Atenção e Hiperatividade

TID Transtorno Invasivo do Desenvolvimento

UFMG Universidade Federal de Minas Gerais

WEKA *Waikato Environment for Knowledge Analysis*

YSR *Youth Self-Report*

SUMÁRIO

1 INTRODUÇÃO **19**
1.1 Problema 22
1.2 Objetivos 22
1.2.1 Objetivo geral 22
1.2.2 Objetivo específico 22
1.3 Justificativa 23
1.4 Organização do trabalho 23

2 REFERENCIAL TEÓRICO **25**
2.1 Prevalência de Transtornos Depressivos 25
2.2 Depressão em Crianças e Adolescentes 28
2.3 Mineração de Dados 31
2.4 Máquina de Vetores de Suporte 31
2.5 Rede Neural Artificial 33
2.6 Extração de Conhecimento em Métodos de Caixa Preta 34
2.6.1 Dimensões da Interpretabilidade 35
2.6.2 Tipos de Abordagens 36
2.6.3 Tipos de Explicitação do Conhecimento 37
2.6.4 Métodos de Extração de Conhecimento 38
2.6.5 Precisão local 40
2.6.6 Missingness 41
2.6.7 Consistência 41

3 REVISÃO SISTEMÁTICA DA LITERATURA **43**
3.0.1 Questões de Pesquisa 43
3.0.2 Critério de Seleção/Exclusão 44
3.0.3 Processo de Pesquisa 44
3.0.4 Discussão 46
3.0.4.1 Quais as características ligadas à depressão são citados na literatura? 46

3.0.4.2 Quais métodos estatísticos e computacionais são utilizados para o estudo da depressão? 49
3.0.4.3 Quais são as bases de dados atualmente disponíveis para análise de pessoas com depressão? 52
3.0.4.4 Quais os tipos de instrumentos são utilizados para a investigação da depressão? 54

4 METODOLOGIA **57**
4.1 Levantamento Bibliográfico e Revisão Sistemática da Literatura ... 57
4.2 Descrição da base de dados 57
4.2.1 Pré-processamento 60
4.3 Padronização de Valores Ausentes 61
4.4 Remoção de Atributos com Poucas Informações 64
4.5 Tratamento da Inconsistência dos Dados 64
4.6 Identificação e Manipulação do Atributo Classe 65
4.7 Balanceamento da Base de Dados 67
4.8 Divisão do Conjunto de Treino e Teste 67
4.9 Algoritmos Genéticos para seleção de atributos 68
4.9.1 Representação dos Indivíduos 69
4.9.2 Fitness 70
4.9.3 Parâmetros dos Experimentos 70
4.10 Descrição dos Métodos 70
4.11 Métricas de avaliação da qualidade dos modelos 71

5 RESULTADOS E DISCUSSÕES **73**

REFERÊNCIAS **83**

1 INTRODUÇÃO

Segundo a Organização Mundial da Saúde (OMS) (WHO, 2018), a depressão* é diferente das oscilações de humor habituais e de sentimentos de curta duração em resposta aos desafios da vida cotidiana. É a principal causa de doenças e incapacidades na adolescência em todo o mundo, podendo se tornar um grave problema de saúde, principalmente quando duradouro e com intensidade moderado ou forte. Em todo o mundo, a depressão atinge cerca de 300 milhões de pessoas, um aumento de mais de 18% entre os anos de 2005 e 2015 (WHO, 2018), e se não tratada, pode fazer com que a pessoa afetada sofra bastante, interferindo no seu desempenho profissional, estudantil e/ou familiar, e no pior dos casos, pode levar ao suicídio. Todos os anos, cerca de 800 mil pessoas morrem por suicídio, considerado a segunda principal causa de morte entre os jovens de 15 a 29 anos (WHO, 2018)(ANDERSON; SMITH et al., 2005).

Embora existam tratamentos eficazes para a depressão, a própria OMS alerta que menos da metade dos afetados no mundo recebem esses tratamentos. As barreiras para o atendimento efetivo incluem falta de recursos, falta de profissionais de saúde treinados e o estigma social associado a transtornos mentais. Além disso, outro obstáculo ao tratamento efetivo é a avaliação imprecisa. As pessoas com depressão muitas vezes não são diagnosticadas corretamente como tal, e outras, que não têm o distúrbio, são diagnosticadas erroneamente como depressivas. Esse fato leva à prescrição desnecessária de antidepressivos para uns e à falta dela para outros que necessitam. Essa consequência da imprecisão causa transtorno aos demais tratamentos da depressão (ROCHA, 2009).

Para a OMS (WHO, 2018), a depressão leve à moderado pode ser efetivamente tratada com terapia comportamental cognitiva ou psicoterapia. Os antidepressivos podem ser uma forma eficaz de tratamento para depressão moderado a grave, mas não são a primeira opção de tratamento para casos de depressão leve. Eles não devem ser usados para tratar depressão em crianças e não são os mais indicados no tratamento em adolescentes. Estes devem fazer o uso de antidepressivos com cautela e somente quando necessário (ROCHA, 2009).

Algumas pesquisas (COMIJS et al., 2013)(YOON; TAHA; BAKKEN, 2014)(WANG et al., 2016) elucidam que metade de todas as pessoas que desenvolvem transtornos mentais têm seus primeiros sintomas até os 14 anos. Para a Sociedade Americana de Psiquia-

*O termo depressão é utilizado com frequência para se referir a qualquer um dos vários transtornos depressivos. Alguns estão classificados no *Diagnostic and Statistical Manual of Mental Disorders, Fifth Edition* (DSM-5) (ASSOCIATION et al., 2013) por sintomas específicos.

tria (*American Psychiatric Association*) (APA, 2017), uma em cada seis pessoas sofrerá de depressão em algum momento de sua vida, o que leva ao impressionante número de cerca de um bilhão de pessoas em todo o planeta. Ou seja, cuidar de crianças e adolescentes com problemas de saúde mental pode evitar mortes e/ou o sofrimento ao longo da vida.

Desta forma, apesar de existirem tratamentos psicológicos e farmacológicos eficazes para a depressão, para que isso ocorra, é fundamental um diagnóstico correto. Logo, torna-se essencial pesquisas que contribuam para o diagnóstico e tratamento desse distúrbio, especialmente em crianças e adolescentes. Na área da Computação, trabalhos têm sido desenvolvidos para contribuir no diagnóstico e no estudo da depressão. Dentre eles sobressaem-se os que utilizam Aprendizagem de Máquina, uma área da Inteligência Artificial voltada para o desenvolvimento de algoritmos e técnicas que possam extrair informações de dados (ORRU et al., 2012)(SCHMIDHUBER, 2015)(GOODFELLOW et al., 2016)(WITTEN et al., 2016). A literatura indica resultados satisfatórios advindos da combinação de técnicas de aprendizagem de máquina com a identificação de padrões que caracterizam doenças, especificamente aquelas relacionados à depressão e outros transtornos mentais (GKOTSIS et al., 2017). Em testes preliminares realizados com diversos classificadores utilizando-se a mesma a base de dados deste estudo (MALAQUIAS et al., 2019), o classificador SVM (*Support Vector Machine*, ou Máquinas de Vetores de Suporte) e a Rede Neural *Feedforward Multilayer Perceptron* obtiveram desempenhos melhores em relação aos outros classificadores, tais como os algoritmos C4.5 (QUINLAN, 1993), CART *(Classification and Regression Trees)*, (BREIMAN et al., 1984), *Random Forest* (BREIMAN, 2001), e RIPPER (COHEN, 1995).

SVMs têm demonstrado um melhor desempenho de generalização em comparação a outras técnicas de classificação em diversas áreas de aplicação (BYUN; LEE, 2002). Considerado um método de natureza caixa preta por "esconder" a sua lógica interna para os usuários, a sua incapacidade em fornecer uma explicação sobre as suas classificações torna-se um empecilho para a sua aplicação prática. Outro método da mesma natureza que, em testes preliminares, apresentou bons resultados foi a Rede Neural *Feedforward Multilayer Perceptron* (MALAQUIAS et al., 2019). Tendo em vista essa limitação dos classificadores e a exigência do fornecimento de explicações quanto às classificações em diversos segmentos do mundo real, nesse trabalho foi utilizado a abordagem SHAP para explicar a saída dos modelos SVM e RNA e assim identificar os atributos mais relevantes para a classificação da sintomatologia depressiva em crianças e adolescentes.

Os algoritmos de extração de conhecimento podem ser classificados em duas categorias básicas: "pedagógica" e "decomposição". A abordagem pedagógica extraem as regras que se relacionam diretamente com as entradas e saídas do classificador. Essa abordagem baseia-se em consultar o modelo de natureza caixa preta para gerar exemplos de saída, e posteriormente aplicar algoritmos padrão para a construção de árvores de decisão. Já

a abordagem por decomposição está inerentemente entrelaçada com a estrutura interna do classificador, buscando explicar a computação individual dos componentes internos (GUIDOTTI et al., 2018a).

Existem na literatura diversos algoritmos para extração de conhecimento, em diversos contextos, em que somente os resultados adquiridos pelo algoritmo de caixa preta não são suficientes, mas a interpretação do conhecimento. Em (GUIDOTTI et al., 2018b), é apresentada uma pesquisa com os principais problemas abordados na literatura em relação a explicação de modelos caixa preta e métodos para abrir e explicar esses modelos. Os autores apresentam diversos métodos para extração de conhecimento em RNA e SVM, como o Trepan (CRAVEN; SHAVLIK, 1996), G-REX (ARBATLI; AKIN, 1997) e Rx-REN (AUGASTA; KATHIRVALAVAKUMAR, 2012) para a RNA e o *SVM+Prototype* (NÚÑEZ; ANGULO; CATALÀ, 2002) para o SVM.

Em (MARTENS et al., 2007), os autores apresentam uma visão geral das seguintes técnicas de extração de regras: *SVM+Prototype*, Fung et al., C4.5, Trepan e G-REX. As técnicas descritas são comparadas usando conjuntos de dados públicos e problemas como diagnóstico médico e pontuação de crédito (*credit scoring*), onde a compreensibilidade, segundo os autores, é um requisito fundamental. Para o conjunto de dados do *Wisconsin Diagnostic Breast Cancer*, a tarefa consiste em classificar as massas mamárias como sendo benignas ou malignas. Os experimentos mostraram uma precisão média de 96,3% alcançado pelo SVM, porém a falta de clareza os torna inúteis para os médicos. Por outro lado, as regras extraídas possibilitam uma melhor compreensão do problema, mantendo um alto desempenho. A técnica proposta por (FUNG; SANDILYA; RAO, 2005) conseguiu um desempenho de 95,2% de precisão. O *SVM+Prototype* (NÚÑEZ; ANGULO; CATALÀ, 2006) também foi aplicado para a mesma base de dados e obteve uma precisão de 96,6%. Os autores concluem que as técnicas de extração de regras de SVM perdem apenas uma pequena porcentagem no desempenho em comparação com SVMs.

Diante do exposto, este trabalho tem como principal objetivo classificar se uma criança ou adolescente tem depressão e descobrir quais características são determinantes para uma correta classificação. Assim, além de ter alta sensibilidade na classificação, o método deve explicitar o padrão utilizado para fazer tais predições. Para isso foi utilizada uma base de dados com informações de 377 crianças e adolescentes brasileiros com idade entre 10 e 16 anos obtida através de uma parceria com o Programa de Pós-Graduação em Psicologia: Cognição e Comportamento da Universidade Federal de Minas Gerais (UFMG).

1.1 Problema

A depressão é um transtorno mental comum e uma das desordens mais incapacitantes em todo o mundo (WHO, 2018). O transtorno de depressão é difícil de ser diagnosticado por haver muitos fatores contribuintes, incluindo comportamento biológicos, sociais e pessoais e seus sintomas podem ser confundidos com outros distúrbios.

Considerando os obstáculos citados para um diagnóstico correto da depressão, buscamos responder ao seguinte questionamento, objeto de discussão deste trabalho: quais são as características mais relevantes para o estudo da depressão em crianças e adolescentes?

1.2 Objetivos

1.2.1 Objetivo geral

O principal objetivo deste trabalho é caracterizar crianças e adolescentes com sintomatologia depressiva através da abordagem de extração de conhecimento denominada SHAP, que possibilita a identificação dos atributos mais relevantes para a classificação. Para a classificação dos dados, e posteriormente a extração de conhecimento através do SHAP, foram utilizados os classificadores SVM e Rede Neural *Multilayer Perceptron*.

1.2.2 Objetivo específico

Como objetivo específico deste trabalho, estão:

- Realizar uma revisão sistemática da literatura para identificar o atual panorama da depressão. A partir desta revisão sistemática foi possível identificar:
  - As características normalmente ligadas à depressão citadas na literatura
  - Os métodos estatísticos e computacionais que estão sendo utilizados para o estudo da depressão
  - As principais bases de dados atualmente disponíveis no contexto de depressão
  - Os principais instrumentos utilizados para a investigação de depressão.
- Levantar as características necessárias para identificar os principais fatores que contribuem para a depressão em crianças e adolescentes.
- Utilizar algoritmos genéticos para seleção das características mais relevantes na identificação das crianças e adolescentes com depressão

1.3 Justificativa

Ainda que o início da depressão possa ocorrer em qualquer idade, a maioria dos adultos que vivem com o transtorno experimentou seu primeiro episódio durante a adolescência (LEWINSOHN; ROHDE; SEELEY, 1998). O final da adolescência é considerado um período vulnerável para a depressão, onde um quarto de todos os jovens experimentará um episódio de transtorno depressivo ao final da adolescência, um número que está aumentando ao longo do tempo (KESSLER; AVENEVOLI; MERIKANGAS, 2001).

O diagnóstico precoce dos transtornos mentais é essencial para a promoção de qualidade de vida e sua associação com as técnicas de aprendizado de máquina vem sendo cada vez mais estudada. Apesar de soluções completamente não-intuitivas, os classificadores de Máquinas de Vetores de Suporte (SVM) apresentam desempenho de generalização superior em comparação a outras técnicas de classificação em diversas áreas de aplicação (BYUN; LEE, 2002). Por ocultar a sua lógica interna para os usuários, o método é considerado de natureza "caixa preta" por gerar modelos incompreensíveis por especialistas humanos (FUNG; SANDILYA; RAO, 2005), o que pode se tornar um obstáculo para a sua aplicação prática, principalmente quando o objetivo é a explicação da classificação. A mesma situação se aplica a Rede Neural, um método da mesma natureza caixa preta e que também apresentou um bom desempenho em testes preliminares.

Portanto, a extração do conhecimento a partir das decisões de classificação dos classificadores SVM e Rede Neural contribuirá para a caracterização da sintomatologia depressiva em crianças e adolescentes, em que profissionais da saúde, familiares e educadores podem intervir mais precocemente no tratamento destes pacientes.

1.4 Organização do trabalho

O Capítulo 2 desta dissertação apresenta o referencial teórico, abordando os principais conceitos relevantes para a compreensão do trabalho. Nesse capítulo serão apresentados as principais características da depressão, além das definições de aprendizado de máquina e extração de conhecimento. Em seguida, no Capítulo 3 é apresentada uma revisão sistemática da literatura, realizada com o intuito de elucidar os principais trabalhos que combinam abordagens computacionais e estatísticas para o estudo da depressão. No Capítulo 4 é apresentada a metodologia necessária para a realização do trabalho, como a descrição e composição da base de dados e apresentação das estratégias de pré-processamento utilizadas, incluindo a descrição do algoritmo genético utilizado na seleção de atributos. No Capítulo 5 são apresentados os resultados e discussões acerca do problema a partir da metodologia proposta. O Capítulo **??** encerra com as considerações finais e trabalhos futuros e apresenta algumas produções acadêmicas oriundas dessa dis-

sertação.

2 REFERENCIAL TEÓRICO

Para um melhor entendimento deste trabalho são apresentados os principais conceitos de depressão e aprendizado de máquina, área da computação que tem sido objeto de muito interesse na comunidade biomédica (SHIMIZU; NAKAYAMA, 2020).

2.1 Prevalência de Transtornos Depressivos

Segundo (RITCHIE; ROSER, 2020), a parcela da população mundial com depressão varia entre 2% e 6%. Em 2017, cerca de 264 milhões de pessoas de todas as idades sofreram com a depressão. A Figura 1 apresenta o número total de pessoas, de todas as idades e em ambos os sexos, com transtornos depressivos por país em todo o mundo. Os números apresentados fornecem uma estimativa da depressão com base em dados médicos, epidemiológicos, pesquisas e modelos de meta-regressão. Nesse cenário, destaca-se a posição do Brasil em relação aos outros países (com $7,22$ milhões de pessoas), ocupando o quarto lugar entre os países com maior número de pessoas com depressão em todo o mundo, ficando atrás apenas da China ($56,36$ milhões), Índia ($45,7$ milhões) e Estados Unidos ($15,5$ milhões).

Figura 1 – Número de pessoas com depressão por país.

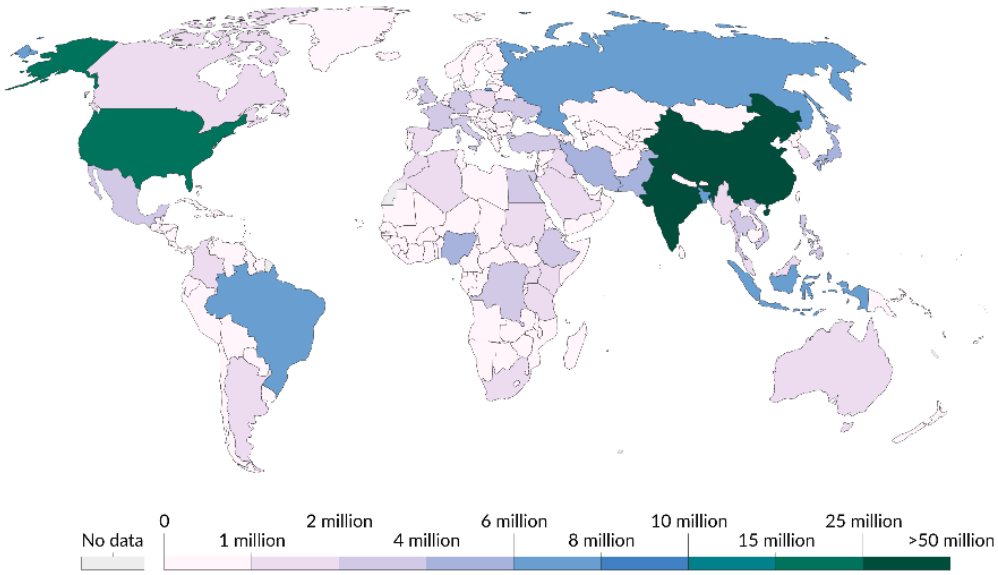

Fonte: Instituto de Métricas e Avaliação em Saúde dos Estados Unidos (RITCHIE; ROSER, 2020)

Já a Figura 2 apresenta o número total de pessoas depressivas no Brasil, de todas as idades e ambos os sexos, ao longo dos anos. É possível observar um aumento no número de casos ao longos dos anos, com uma leve queda entre os anos 2005 e 2010 e um novo aumento no número de pessoas depressivas após esse período de queda.

Figura 2 – Número de pessoas com depressão no Brasil em qualquer idade e sexo.

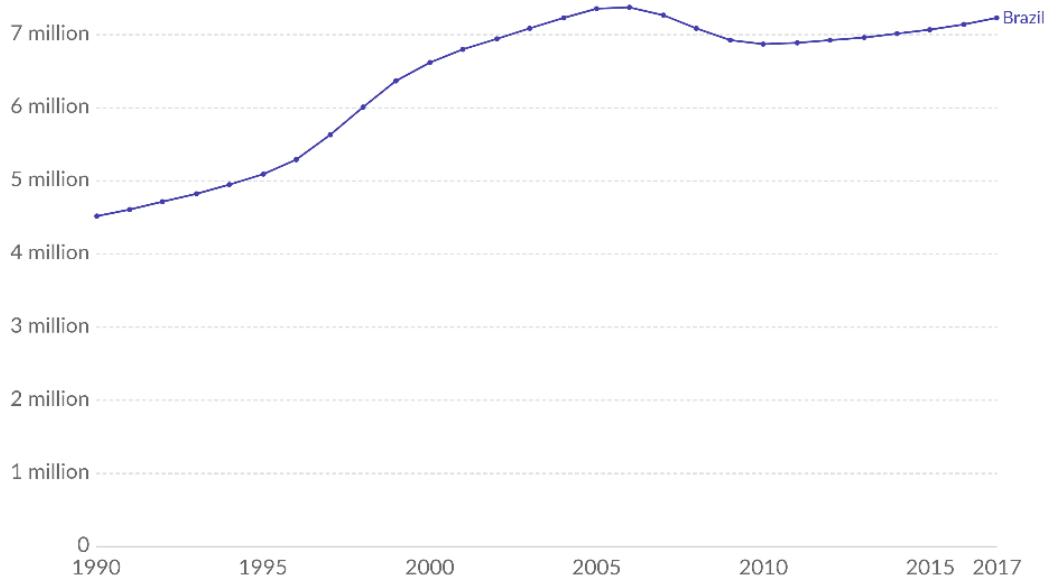

Fonte: Instituto de Métricas e Avaliação em Saúde dos Estados Unidos (RITCHIE; ROSER, 2020)

A Figura 3 apresenta o número total de pessoas com depressão no Brasil diferenciando por sexo. Nessa imagem é possível notar um maior número de indivíduos do sexo feminino. Em 2017 o percentual da população brasileira com depressão era dividida entre $65,95\%$ de mulheres e $34,05\%$ de homens, um número superior aos países com maior número de pessoas com depressão em todo o mundo e maior até do que a média global, que é dividida em $61,1\%$ feminina e $38,9\%$ masculina.

Apesar de o foco do trabalho ser o estudo da depressão em crianças e adolescentes, as Figuras 4 e 5 nos possibilitam uma visualização da situação do Brasil em relação a depressão através do resultado de uma pesquisa nacional de saúde do Instituto Brasileiro de Geografia e Estatística (IBGE) para o ano de 2013 (IBGE, 2020). A Figura 4 apresenta o percentual de pessoas brasileiras de 18 anos ou mais de idade que referem diagnóstico de depressão por um profissional de saúde mental, agrupados por grande região. A região do Brasil com maior percentual de depressão é a região Sul $(12,6\%)$, seguido pelo Sudeste $(8,4\%)$, Centro-Oeste $(7,2\%)$, Nordeste (5%) e Norte $(3,1\%)$.

A Figura 5 apresenta os mesmos dados da pesquisa nacional para o mesmo ano, porém agrupados por estado. Rio Grande do Sul $(13,2\%)$, Santa Catarina $(12,9\%)$ e

Figura 3 – Número total de pessoas de todas as idades com depressão no Brasil, diferenciadas por sexo.

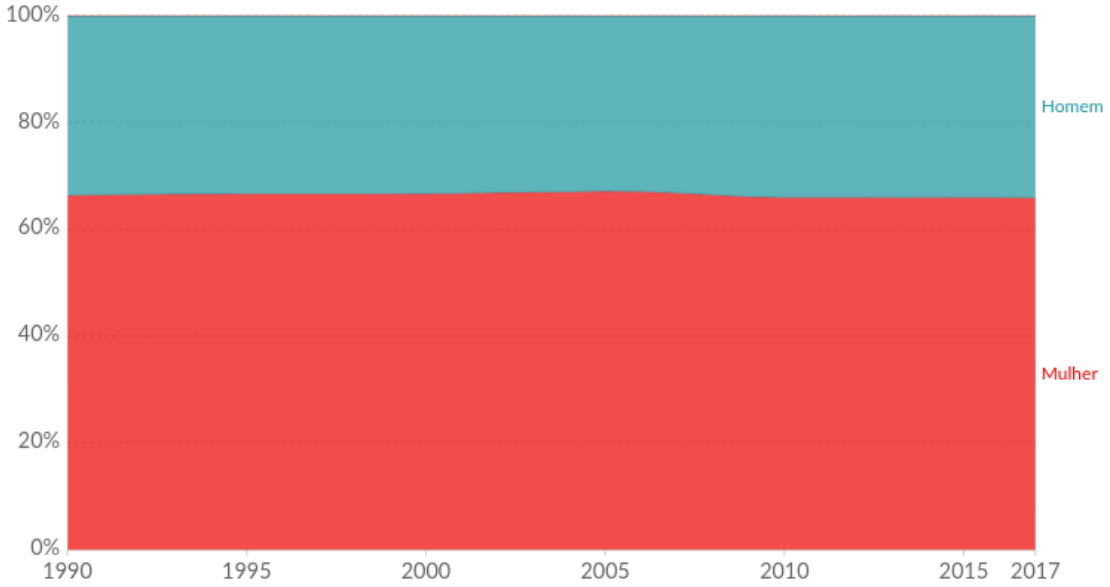

Fonte: Instituto de Métricas e Avaliação em Saúde dos Estados Unidos (RITCHIE; ROSER, 2020)

Figura 4 – Percentual de pessoas brasileiras de 18 anos ou mais de idade que referem diagnóstico de depressão por profissional de saúde mental no ano de 2013 agrupados por região.

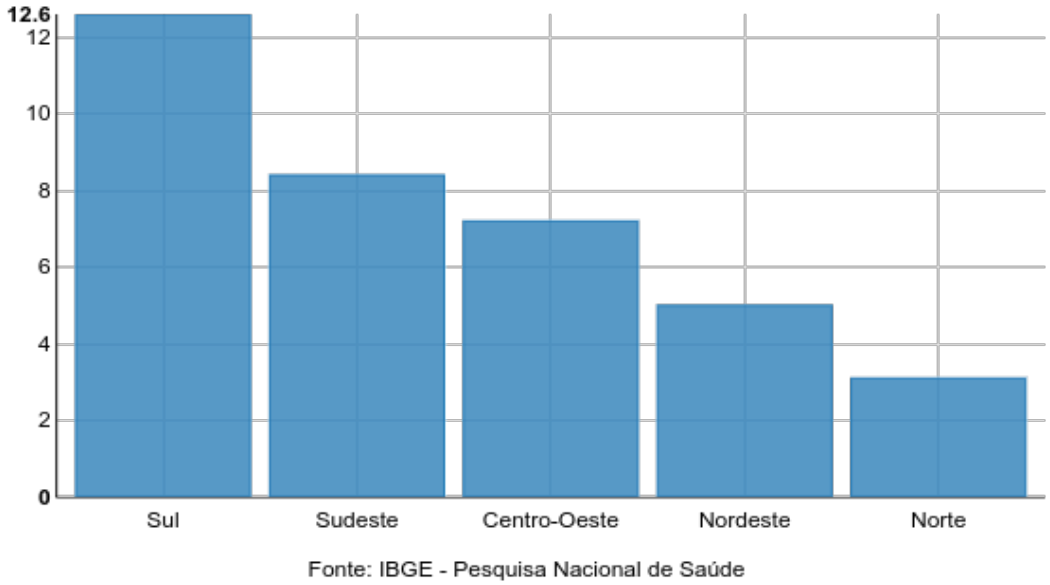

Paraná (11, 7%) liberam como os estados com maior percentual de pessoas com depressão, refletindo as informações apresentadas na Figura 4.

Figura 5 – Percentual de pessoas brasileiras de 18 anos ou mais de idade que referem diagnóstico de depressão por profissional de saúde mental no ano de 2013 agrupadas por estados.

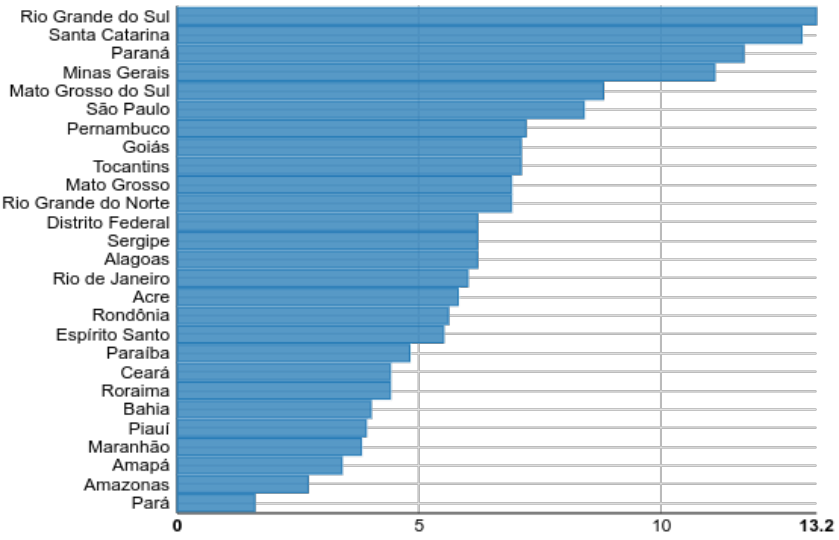

Fonte: IBGE - Pesquisa Nacional de Saúde

2.2 Depressão em Crianças e Adolescentes

O termo depressão, na linguagem corrente, tem sido empregado para designar tanto um estado afetivo normal (a tristeza), quanto um sintoma, uma síndrome e uma (ou várias) doença(s) (PORTO, 1999).

Os sintomas da depressão são diversificados e a doença pode ter relação tanto com fatores genéticos (FLINT; KENDLER, 2014) quanto com fatores biológicos (PANNEKOEK et al., 2014), ambientais (PEYROT et al., 2013), sociais (GUERRA et al., 2016) e comportamentais (PAUNIO et al., 2015), além da associação ou co-ocorrência com outras comorbidades e condições clínicas (MOORE et al., 2012; YUSOF et al., 2016). A depressão é um transtorno psiquiátrico com grande impacto nas conexões sociais, escolares e familiares. Independentemente da forma ou dos sintomas, não é trivial diagnosticar a doença, visto que diversos motivos podem influenciar nas diferentes formas em que o transtorno é apresentado.

No mundo, 10 a 20% das crianças e adolescentes sofrem de transtornos mentais (WHO, 2018). No Brasil, a prevalência de depressão em crianças com menos de 14 anos varia de 0,2% a 7,5% (AVANCI et al., 2012). Os dados são ainda mais alarmantes quando em perspectiva, mostrando que apenas 19,2% das crianças e adolescentes com casos de depressão, vinculadas ao Sistema Único de Saúde (SUS), procuraram ou de fato tiveram algum tratamento em 2014 (COUTINHO MARIA P. L., 2014). Além disso, há o agravante de que jovens sofrendo desse transtorno têm o risco de suicídio aumentado (BIRMAHER

et al., 1996). A Figura 6 apresenta alguns fatos importantes sobre o impacto da depressão em nível global, sendo que cerca de 300 milhões de pessoas em todo o mundo, em sua maioria mulheres, sofrem com a depressão.

Figura 6 – Informações sobre a depressão no mundo

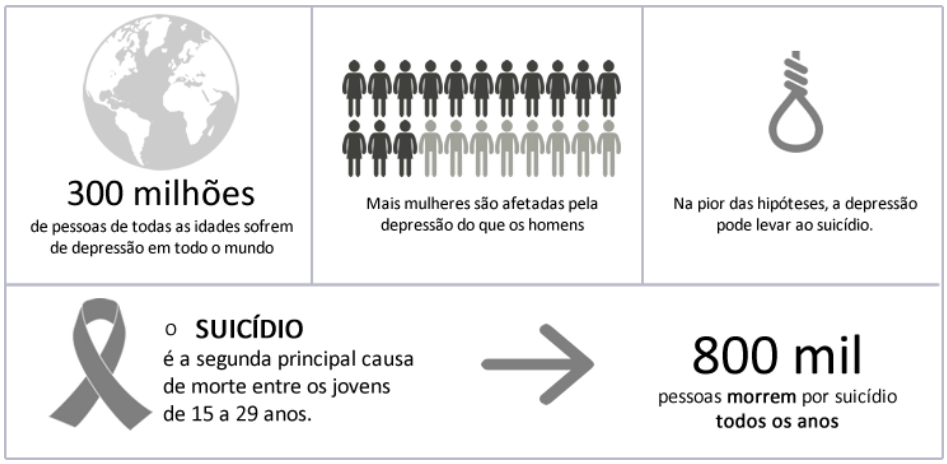

Fonte: Elaborado pelo autor com dados extraídos de (WHO, 2018).

Em 1952, a Associação Americana de Psiquiatria publicou um manual de orientação, em consenso com profissionais da área, denominado *Diagnostic and Statistical Manual of Mental Disorders* (Manual Diagnóstico e Estatístico de Transtornos Mentais, ou simplesmente DSM) para auxiliar no diagnóstico clínico de transtornos mentais, fornecendo diretrizes para diagnósticos mais fáceis e confiáveis (ASSOCIATION et al., 2013). Os critérios apresentados no Quadro 1 foram retirados da versão mais atualizada do manual, a quinta edição (DSM-V), lançada em 2013*.

Segundo o DSM-V, o transtorno depressivo maior é caracterizado pela presença de cinco (ou mais) sintomas apresentados no Quadro 1 por pelo menos duas semanas de duração, e pelo menos um dos sintomas é humor deprimido ou perda de interesse ou prazer (ASSOCIATION et al., 2013). O manual também está totalmente harmonizado com a Classificação Estatística Internacional de Doenças e Problemas Relacionados à Saúde, ou apenas Classificação Internacional de Doenças (CID), o qual é um sistema de codificação da OMS utilizado em diversos países para catalogar diferentes doenças, sintomas, e condições de saúde (SAÚDE, 1994).

Para verificar se os itens destacados sobre depressão no DSM-V são atendidos e realizar corretamente o diagnóstico, diversos instrumentos podem ser utilizados. Alguns instrumentos possuem o formato de questionários, também conhecidos como inventários, e normalmente são direcionados a grupos específicos, para atender as particularidades de cada público alvo. Dentre os instrumentos utilizados, podemos citar o Inventário de

*As versões do DSM-I, II, III, IV e V foram lançadas, respectivamente, em 1952, 1968, 1980, 1994 e 2013 (ASSOCIATION, 2018).

Quadro 1 – Critérios diagnósticos para o Transtorno Depressivo.

1.	Humor deprimido na maior parte do dia.
2.	Acentuada diminuição do interesse ou prazer em todas ou quase todas as atividades na maior parte do dia, quase todos os dias.
3.	Perda ou ganho significativo de peso sem estar fazendo dieta, ou redução ou aumento do apetite quase todos os dias.
4.	Insônia ou hipersonia quase todos os dias.
5.	Agitação ou retardo psicomotor quase todos os dias.
6.	Fadiga ou perda de energia quase todos os dias.
7.	Sentimentos de inutilidade ou culpa excessiva ou inapropriada quase todos os dias.
8.	Capacidade diminuída para pensar ou se concentrar, ou indecisão, quase todos os dias.
9.	Pensamentos recorrentes de morte, ideação suicida.

Fonte: DSM-V (ASSOCIATION et al., 2013)

Depressão de Beck (BDI - *Beck Depression Inventory*) (BECK; STEER; BROWN, 1996), que em sua versão atual é direcionada a pacientes com idade superior a 13 anos, a Escala de Avaliação de Depressão de Hamilton (HAM-D - *Hamilton Rating Scale for Depression*) (HAMILTON, 1960), destinada a população adulta e a Escala de Depressão Geriátrica (GDS - *Geriatric Depression Scale*) (SHEIKH; YESAVAGE, 1986), destinada a pessoas idosas.

O Inventário de Auto-avaliação para Jovens (YSR - *Youth Self-Report*) (ACHENBACH; EDELBROCK, 1987) é um instrumento amplamente utilizado que avalia comportamentos problemáticos em crianças e adolescentes com idade entre 11 e 18 anos. Em sua versão revisada de 2001, o relatório é composto de 112 itens pontuadas usando uma escala de três pontos (0 = ausente, 1 = ocorre às vezes, 2 = ocorre com frequência). As perguntas do questionário são preenchidas pelos jovens para descrever seu próprio comportamento. Se o jovem não puder preencher o formulário, ele poderá ser apresentado oralmente.

Um outro instrumento utilizado para o diagnóstico da depressão em crianças e adolescentes é o Inventário de Depressão Infantil (CDI) (KOVACS, 1992), destinado a crianças e adolescentes com idades entre 7 e 17 anos. O CDI é um questionário amplamente utilizada e com alta confiabilidade. Foi desenvolvido usando como modelo o Inventário de Depressão de Beck (BDI - *Beck Depression Inventory*), destinado a adultos. É composto por 27 itens, e assim como o YSR, os próprios jovens avaliam a si mesmos com base em como se sentem e pensam, com cada pergunta sendo pontuada em uma escala de 0 a 2.

2.3 Mineração de Dados

Mineração de Dados (*Data Mining*) é um ramo da computação que teve início na década de 1980 (AMO, 2004) quando os profissionais das empresas e organizações começaram a se preocupar com o grande volume de dados armazenados. O conceito de Mineração de Dados está se tornando cada vez mais popular como uma ferramenta de descoberta de informações.

Mineração de dados é parte de um processo maior denominado Processo de Descoberta de Conhecimento (*Knowledge Discovery in Database - KDD*). O KDD é um conjunto de técnicas e métodos para preparação, exploração dos dados, interpretação de seus resultados e assimilação dos conhecimentos minerados (GOLDSCHMIDT; PASSOS, 2005).

As etapas do processo de Descoberta de Conhecimento podem ser visualizadas na Figura 7. A primeira etapa, a Seleção, consiste na decisão de quais conjuntos de dados serão utilizados para se obter informações relevantes. A segunda etapa é o Pré-processamento, onde é realizada a limpeza dos dados e a seleção de atributos. Essa etapa consiste no tratamento ou remoção de informações ausentes, errôneas ou inconsistentes que devem ser corrigidas de forma que não comprometam a qualidade dos modelos extraídos ao final do processo de KDD. A terceira etapa, Transformação, analisa os dados obtidos da etapa anterior e os reorganiza para que os algoritmos de aprendizado possam ser aplicados. A quarta etapa é a mineração dos dados, uma das mais importantes etapas do processo. A mineração faz com que os dados selecionados, limpos e formatados em etapas anteriores sejam transformados em informações úteis, ou seja, essa etapa consiste em construir um modelo com base em dados históricos que possa ser aplicado a novos dados visando categorizá-los em classes (HAN; KAMBER, 2006). A última etapa é a de Interpretação, onde as regras indicadas pelo processo anterior são interpretadas e avaliadas, podendo descobrir padrões, relacionamentos e descoberta de novos fatos, que podem ser aplicados em diversos segmentos (FAYYAD et al., 1996).

2.4 Máquina de Vetores de Suporte

A técnica de classificação conhecida como Máquina de Vetores de Suporte (do inglês, *Support Vector Machine*, ou SVM) (CORTES; VAPNIK, 1995) é embasada na Teoria de Aprendizado Estatístico. Essa técnica busca a construção de um hiperplano como superfície de decisão, de forma a maximizar a separação entre as diferentes classes de um problema (HEARST et al., 1998).

Diversos hiperplanos podem ser construídos para separação da classe. Cada hiperplano define uma margem de separação entre as classes do problema, onde os pontos

Figura 7 – Processo KDD.

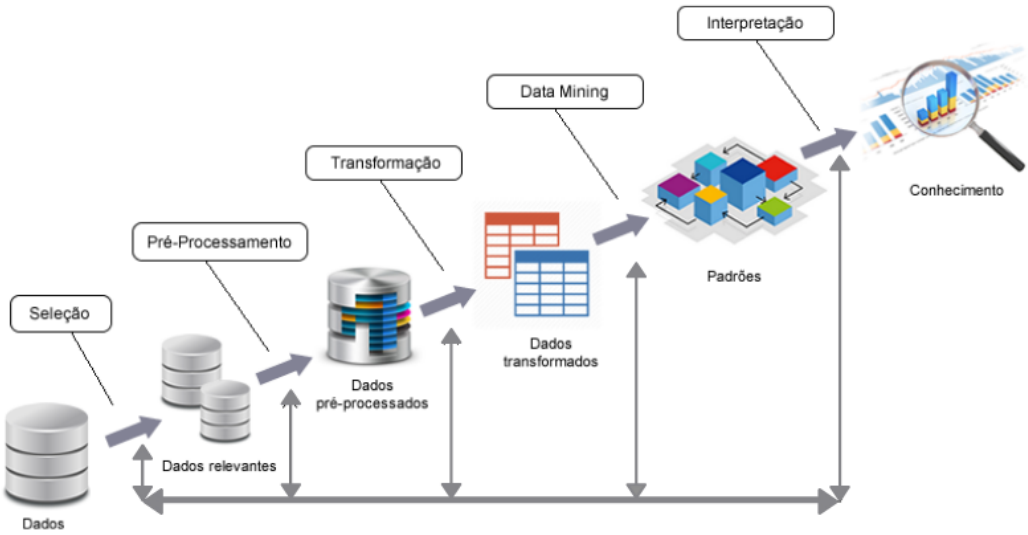

Fonte: Adaptado de (FAYYAD et al., 1996).

situados nos limites são chamados de vetores de suporte, e o meio da margem é nosso hiperplano de separação ótimo. Espera-se que o hiperplano com as margens largas possa ser mais preciso em classificar dados futuros do que o hiperplano com margens estreitas (VAPNIK, 2013). A Figura 8 ilustra a separação de duas classes (quadrado e círculo) através de um hiperplano ótimo.

Figura 8 – Representação de um hiperplano ótimo separando duas classes.

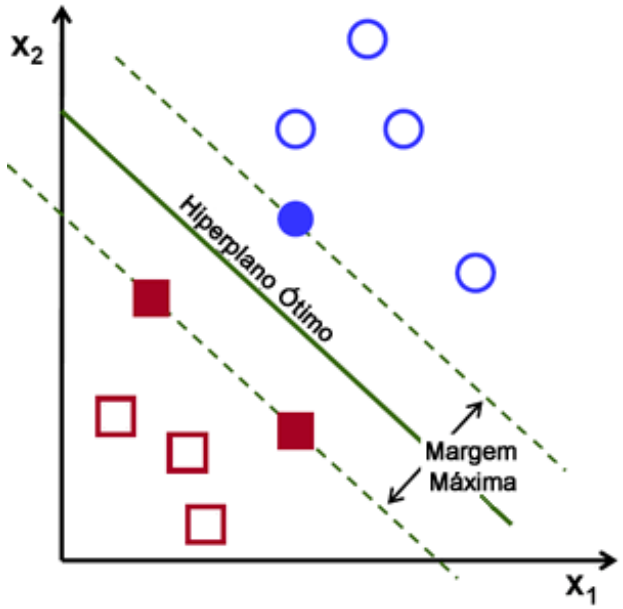

Fonte: Adaptado de (FUNG; MANGASARIAN, 2005).

Considere uma tarefa de classificação binária com o conjunto de dados de treinamento (x_i, y_i), $x_i \in R^m$, $y_i = \{-1, +1\}$ e a função de decisão $f(x) = sign(w \cdot x + b)$.

Uma boa generalização é obtida maximizando a margem entre o hiperplano de separação ($w \cdot x + b = 0$) e os pontos de dados mais próximos no espaço de entrada. As Equações 2.1 e 2.2 representam os hiperplanos de separação no caso de conjuntos de dados separáveis:

$$x_i w + b \geq 1 \text{ para } y_i = +1 \tag{2.1}$$

$$x_i w + b \leq -1 \text{ para } y_i = -1 \tag{2.2}$$

Para o caso linearmente separável, encontrar uma margem de separação máxima $d(d = 2/(\|w\|))$ é um problema de otimização restrito, representado pela Equação 2.3.

$$\text{minimizar } \frac{1}{2} \|w\|^2 \text{ sujeito a } y_i(wx_i + b) \geq 1 \tag{2.3}$$

O classificador SVM apresenta desempenho de generalização superior em comparação a outras técnicas de classificação em diversas áreas de aplicação. No entanto, as suas soluções são completamente não-intuitivas por gerar modelos incompreensíveis, chamados de modelos de "caixa preta", tornando-se difíceis de serem interpretadas por especialistas humanos (FUNG; SANDILYA; RAO, 2005). Para suprir essa limitação, há na literatura técnicas para extração de conhecimento em diferentes métodos caixa preta que ajudam na explicação de suas decisões de classificação (BARAKAT; BRADLEY, 2010).

2.5 Rede Neural Artificial

Uma Rede Neural Artificial (RNA) é um modelo matemático inspirado no cérebro humano, no qual reflete suas habilidades de "aprender" e "generalizar". A RNA é formada por um conjunto de neurônios organizados em camadas, onde cada ligação entre os neurônios poderá transmitir um sinal que será processado por um neurônio receptor e depois transmitido aos próximos neurônios conectados a ele (AGATONOVIC-KUSTRIN; BERESFORD, 2000). Cada neurônio combina um conjunto de valores de entrada para produzir um valor de saída, que por sua vez é passado para outros neurônios nas camadas seguintes até a camada final, onde o resultado é gerado. Ao calcular o resultado, ele é comparado ao resultado verdadeiro, e o erro de cada peso é calculado e atualizado individualmente, levando ao aprendizado da rede. A Figura 9 ilustra uma arquitetura de uma rede neural com três entrada, duas camadas ocultas com quatro neurônios cada uma e uma camada de saída, com um único neurônio.

Figura 9 – Arquitetura de uma rede neural.

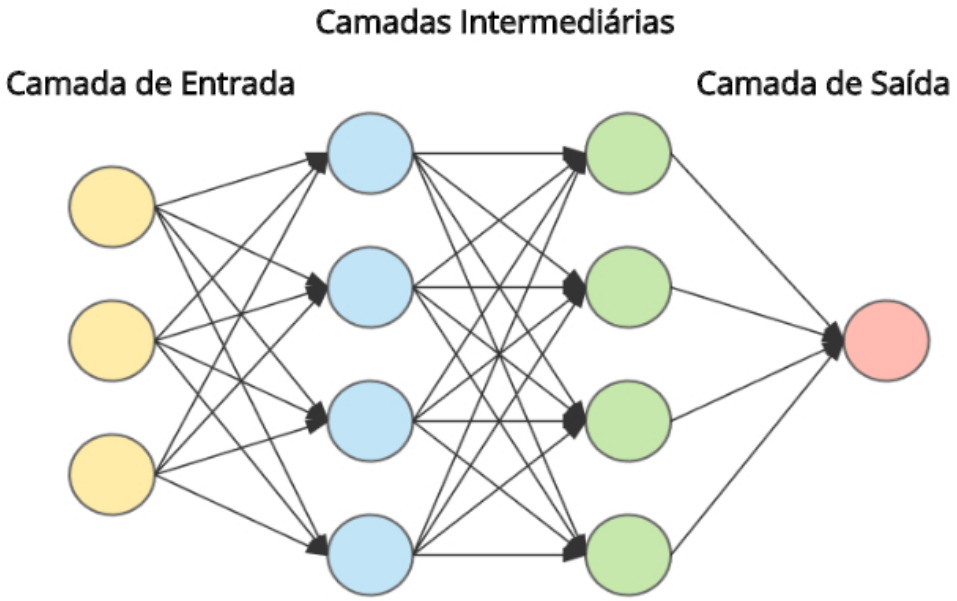

Fonte: (DERTAT, 2017)

2.6 Extração de Conhecimento em Métodos de Caixa Preta

Nos últimos anos, as Máquinas de Vetores de Suporte têm apresentado um bom desempenho em diversas áreas de aplicação, porém a sua incapacidade de explicação do processo pelo qual um resultado de aprendizado foi alcançado pode comprometer a sua aplicação prática, especialmente na área de aplicações médicas. Em (DAVIS; BUCHANAN; SHORTLIFFE, 1977), os autores argumentam que mesmo uma explicação limitada pode influenciar de forma positiva a aceitação do sistema pelo usuário. Algumas técnicas de indução de regras, como a C4.5 de Quinlan (QUINLAN, 1993), constroem modelos bastante compreensíveis, porém muitas vezes perdem consideravelmente em qualidade se comparado ao classificador SVM, por exemplo.

Sendo assim, a visível falta da capacidade explicativa dos métodos de caixa preta e seus desempenhos muitas vezes superiores aos métodos de indução de regras, levou a diversas abordagens com o objetivo de extrair regras que possam fornecer uma explicação de suas decisões. A extração de regras é uma técnica que tenta encontrar uma harmonização entre os dois requisitos, criando um conjunto de regras simples que imita como o modelo de caixa preta toma suas decisões. Um modelo é dito ser de natureza caixa preta por manter sua estrutura interna desconhecida ou não ser levada em consideração em sua análise.

Dado um modelo de caixa preta para um problema de classificação, a extração de conhecimento traduz-se em fornecer um modelo interpretável e transparente que, além de ser capaz de imitar o comportamento da caixa preta, também seja compreensível pelos seres humanos (GUIDOTTI et al., 2018a). O conjunto de conhecimento extraído pode ser modelado, por exemplo, por uma árvore de decisão ou por um conjunto de regras (HUYSMANS et al., 2011a).

Os algoritmos de extração de regras podem ser classificados em duas categorias básicas: "pedagógica" e "decomposição". A abordagem pedagógica extraem as regras que se relacionam diretamente com as entradas e saídas do classificador. Essa abordagem utiliza um classificador treinado como um oráculo para produzir um conjunto de exemplos relacionando as entradas e saídas, e posteriormente aplicar algoritmos padrão para a construção de árvores de decisão, por exemplo (DUENYAS; MARGALIOT, 2015). Já a abordagem por decomposição está intimamente entrelaçada com a estrutura interna do SVM e seu hiperplano construído, buscando explicar a computação individual dos componentes internos (GUIDOTTI et al., 2018a).

2.6.1 Dimensões da Interpretabilidade

Em um contexto de aprendizado de máquina, existem duas dimensões de interpretação: a interpretabilidade Global e a interpretabilidade Local, que podem ser visualizadas na Figura 10.

Figura 10 – Interpretação Global e Local.

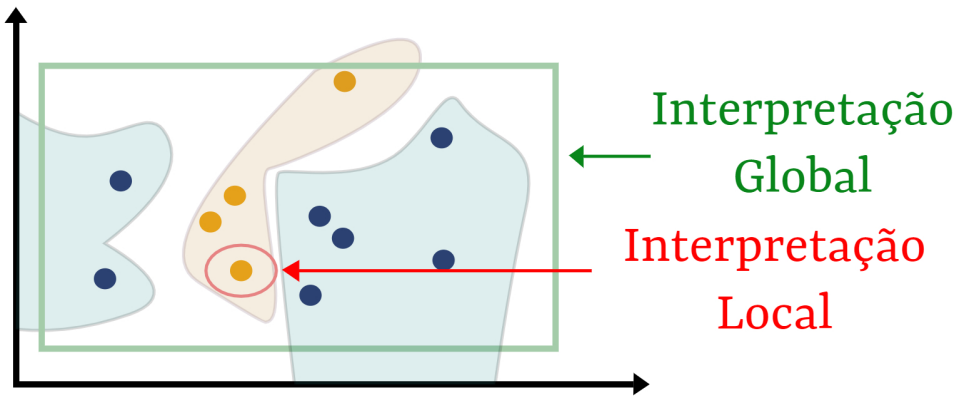

Fonte: (SARKAR, 2018)

Na interpretabilidade Global é possível entender o raciocínio que leva a todos os caminhos possíveis de resultado do modelo, dando foco principal ao entendimento científico e a completa identificação de padrões da decisão (GUIDOTTI et al., 2018b). É tudo sobre a competência de explicar e entender as decisões com base nas condições entre

as variáveis de resposta e as características preditoras da base completa de dados (SARKAR, 2018). Para uma boa interpretação Global, o cientista carece de um conhecimento completo sobre o modelo, conceitos como estrutura, hipóteses, variáveis e constantes.

Já a interpretabilidade Local encaixa-se em uma situação em que é necessário justificar uma decisão específica, ou seja, conhecer a razão para tal escolha do modelo. Nesse caso, o especialista concentra seus recursos para analisar um único ponto de dados e sua região local, em busca de entender as decisões tomadas para essa determinada região, levando a explicações mais precisas do modelo (SARKAR, 2018). É interessante destacar que as duas interpretações podem ser agregadas em busca de uma explicação precisa para uma determinada classificação.

O conceito de interpretabilidade não pode ser confundido com explicabilidade. A interpretabilidade é sobre até que ponto uma causa e efeito podem ser observados dentro de um sistema, ou seja, é a capacidade de observar um modelo e entender o que está acontecendo. Já a explicabilidade, é a extensão onde a lógica interna de um modelo pode ser explicada em termos humanos. A sutil diferença entre esses dois conceitos pode ser resumida da seguinte forma: a interpretabilidade significa poder discernir a lógica sem necessariamente saber o porquê. Já a explicabilidade é ter a capacidade de explicar literalmente as decisões tomadas pelo modelo (GALL, 2018).

2.6.2 Tipos de Abordagens

Segundo (GUIDOTTI et al., 2018b), existem quatro principais abordagens para extração de conhecimento em métodos de caixa preta: *Explicação do Modelo de Caixa Preta* (*Black Box Model Explanation*), *Explicação do Resultado da Caixa Preta* (*Black Box Outcome Explanation*), *Problema de Inspeção da Caixa Preta* (*Black Box Inspection Problem*) e *Problema de Design de Caixa Transparente* (*Transparent Box Design Problem*). Todas estas abordagens têm como objetivo fornecer um modelo preditivo preciso e interpretável.

Para a **Explicação do Modelo de Caixa Preta**, a saída da ferramenta que utiliza essa abordagem, ao receber o algoritmo de caixa preta e o conjunto de dados como entrada, deve ser um modelo preditivo globalmente compreensível, de forma que seu comportamento reproduz a caixa preta de entrada, mas agora, sua lógica de decisão deixa de ser somente interna, passando a ser totalmente visível e explicável para seres humanos. Em outras palavras, é a total transformação de uma caixa preta em uma caixa branca aproximada, como uma árvore de decisão ou um conjunto de regras (HUYSMANS et al., 2011b). Para exemplificar esse tipo de abordagem, pode-se citar o TREPAN (CRAVEN; SHAVLIK, 1995), PALM (KRISHNAN; WU, 2017) e o ALPA (Junqué de Fortuny; Martens, 2015).

A abordagem **Explicação do Resultado da Caixa Preta**, consiste em prover somente a interpretação sobre o resultado. Uma ferramenta dessa abordagem, possui o mesmo funcionamento que a anteriormente apresentada, com exceção de um item: sua dimensão de interpretação. Para este caso, sua saída deve ser a previsão juntamente com uma explicação sobre os motivos dessa previsão gerando um modelo localmente compreensível, ou seja, não é necessário explicar ou interpretar toda a lógica que rege a caixa preta, mas somente as razões para a classificação de uma determinada instância, como um caminho individual de uma árvore de decisão ou uma única regra de associação (FREITAS, 2014). Para esse abordagem, podemos citar o CAM (ZHOU et al., 2015a), LIME (RIBEIRO; SINGH; GUESTRIN, 2016) e Grad-CAM (SELVARAJU et al., 2016).

O **Problema de Inspeção da Caixa Preta** possui um viés diferente das duas abordagens anteriormente apresentadas. Uma ferramenta dessa abordagem também recebe como entrada um algoritmo de caixa preta e uma base de dados, mas dessa vez, sua saída consiste em uma reprodução visual de todo o comportamento do modelo inserido, como um gráfico de dependência parcial (KRAUSE; PERER; NG, 2016) ou uma curva de característica de efeito variável (CORTEZ; EMBRECHTS, 2013). Para essa abordagem, o especialista responsável busca em suas análises entender o por quê do modelo tomar certas decisões e como ele funciona de acordo com suas características, informações que podem ser extraídas graficamente. Para essa abordagem, os seguintes algoritmos podem ser citados: Tree View (THIAGARAJAN et al., 2016), Prospector (KRAUSE; PERER; NG, 2016) e Auditing (ADLER et al., 2016).

A última abordagem chamada de **Problema de Design de Caixa Transparente** consiste basicamente em prover um modelo que tenha uma combinação das duas dimensões da interpretabilidade, *Global* e *Local*, por conta própria, como uma extensa árvore de decisão que possui explicação para cada classificação. Alguns exemplos de algoritmos que utilizam essa abordagem são: CPAR (YIN; HAN, 2003), Rule Set (WANG et al., 2017) e o SHAP (LUNDBERG; LEE, 2017).

2.6.3 Tipos de Explicitação do Conhecimento

Nesta subseção será abordado uma breve descrição de duas das mais importantes formas de saída que a ferramenta de extração de conhecimento pode gerar. Ou seja, como as regras, até então não conhecidas, que estão inseridas dentro dos métodos de caixa preta, se tornam interpretáveis e visíveis para seres humanos.

A primeira forma apresentada é a Árvore de Decisão. As Árvores de Decisão são conhecidas pela sua simplicidade e facilidade de interpretação (QUINLAN, 1993), utilizada tanto para interpretação *Global*, quanto *Local*. Possui estrutura gráfica, e seu formato de árvore hierárquica destaca os atributos mais relevantes daquela determinada

base, favorecendo a análise do conhecimento adquirido.

Por sua vez, as árvores de decisão são compostas de vários nós que significam testes em atributos e nós folha representando um valor de classe (QUINLAN, 1993). Essas duas propriedades em conjunto estabelecem vários caminhos da raiz até o último nível de folhas, sendo que, cada caminho representa uma regra de classificação daquela base de dados. A seleção de atributos para os nós da árvore varia entre os diversos algoritmos de árvores de decisão, sendo determinados de acordo com a distribuição de classes dos exemplos antes e depois da divisão (TAN; STEINBACH; KUMAR, 2005).

O fato de conhecer quais são as regras que determinam o modelo preditivo o torna interpretável para seres humanos e apto para ser utilizado na abertura de um método de caixa preta.

Outra forma conhecida para explicitar o conhecimento são as Regras de Decisão, que consistem em uma representação lógica e textual sobre um modelo ou um resultado. Seu formato mais conhecido são as regras *SE-ENTÃO*, em que a cláusula *SE* são as condições e a cláusula *ENTÃO* as classes, são extraídas pelas Regras de Classificação e podem ser compostas por negações e pelos conectivos.

As próprias Árvores de Decisão podem ser resumidas em Regras de Decisão, entretanto, não possuem as mesmas interpretações. Por conta de seu design textual, as Regras não fornecem informações sobre as relevâncias dos atributos como nas Árvores, sendo necessário que essas informações sejam adicionadas (FREITAS, 2014). Apesar dessa característica causar uma certa dificuldade para o especialista entender o modelo como um todo, permite investigar regras particulares, fazendo com que tenha um entendimento parcial sobre o modelo. Em outras palavras, a interpretação *Local* é favorecida.

2.6.4 Métodos de Extração de Conhecimento

Com a crescente demanda de sistemas precisos de suporte à decisão construídos como modelos caixa preta, onde uma explicação do processo de classificação não é claro para o usuário, a literatura cita diversas abordagens que visam superar essa deficiência (GUIDOTTI et al., 2018a).

O método *SVM+Prototypes*[†] foi proposto por (NÚÑEZ; ANGULO; CATALÀ, 2002) para extração de regras e máquinas de vetores de suporte. Essa abordagem aproveita as informações fornecidas pelos vetores de suporte e funciona da seguinte forma: primeiro determina a função de decisão por meio de um SVM e, em seguida, um algoritmo de agrupamento é utilizado para descobrir um vetor de protótipo para cada classe.

[†]Infelizmente, até a finalização dessa dissertação, o método proposto para extração de regras em SVM não pôde ser encontrado para *download*, não sendo possível utilizá-lo neste trabalho.

Usando métodos geométricos, esses pontos são unidos aos vetores de suporte para definir elipsoides no espaço de entrada que podem ser transformados em regras *se-então*.

Outro método encontrado na literatura é o método ALPA[‡], proposto por (FORTUNY; MARTENS, 2015) como uma técnica de extração de regras baseada no aprendizado ativo. A ideia central na qual o ALPA se baseia é que, para melhorar um conjunto de regras em termos de precisão ou fidelidade, devemos treinar um modelo compreensível (modelo caixa-branca) para imitar a saída de um modelo de caixa-preta mais complexo e com melhor desempenho. Dado um conjunto de treinamento e uma técnica de caixa-preta, apresentando os valores-alvo previstos (classe) do conjunto de treinamento ao algoritmo de caixa-branca em vez dos valores-alvo originais associados ao conjunto de treinamento, podemos melhorar a semelhança entre o método caixa-preta e caixa-branca substancialmente.

O método *Eclectic Rule-Extraction* para SVM, proposto por (BARAKAT; DIEDERICH, 2005)[§] utiliza as informações fornecidas pelos vetores de suporte ao modelo aprendido, que definem o hiperplano de separação e os parâmetros associados a eles. A abordagem lida com a tarefa de extração de regras em três etapas básicas, que procedem da seguinte maneira: 1) *Estágio de aprendizagem*: utiliza os dados de treinamento para treinar o SVM e obter um modelo com métricas aceitáveis; 2) *Geração de regras*: tem como objetivo expressar de forma compreensível os conceitos aprendidos pelo modelo utilizando o conhecimento oferecido pelos vetores de suporte e parâmetros; 3) *Avaliação da qualidade das regras extraídas*: um conjunto de teste (não utilizado no treinamento) é utilizado para validar a qualidade das regras extraídas.

O SHAP (*SHapley Additive exPlanations*) é uma abordagem unificada para interpretar previsões e explicar os resultados de qualquer modelo de aprendizado de máquina. O seu objetivo é explicar a previsão de uma instância x calculando a contribuição de cada atributo na previsão. SHAP conecta a teoria dos jogos à explicação local, para atribuir uma medida de importância a cada atributo, para uma determinada previsão (LUNDBERG; LEE, 2017), com valores maiores indicando uma maior participação de um atributo em uma previsão. O SHAP calcula essa medida de importância do atributo usando os valores de *Shapley*, introduzidos em 1953 por Lloyd Shapley no campo da teoria dos jogos (SHAPLEY, 1953), mas apenas recentemente sendo aplicados nesse contexto.

Os cálculos dos valores SHAP são simples, mas computacionalmente caros. A ideia é treinar novamente o modelo para todos os subconjuntos de atributos $S \subseteq F$, onde F é o conjunto de todos os atributos. Os valores de *Shapley* avaliam a importância de cada

[‡]A obtenção do método só foi possível após contato com os autores por *e-mail*, que disponibilizaram um *plugin* da ferramenta *Weka* (WITTEN et al., 2016).

[§]O método *Eclectic Rule-Extraction* para SVM, proposto por (BARAKAT; DIEDERICH, 2005) também não é disponibilizado para *download*, e até a finalização dessa dissertação, não pôde ser testado.

atributo, representando seu impacto nas previsões do modelo. Para calcular esse impacto, ele compara as previsões de modelos treinados com e sem o atributo. Como o impacto de um atributo também depende de outros atributos incluídos no modelo, as comparações anteriores são feitas para todos os subconjuntos de atributos possíveis e os valores de *Shapley* são uma média ponderada de todas as comparações.

A explicação do valor de *Shapley* é representado como um método de atribuição de atributo aditivo, um modelo linear. SHAP especifica a explicação de acordo com a Equação 2.4.

$$g(z') = \Phi_0 + \sum_{j=1}^{M} \Phi_j z'_j \tag{2.4}$$

onde g é o modelo de explicação, $z' \in \{0,1\}^M$ é o vetor de coalizão, M é o tamanho máximo de coalizão e $\Phi_j \in \mathbb{R}$ é a atribuição do elemento para um elemento j, os valores de *Shapley*. No vetor de coalizão, uma entrada 1 significa que o valor do atributo correspondente é "presente" e que 0 é "ausente". Para calcular os valores de *Shapley*, simulamos que apenas alguns valores de atributo estão sendo reproduzidos ("presentes") e outros não ("ausentes"). A representação como um modelo linear de coalizões é um truque para o cálculo dos Φ's. Para uma instância de interesse x, o vetor de coalizão x' é um vetor de todos os $1s$, ou seja, todos os valores de atributos estão "presentes". A fórmula pode ser simplificada como apresentado na Equação 2.5.

$$g(x') = \Phi_0 + \sum_{j=1}^{M} \Phi_j \tag{2.5}$$

Segundo o autor, o SHAP apresenta um melhor desempenho e interpretabilidade computacional do que outras abordagens (LUNDBERG; LEE, 2017), e afirma ainda que existe apenas uma solução para Φ que satisfaz três propriedades, sendo elas: 1) Precisão local; 2) *Missingness*, e 3) Consistência. Essas propriedades são definidas nas próximas subseções:

2.6.5 Precisão local

Esta propriedade assegura que a saída do modelo de explicação corresponde ao modelo original da previsão que está sendo explicada (Equação 2.6).

$$f(x) = g(x') = \Phi_0 + \sum_{j=1}^{M} \Phi_j x'_j \tag{2.6}$$

2.6.6 Missingness

Aos atributos ausentes não é atribuído qualquer impacto à saída do modelo (Equação 2.7).

$$x'_j = 0 \Rightarrow \Phi_j = 0 \tag{2.7}$$

A falta de informação diz que um atributo ausente recebe uma atribuição de zero. Observe que x'_j refere-se às coalizões, onde um valor de 0 representa a ausência de um valor do atributo. Na notação de coalizão, todos os valores de característica x'_j da instância a ser explicada devem ser '1'. A presença de um 0 significaria que o valor do atributo está ausente para a instância de interesse. Em teoria, um atributo ausente poderia ter um valor *Shapley* arbitrário sem prejudicar a propriedade de precisão local, pois é multiplicada por $x'_j = 0$. Assim, a propriedade *Missingness* impõe que os atributos ausentes obtenham um valor *Shapley* igual a 0.

2.6.7 Consistência

Para quaisquer dois modelos f e f' que satisfaçam à Equação 2.8.

$$f'_x(z') - f'_x(z' \backslash i) \geq f_x(z') - f_x(z' \backslash i). \tag{2.8}$$

isso implica que para todas as entradas $z' \in \{0,1\}^M$, tem-se:

$$\Phi_j(f', x) \geq \Phi_j(f, x) \tag{2.9}$$

Desta forma, a propriedade Consistência diz que, se um modelo for alterado para que a contribuição marginal de um valor de atributo aumente ou permaneça a mesma (independentemente de outros atributos), o valor de *Shapley* também aumentará ou permanecerá a mesma.

A Figura 11 ilustra a abordagem SHAP para explicar a saída de um modelo de aprendizado de máquina. A estrutura, portanto, obtém o modelo gerado por um método de aprendizado de máquina e gera suas medidas de importância de atributos.

A abordagem SHAP foi escolhido para ser utilizado nesse trabalho para extrair conhecimento dos classificadores SVM e RNA, e assim, fornecer uma melhor explicação da classificação das instâncias. A escolha é fundamentada nas afirmações dos autores que apresentam o SHAP como uma abordagem para explicação de qualquer modelo de aprendizado de máquina e com melhor desempenho e interpretabilidade. Outros fatores

Figura 11 – Abordagem SHAP.

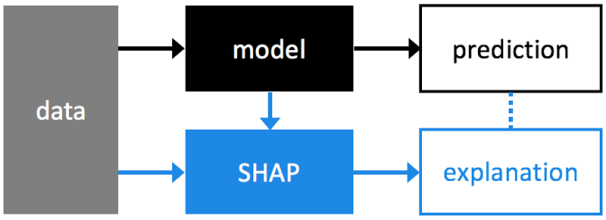

Fonte: Adaptado de (LUNDBERG; LEE, 2017).

que impactaram a escolha do SHAP, é o fato de ser uma ferramenta grátis, de código aberto, de fácil uso e com uma documentação disponível para consulta.

3 REVISÃO SISTEMÁTICA DA LITERATURA

A Revisão Sistemática da Literatura (RSL) é um método que tem como objetivo identificar, avaliar e interpretar um grande conjunto disponível de pesquisas científicas relevantes para determinada área (SANTOS; FERREIRA; PRATES, 2012)(KITCHENHAM et al., 2009). A aplicação desse método proposto permite a sistematização e organização das informações disponibilizadas por cada estudo analisado, além de proporcionar a descrição dos trabalhos e bases de dados utilizadas na pesquisa.

Resumidamente, o que se propõe são as etapas de planejamento, condução e relatório. Os respectivos significados dessas etapas são:

1. Planejamento: identificação das questões de pesquisa e elaboração do protocolo de revisão;
2. Condução: seleção dos estudos, guiada pelo protocolo elaborado na primeira etapa;
3. Relatório: validação e análise dos resultados.

Para elucidar os principais trabalhos que combinam abordagens computacionais e estatísticas e Depressão foi utilizado como base o relatório técnico de (KITCHENHAM et al., 2009), que apresenta procedimentos para a realização de uma Revisão Sistemática da Literatura.

3.0.1 Questões de Pesquisa

Para (KITCHENHAM, 2004), a atividade mais notável durante o protocolo é formular as questões de pesquisa. Pode-se dizer que a pergunta mais adequada é geralmente aquela que é significativa e importante para os profissionais e pesquisadores da área. Tendo em vista essa diretriz, quatro questões de pesquisa (QPs) foram formuladas para a abordagem deste estudo:

- [$QP1$] Quais as características ligadas à depressão são citados na literatura?
- [$QP2$] Quais métodos estatísticos e computacionais são utilizados para o estudo da depressão?
- [$QP3$] Quais são as bases de dados atualmente disponíveis para análise de pessoas com depressão?

- [$QP4$] Quais os tipos de instrumentos são utilizados para a investigação da depressão?

3.0.2 Critério de Seleção/Exclusão

Com o propósito de manter o maior número de trabalhos relevantes, a eliminação foi realizada pela aplicação dos seguintes critérios:

- Artigos de idiomas diferentes de inglês e português foram excluídos;
- Trabalhos duplicados do mesmo estudo foram considerados equivalentes. A versão mais recente foi mantida;
- Livros, tutoriais, editoriais, pôsteres, painéis, transcrições de palestras e mesas redondas, materiais de oficinas e demonstrações e trabalhos de *workshops* foram desconsiderados;
- Artigos que versam sobre o tratamento farmacológico e a análise de seus efeitos, já que esse não é o objetivo desta RSL, foram desconsiderados.

3.0.3 Processo de Pesquisa

A Organização Mundial de Saúde reporta que o número de pessoas com depressão cresceu 18,4% entre os anos de 2005 e 2015 (WORLD HEALTH ORGANIZATION, 2017). Por esta razão, o período de busca foi definido entre 1º de janeiro de 2005 a 2018 (ano corrente da realização da SLR). A escolha das bases de dados incluiu os principais repositórios digitais na área da Computação, como a *Association for Computing Machinery* (ACM), o *Institute of Electrical and Electronics Engineers* (IEEE) e *ScienceDirect*, e outras de áreas relacionadas à saúde, como a *PubMed*. O Quadro 2 apresenta os repositórios digitais pesquisados e as quantidades de artigos mantidos em cada fase de seleção.

Esses repositórios foram escolhidos pois abarcam a maior parte das áreas relacionadas à saúde, como a Biologia, Psicologia e especialidades da Medicina, além de abrangerem áreas como a Computação e Bioinformática.

É sabido que outros locais de busca podem conter publicações relevantes sobre o estudo da depressão, contudo o escopo deve ser delimitado de forma a permitir o aprofundamento nas questões levantadas. Dessa forma, as bases selecionadas representam os principais repositórios de eventos e periódicos, tanto na área computacional, quanto na área biomédica.

Para a pesquisa usando as máquinas de busca dos repositórios selecionados foram utilizados os seguintes termos: *"depression"*, *"depressive disorder"*, *"data mining"*,

Quadro 2 – Bases de dados utilizados para obter os trabalhos para a realização da SLR.

Bases de Dados	Forma de Pesquisa
ACM - Association for Computing Machinery	Busca automática de 2010 a 2017
GEO DataSets - Gene Expression Omnibus DataSets	Busca automática de 2005 a 2017
IEEE - Institute of Electrical and Electronics Engineers	Busca automática de 2008 a 2017
Journal of Affective Disorders	Busca automática de 2005 a 2017
NeuroImage: Clinical	Busca automática de 2005 a 2017
Procedia - Social and Behavioral Sciences	Busca automática de 2005 a 2017
Psychiatry Research	Busca automática de 2005 a 2017
PubMed	Busca automática de 2005 a 2017
PubMed Health	Busca automática de 2005 a 2017

Fonte: Resultado da pesquisa.

"machine learning", *"statistical analysis"*, *"questionnaire"* e *"instrument"*. Estes termos foram combinados de acordo com a sentença lógica: *(depression OR depressive disorder) AND (data mining OR machine learning OR statistical analysis OR (questionnaire AND (machine learning OR statistical analysis OR data mining)) OR (instrument AND (machine learning OR statistical analysis OR data mining)))*.

É importante ressaltar que pelo menos um dos dois termos, *"depression"* ou *"depressive disorder"*, deveriam estar obrigatoriamente no título ou no resumo do artigo. Os termos restantes poderiam estar em qualquer parte do texto.

O protocolo utilizado para realizar a revisão é composto pelas etapas:

- Seleção inicial: aplicação dos critérios de seleção/exclusão (Subseção 3.0.2);
- Eliminação por título;
- Eliminação por resumo;
- Eliminação por leitura diagonal;
- Leitura completa dos artigos não eliminados nas etapas anteriores.

A Tabela 1 apresenta os repositórios digitais pesquisados e as quantidades de artigos mantidos em cada fase de seleção. Cada artigo retornado pelas buscas foi revisado individualmente pelos autores deste trabalho, e a decisão final a respeito da permanência ou não do artigo foi dada pela opinião da maioria dos avaliadores. Foram selecionados somente os artigos que respondem a pelo menos uma das questões de pesquisa. A Tabela 1 apresenta a número de artigos encontrados inicialmente e a quantidade mantida em cada uma das etapas de seleção.

Tabela 1 – Número de artigos mantidos após cada uma das três fases de filtragem da revisão.

Base de Dados	Seleção Inicial	Seleção por Título	Seleção por Resumo	Seleção por Leitura Diagonal
ACM	31	17	15	4
Geo DataSets	5	2	0	0
IEEE	7	4	2	1
PubMed	493	233	68	26
PubMed Health	15	2	0	0
ScienceDirect	232	83	33	7
Total	**783**	**341**	**118**	**38**

Fonte: Resultado da pesquisa.

No Quadro 3 estão os dados dos artigos resultantes da eliminação pela leitura diagonal dos artigos, ou seja, após todas as etapas de seleção da revisão sistemática. São 38 artigos identificados com a letra "A" seguida de um número sequencial de 1 a 38, além de conter o nome do repositório do qual o trabalho foi recuperado e o ano de publicação.

3.0.4 Discussão

Nesta seção são discutidas as questões de pesquisa apresentadas na Subseção 3.0.1, conforme os dados e informações contidos nos 38 artigos selecionados pela revisão.

3.0.4.1 Quais as características ligadas à depressão são citados na literatura?

A depressão é uma doença comum, que afeta negativamente a qualidade de vida do indivíduo, é de difícil diagnóstico por ser decorrente da interação de vários tipos de fatores como os biológicos, psicológicos e sociais (PATEL et al., 2007), dentre outros, sendo facilmente confundida com outros distúrbios.

Para identificar estes fatores, propomos uma taxonomia dos inúmeros aspectos relacionados à depressão. A taxonomia, apresentada na Figura 12, consiste em quatro amplas dimensões: 1) Comorbidades, 2) Fatores de risco, 3) Fases da depressão identificadas e 4) Principais sintomas. Além disso, cada uma destas quatro categorias foi subdividida em aspectos mais específicos em diferentes níveis de granularidade.

Ao observar a Figura 12, fica nítida a complexidade da interação entre os fatores que caracterizam a depressão, seja pela quantidade de fatores, seja pelas subdivisões que abarcam áreas distintas, mas relacionadas de alguma forma: psicológicos e comportamentais, neurobiológicos ou relacionados à saúde, geográficos, sócio-econômicos e demográficos ou ainda pelos fatores em si. Fatores aparentemente não relacionados como fumar, número

Quadro 3 – Artigos selecionados pela pesquisa

ID	Source	Title	Year
A1	ACM	Classification of the most Significant Psychological SymptWHO in Mental Patients with Depression using Bayesian Network	2015
A2	ACM	Decision Tree Based Depression Classification from Audio Video and Language Information	2016
A3	ACM	Diagnosis of depression by behavioural signals	2013
A4	ACM	A Data Mining Approach for Prediction of Students' Depression Using Logistic Regression And Artificial Neural Network	2018
A5	IEEE	Artificial Intelligent System for Automatic Depression Level Analysis Through Visual and Vocal Expressions	2018
A6	PubMed	Analyzing depression tendency of web posts using an event-driven depression tendency warning model	2016
A7	PubMed	Antenatal depression: Prevalence and risk factors in a hospital based Turkish sample	2013
A8	PubMed	Association between vitamin b12 levels and melancholic depressive symptWHO: a Finnish population-based study	2013
A9	PubMed	Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal	2013
A10	PubMed	Clinical characteristics associated with different strengths of loudness dependence of auditory evoked potentials (LDAEP) in major depressive disorder	2012
A11	PubMed	Development and validation of a patient-report measure of fatigue associated with depression	2011
A12	PubMed	Fusing data mining, machine learning and traditional statistics to detect biomarkers associated with depression	2016
A13	PubMed	Higher Healthy Eating Index-2005 Scores Associated with Reduced SymptWHO of Depression in an Urban Population: Findings from the Healthy Aging in Neighborhoods of Diversity Across the Life Span (HANDLS) Study	2010
A14	PubMed	Identifying Patients with Depression Using Free-text Clinical Documents	2015
A15	PubMed	Increased Cortical-Limbic Anatomical Network Connectivity in Major Depression Revealed by Diffusion Tensor Imaging	2012
A16	PubMed	Insomnia and the risk of depression: A meta-analysis of prospective cohort studies	2016
A17	PubMed	Machine learning approaches for integrating clinical and imaging features in late-life depression classification and response prediction	2015
A18	PubMed	Machine learning classification with confidence: Application of transductive conformal predictors to MRI-based diagnostic and prognostic markers in depression	2011
A19	PubMed	Plasma biomarkers of depressive symptWHO in older adults	2012
A20	PubMed	Prevalence and risk factors of depression among community dwelling elderly	2014
A21	PubMed	Prevalence of depression and associated risk factors among the elderly in urban and rural field practice areas of a tertiary care institution in Ludhiana	2015
A22	PubMed	Risk factors for depressive symptWHO during pregnancy	2011
A23	PubMed	Sintomas depressivos na gestação: Influência dos aspectos social, comportamental, psicológico e obstétrico	2016
A24	PubMed	Text mining for identifying topics in the literatures about adolescent substance use and depression	2016
A25	PubMed	The association between serum 25-hydroxyvitamin D concentrations and depressive symptWHO in Korean adults: findings from the fifth Korea National Health and Nutrition Examination Survey 2010.	2014
A26	PubMed	The association between workplace bullying and depressive symptWHO: The role of the perpetrator	2016
A27	PubMed	Unsupervised classification of major depression using functional connectivity MRI	2014
A28	PubMed	Using a data mining approach to discover behavior correlates of chronic disease: A case study of depression	2014
A29	PubMed	Predicting Depression Among Community Residing Older Adults: A Use of Machine Learning Approch	2018
A30	PubMed	A machine learning framework involving EEG-based functional connectivity to diagnose major depressive disorder (MDD)	2018
A31	PubMed	Depression and associated variables in people over 50 years in Spain	2018
A32	Science Direct	Childhood abuse in late-life depression	2013
A33	Science Direct	Development and validation of prediction algorithms for major depressive episode in the general population	2013
A34	Science Direct	Distinguishing symptom dimensions of depression and anxiety: An integrative approach	2012
A35	Science Direct	Negative perceptions of ageing predict the onset and persistence of depression and anxiety: Findings from a prospective analysis of the Irish Longitudinal Study on Ageing (TILDA)	2016
A36	Science Direct	Poor sleep predicts symptWHO of depression and disability retirement due to depression	2015
A37	Science Direct	Reference values for major depression questionnaires: The Leiden Routine Outcome Monitoring Study	2013
A38	Science Direct	Studying depression using imaging and machine learning methods	2016

Fonte: Resultado da pesquisa.

Figura 12 – Fatores relacionados à depressão.

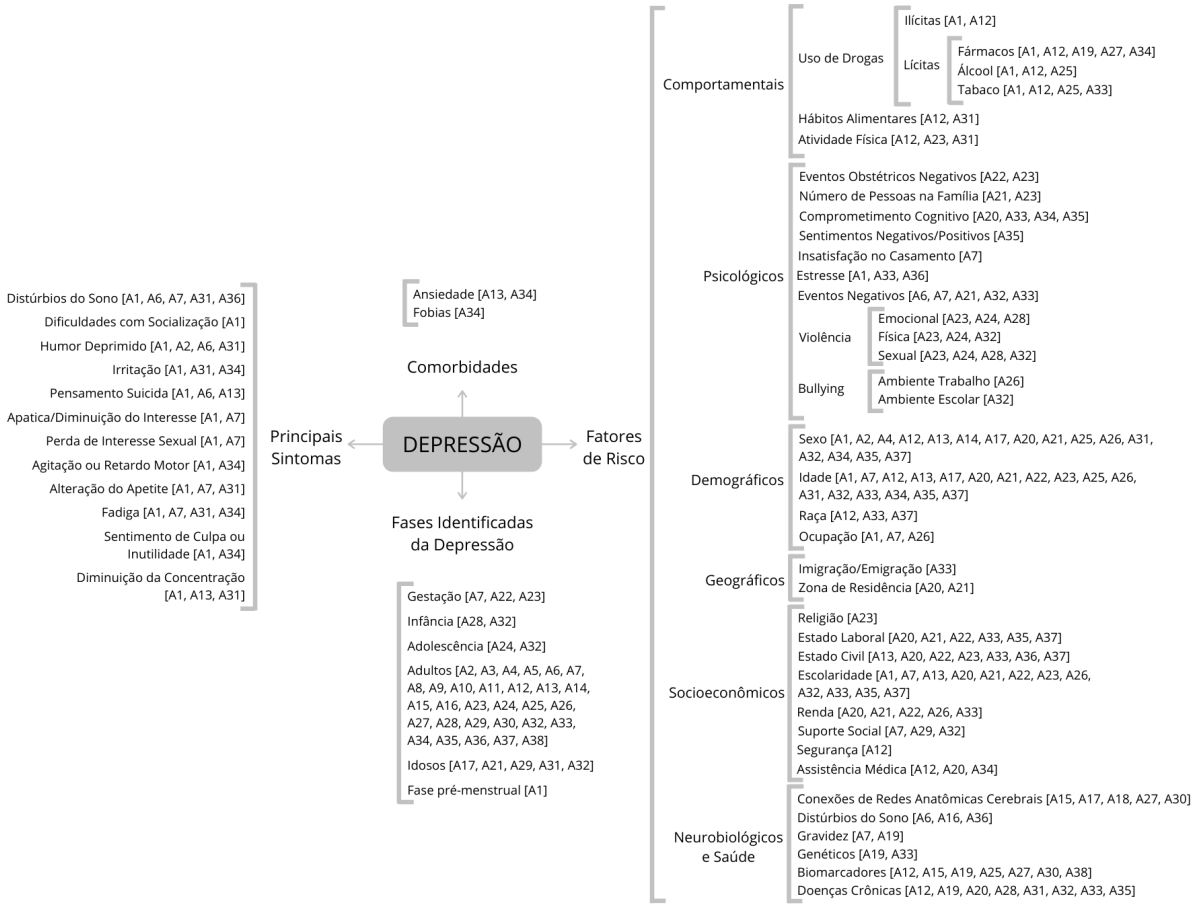

Fonte: Elaborado pelo autor com dados extraídos da pesquisa.

de pessoas na família e local em que reside podem, conjuntamente ou não, desencadear o processo que leva à depressão. Tal classificação aponta para a dificuldade inerente à tarefas de diagnóstico e de predição da depressão.

Existe uma conexão entre os fatores de risco, comorbidades, principais sintomas e fases etárias/fisiológicas pesquisadas em relação à depressão (Figura 12). Nota-se uma prevalência por pesquisas em adultos e/ou pessoas com doenças crônicas em detrimento das outras faixas etárias.

Os fatores de risco podem ser subdivididos em seis subgrupos principais: comportamentais, psicológicos, demográficos, geográficos, socioeconômicos, neurobiológicos e de saúde em geral. Quanto às perguntas de cunho demográfico e socioeconômico há o predomínio de questionamentos em relação à idade, sexo e escolaridade. Tais fatores podem influenciar diretamente no diagnóstico do transtorno já que, por exemplo, sabe-se que mulheres tendem a ter mais depressão que homens (BECK; ALFORD, 2011)(SILVA et

al., 2014).

Com relação aos sintomas mais frequentes na depressão, distúrbios do sono, humor deprimido e fadiga foram os mais recorrentes nos trabalhos avaliados. Tais sintomas podem ser facilmente estigmatizados; isto é, as pessoas que convivem com o indivíduo com depressão podem confundir com preguiça e falta de interesse e isso, por sua vez, imputa a culpa desses sintomas ao próprio paciente. Esse tipo de estigma tem suas raízes na própria construção da definição do termo "depressão" que, por séculos, não era compreendido como um transtorno que dependia de cuidados próprios da medicina, mas sim, como algo a ser entendido por meio de alguma divindade (QUEVEDO; NARDI; SILVA, 2018).

Ter conhecimento e compreender os amplos aspectos interligados e apresentados por essa taxonomia auxilia no entendimento da depressão de forma holística. Tratamentos que desconsideram a abrangência desse transtorno podem estar fadados ao fracasso. Portanto, o desafio é atuar em diferentes âmbitos para potencializar a melhoria da qualidade de vida da pessoa com depressão.

3.0.4.2 Quais métodos estatísticos e computacionais são utilizados para o estudo da depressão?

Em uma análise preliminar, foi observado que abordagens baseadas em Machine Learning e Estatística se sobressaíam no contexto de depressão. Assim, o nosso objetivo foi avaliar que técnicas e algoritmos pertencentes a essas abordagens estavam sendo utilizados no contexto de depressão. O Quadro 4 apresenta os principais métodos utilizados no contexto avaliado. Nota-se que a maioria dos trabalhos no contexto de depressão utilizaram SVM, árvore de decisão e regressão logística.

Patel, Khalaf e Aizenstein (2016a) apresentam uma pesquisa de trabalhos anteriores que se concentram no estudo da depressão e utilizam características relacionadas às imagens de ressonância magnética para estimarem modelos de predição para depressão. Dos quinze trabalhos levantados pelos autores, em quatorze utilizou-se máquinas de vetor de suporte (SVM, do inglês *Support Vector Machines*).

Galiatsatos et al. (2015) utilizam Redes bayesianas para encontrar um modelo ótimo de fatores psicológicos que levassem aos pacientes do estudo a terem pensamentos de morte ou suicídio, com o intuito de alcançar de forma mais ágil o tratamento adequado. Ainda segundo os autores, os resultados desses experimentos estão de acordo com a opinião de especialistas de que os fatores mais significativos que afetam os pacientes mentais com depressão a terem pensamentos de morte ou suicídio são alteração do humor, perda de interesse ou prazer, indignidade/culpa, morar na zona urbana e diminuição da capacidade de concentração.

Quadro 4 – Principais métodos computacionais utilizados no contexto da depressão.

Método	Referência
Máquinas de Vetores de Suporte (SVM)	[A15] [A17] [A18] [A30]
Random Forests	[A19]
Rede Neural Artificial	[A4] [A5]
Redes Bayesianas	[A1] [A30]
Árvore de Decisão	[A2] [A10] [A14] [A17] [A28]
Algoritmo Genético	[A9]
Algoritmo de Agrupamento	[A24] [A27]
Chi-quadrado	[A7] [A8] [A21]
Teste de Fisher	[A7]
Teste T de Student	[A8] [A15]
Lógica Fuzzy	[A1]
Análise Fatorial Exploratória	[A11] [A34]
Regressão Logística	[A3] [A4] [A7] [A8] [A9] [A10] [A12] [A14] [A20] [A21] [A22] [A25] [A29] [A30] [A31] [A32] [A33] [A35] [A36]

Fonte: Resultado da pesquisa.

Em (YANG et al., 2016), os autores propõem a utilização de algoritmos de árvore de decisão para a classificação de pessoas com depressão. A árvore de decisão é construída de acordo com a pontuação do PHQ-8 (KROENKE et al., 2009) e das características dos participantes, obtidas por meio da análise dos arquivos de transcrição das consultas. Os resultados mostram que o modelo utilizado obteve respostas muito promissoras, atingindo uma pontuação F1-score de 0.571 para a classe deprimida e 0.877 para a classe não deprimida.

Patel et al. (2015) utilizaram vários métodos de aprendizado de máquina com entradas de imagens multimodais e recursos baseados em rede para estimar modelos de previsão para o diagnóstico de depressão tardia e resposta ao tratamento. Seus dados demográficos e de habilidades cognitivas foram registrados e as características cerebrais foram adquiridas usando pré-tratamento por ressonância magnética multimodal. Métodos de aprendizado linear e não linear foram testados e as árvores de decisão estimaram os modelos de previsão mais precisos para o diagnóstico de depressão tardia (precisão de 87.27%) e resposta ao tratamento (precisão de 89.47%). O modelo de diagnóstico incluiu medidas de idade, escore do exame do estado mental e imagem estrutural. Os autores concluem que combinações de imagens e medidas sem imagens podem ajudar a prever melhor o diagnóstico da depressão tardia e a resposta ao tratamento. Eles ainda acrescentam que esses achados podem ajudar a entender melhor a depressão tardia e identificar etapas preliminares para o tratamento personalizado da depressão tardia.

Tung e Lu (2016) utilizam mineração de texto para analisar e prever a tendência de depressão de postagens na web. Os autores propõem um método de extração de eventos para retirar automaticamente termos de eventos negativos. Além disso, também é proposto um modelo de aviso de tendência à depressão para prever a propensão à depressão de blogueiros da Web ou autores de publicações, analisando seus artigos publicados. O modelo proposto obtém um *recall* e *F-measure* de 0.668 e 0.624, respectivamente. Os autores concluem que o modelo desenvolvido pode ajudar os médicos a diagnosticarem e até rastrear a depressão dos autores de postagens na Web com mais eficiência.

Em (HOSSEINIFARD; MORADI; ROSTAMI, 2013) os autores utilizam a análise não linear do sinal de EEG para discriminar pacientes com depressão e controles normais. O EEG é um exame médico usado para medir as atividades elétricas do cérebro e avaliar distúrbios cerebrais. Para discriminar os dois grupos, k-NN, análise discriminante linear e regressão logística foram usados. Em todas as experiências, o algoritmo genético é empregado para selecionar as características mais importantes. A técnica proposta é comparada e contrastada com os outros métodos relatados e é demonstrado que, combinando recursos não lineares, o desempenho é aprimorado. Uma precisão de classificação de 90% é alcançada por todos os métodos não lineares e pelo classificador de Regressão Logística. Os autores concluem que a análise não linear do EEG pode ser um método útil para discriminar pacientes deprimidos e indivíduos normais e sugerem que essa análise possa ser uma ferramenta complementar para auxiliar psiquiatras no diagnóstico de pacientes deprimidos.

Em (YANIKKEREM et al., 2013), o teste Qui-quadrado e o teste de Fisher foram utilizados na identificação da relação entre variáveis sócio-demográficas de mulheres grávidas e a pontuação medida por um questionário auto-avaliativo que determina a severidade da depressão. Os autores identificaram que baixo nível de escolaridade, gravidez não planejada, falta de apoio social e sintomas físicos relacionados à gravidez foram os fatores de risco mais importantes para determinar a depressão pré-natal.

Em (MIN et al., 2012), o teste-t de *Student* e o teste do Qui-quadrado foram utilizados para validar uma medida projetada para avaliar a fadiga relacionada à depressão e o seu impacto. Entre os pesquisadores há um interesse no tratamento de sintomas residuais específicos, como a fadiga, e não há medida disponível que forneça uma avaliação detalhada dessa relação. Já em (FANG et al., 2012), o teste-t de *Student* foi utilizado para investigar relações entre fatores clínicos e a depressão. Seus resultados sugerem que a força do *"Loudness Dependence of Auditory Evoked Potentials"* (LDAEP), medida não-invasiva eletroencefalográfica que tem sido notada por suas possíveis implicações clínicas na depressão, pode ser influenciada pelo sexo, tabagismo, estado civil, idade e gravidade corrente da depressão.

Sengupta e Benjamin (2015) realizaram regressão logística para construir um modelo para estimar a prevalência de depressão e identificar os fatores de risco associados à população idosa. Os autores identificaram que ter residência urbana, ser do sexo feminino, idade avançada, morar sozinho, pobreza e comprometimento funcional e cognitivo são fortes preditores para a depressão.

Em (HOSSEINIFARD; MORADI; ROSTAMI, 2013), a regressão logística foi utilizada para examinar a associação entre níveis de vitamina D e sintomas depressivos. Foi identificado que indivíduos com sintomas depressivos apresentaram menores níveis de vitamina D do que os indivíduos não depressivos. Estes autores também avaliaram as associações entre sintomas depressivos e vários fatores socio-demográficos. Os autores identificaram que mulheres, usuários com problemas alcoólicos, fumantes e sujeitos que sofreram perda de peso são mais propensos a terem sintomas depressivos.

Chung et al. (2014) também utilizaram a regressão logística para avaliar os níveis de vitamina B12 em indivíduos com sintomas depressivos melancólicos e não melancólicos, e concluíram que o nível de vitamina B12 foi associado apenas com sintomas depressivos melancólicos.

3.0.4.3 Quais são as bases de dados atualmente disponíveis para análise de pessoas com depressão?

Com relação às bases de dados utilizadas nos trabalhos levantados, diversos artigos utilizam em seus experimentos dados obtidos através de registros médicos de pacientes em clínicas e hospitais (MATZA et al., 2011) (KOLEVA et al., 2011) (FANG et al., 2012) (MIN et al., 2012) (YANIKKEREM et al., 2013) (HOSSEINIFARD; MORADI; ROSTAMI, 2013) (ZENG et al., 2014) (MORAES; CAMPOS; AVELINO, 2016), porém nenhum desses dados são disponibilizados publicamente.

Em (SUNMOO; BASIRAH et al., 2014), os autores utilizam o conjunto de dados do *The Behavioral Risk Factor Surveillance System* (BRFSS), um sistema norte-americano de pesquisas telefônicas relacionadas à saúde. O objetivo do BRFSS é coletar dados específicos sobre comportamentos de risco à saúde, doenças e condições crônicas, acesso a serviços de saúde e uso de serviços de saúde preventivos relacionados às principais causas de morte e incapacidade nos Estados Unidos. Os dados de pesquisa mais recente do BRFSS em 2017 contêm 450.016 registros e 358 atributos. Os fatores avaliados pelo BRFSS em 2017 incluíram estado de saúde, dias saudáveis, qualidade de vida, acesso a serviços de saúde, exercícios físicos, sono inadequado, condições crônicas de saúde, saúde bucal, tabagismo, cigarros eletrônicos, consumo de álcool, imunização, quedas, uso de cinto de segurança, conhecimento sobre HIV/AIDS, entre outros.

Em (YANG et al., 2016), os autores utilizam o banco de dados *Distress Analysis*

Interview Corpus - Wizard of Oz (DAIC-WOZ), no qual são disponibilizados entrevistas clínicas destinadas a apoiar o diagnóstico de transtornos psicológicos, como ansiedade e depressão. Os dados coletados incluem gravações de áudio e vídeo e respostas a questionários em que foram transcritas e registradas uma variedade de características verbais e não verbais. Essa base inclui 189 sessões de interações que variam entre 7-33 minutos (com uma média de 16 minutos). Cada sessão inclui transcrição da interação, arquivos de áudio dos participantes e características faciais.

Dipnall et al. (2016) utilizaram dados do *National Health and Nutrition Examination Survey* (NHANES), um programa de estudo transversal que combina entrevistas e exames físicos para avaliar a saúde e o estado nutricional de adultos e crianças nos Estados Unidos. Neste trabalho, os autores identificaram três biomarcadores associados à depressão de um conjunto inicial de 67: 1) largura de distribuição de glóbulos vermelhos, 2) glicose sérica, e 3) bilirrubina total. Essa associação entre a depressão e os três biomarcadores é amplamente citada na literatura (MAES et al., 2011) (MILLER; MALETIC; RAISON, 2009) (STEWART et al., 2009) (WINOKUR et al., 1988).

Já em (CHUNG et al., 2014), os autores utilizaram uma versão coreana desse mesmo estudo, o *Korea National Health and Nutrition Examination Survey* (KNHANES). O KNHANES é um estudo transversal realizado pela Divisão de Saúde e Bem-Estar Nacional da Coreia do Sul e é composto de três seções diferentes: 1) uma entrevista de saúde, 2) um exame de saúde e 3) uma pesquisa de nutrição. Os dados de saúde psicológica foram obtidos a partir de um questionário de saúde mental, auto-relatado, sob a supervisão de um investigador.

Wang et al. (2013) realizaram as análises baseadas nos dados disponibilizados pelo *National Population Health Survey* (NPHS). O NPHS é uma pesquisa longitudinal realizada a cada dois anos no Canadá desde 1994/1995. Os três primeiros ciclos da pesquisa (1994/1995, 1996/1997 e 1998/1999) foram transversais e longitudinais. A partir do ciclo 4 (2000/2001), a pesquisa tornou-se estritamente longitudinal, ou seja, coleta de informações de saúde e fatores que podem influenciá-la dos mesmos indivíduos em cada ciclo (CATLIN; WILL, 1992). A amostra longitudinal do NPHS é composta por 17.276 pessoas e não é renovada ao longo do tempo.

No Quadro 5 são apresentadas informações que caracterizam as bases mencionadas, além do endereço web de cada base para maiores informações. As bases citadas são identificadas pela sigla.

Quadro 5 – Bases de dados disponíveis sobre depressão

Abreviação	Localização	Tamanho	Ano	Long.	URL
BRFSS	Estados Unidos	450016	2017	Não	https://www.cdc.gov/brfss/data_documentation/index.htm
DAIC-WOZ	Estados Unidos	189	2017	Não	http://dcapswoz.ict.usc.edu
NHANES	Estados Unidos	9544	2015-2016	Não	https://www.cdc.gov/nchs/nhanes/index.htm
KNHANES	Coréia do Sul	8518	2011	Não	https://knhanes.cdc.go.kr/knhanes/intro.html
NPHS	Canadá	17276	2010-2011	Sim	https://www.statcan.gc.ca/eng/survey/household/3225

Fonte: Resultado da pesquisa.

3.0.4.4 Quais os tipos de instrumentos são utilizados para a investigação da depressão?

A última pergunta de pesquisa deste trabalho investigou quais os instrumentos são normalmente utilizados no contexto de depressão e quais as suas principais características.

Observou-se que a maioria dos estudos utilizam com mais frequência os seguintes questionários: Escala de Avaliação de Depressão de Hamilton (HAM-D) (MIN et al., 2012) (FANG et al., 2012) (PATEL et al., 2015) (PATEL; KHALAF; AIZENSTEIN, 2016b) (ZENG et al., 2014), Questionário de Saúde do Paciente (PHQ) (YANG et al., 2016) (MATZA et al., 2011) (TUNG; LU, 2016) (DIPNALL et al., 2016) (ZHOU et al., 2015b) e o Inventário de Depressão de Beck (BDI) (TUNG; LU, 2016) (YANIKKEREM et al., 2013) (SEPPÄLÄ et al., 2013) (HOSSEINIFARD; MORADI; ROSTAMI, 2013) (CUMMINS et al., 2013)(PATEL; KHALAF; AIZENSTEIN, 2016b). No entanto, outros instrumentos tais como o *Geriatric Depression Scale* (GDS) (SHEIKH; YESAVAGE, 1986) e o *Major Depression Inventory* (MDI) (BECH et al., 2001) também são utilizados.

O HAM-D, publicada originalmente em 1960 por Max Hamilton (HAMILTON, 1960) para ser utilizada exclusivamente em pacientes já diagnosticados com depressão, é um questionário projetado para adultos e é utilizado para fornecer uma indicação de depressão, além de servir como um guia para avaliar a recuperação dos usuários (HEDLUND; VIEWEG, 1979).

O PHQ é um questionário de múltipla escolha de auto-avaliação utilizado como ferramenta de triagem e diagnóstico para transtornos de saúde mental, como a depressão (SPITZER et al., 1999). Caracteriza-se por ser um instrumento de aplicação relativamente rápido, contendo praticamente a metade do número de questões em comparação com outros instrumentos disponíveis. Além de estabelecer o diagnóstico do transtorno depressivo, o PHQ pode também estabelecer a gravidade do sintoma depressivo.

O BDI, por sua vez, consiste em um questionário de auto-relato com 21 itens de múltipla escolha. Originalmente desenvolvido em 1978 e atualizado em 1996, o BDI é um dos instrumentos mais utilizados no mundo para medir a severidade de episódios depressivos (MAUST et al., 2012). Para avaliar o resultado, um valor de 0 a 3 é determinado para cada resposta e o resultado final é comparado a uma tabela de valores que indica o

grau e a severidade do quadro depressivo.

O instrumento GDS, utilizado nos experimentos de (ARNOLD et al., 2012) e (SENGUPTA; BENJAMIN, 2015), também é um questionário de auto-avaliação, composto de trinta itens e empregado para identificar especificamente a depressão em idosos.

O MDI, desenvolvido pela Organização Mundial da Saúde, é um questionário de humor de auto-relato e foi aplicado por (TÖRÖK et al., 2016) para medir a ocorrência de sintomas depressivos entre os entrevistados.

Observa-se que, apesar de serem instrumentos diferentes, nota-se algumas semelhanças entre eles. Na Figura 13, é possível observar alguns critérios para o diagnóstico da depressão compartilhado entre os principais instrumentos citados. Outro fato importante a ser observado é a presença de alguns critérios do DSM-V descritos na Tabela 1, apresentada na Seção 2.2, como distúrbio do sono, humor deprimido, perda de interesse por atividades, alterações do apetite e pensamentos de morte.

Outro aspecto que pode ser observado, é a interseção entre os atributos relacionados na Figura 12 e questionamentos característicos dos principais instrumentos de investigação do transtorno de depressão, Figura 13. Isto é, todas as principais questões içadas pelos questionários utilizados na abordagem clínica estão contempladas entre os atributos considerados importantes na caracterização da depressão. Esse fato pode indicar que as bases utilizadas estão, de alguma forma, direcionadas e absortas de maneira que perguntas já validadas pela comunidade científica estejam presentes no momento de análise das peculiaridades para predição da depressão.

Figura 13 – Critérios para o diagnóstico de depressão entre os principais instrumentos de investigação da doença.

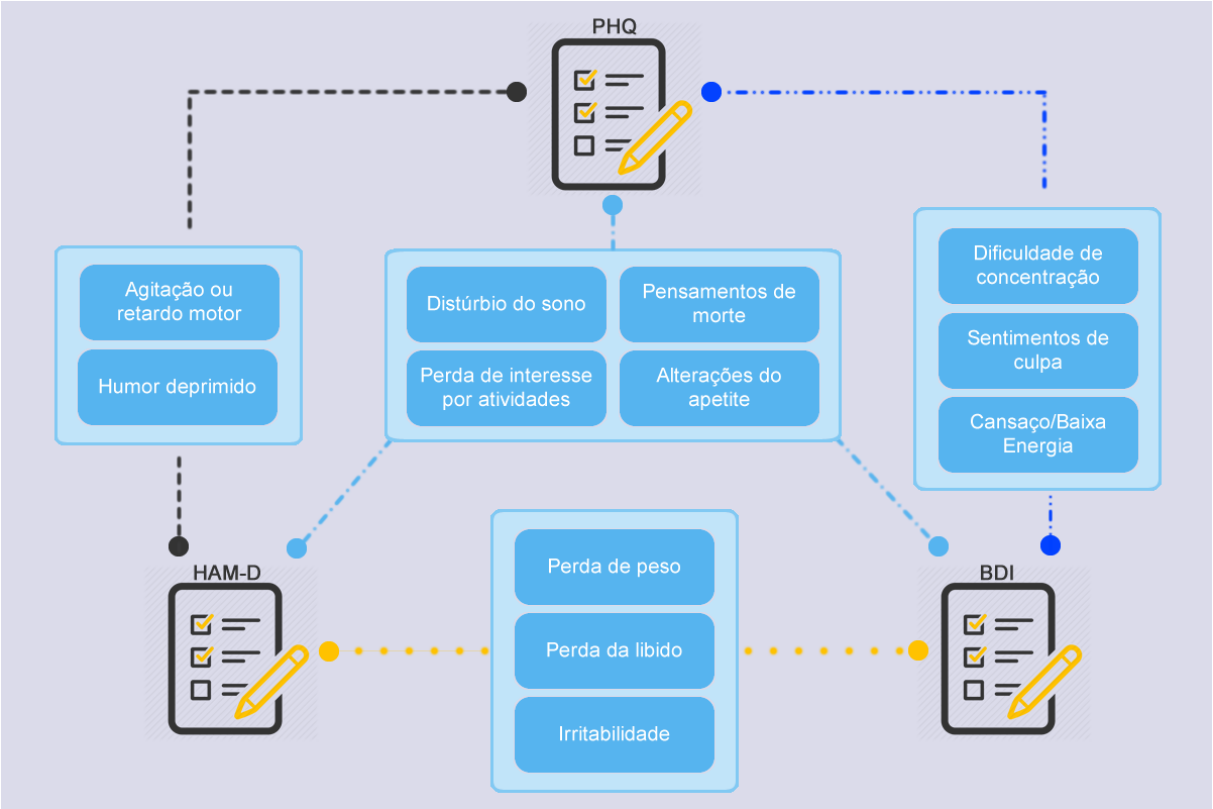

Fonte: Elaborada pelo autor, com dados extraídos da pesquisa.

4 METODOLOGIA

Este capítulo destina-se à apresentação da base de dados, à descrição das etapas de pré-processamento realizadas e dos métodos utilizados. A Figura 14 apresenta, em uma visão mais geral, a metodologia adotada para a realização da dissertação.

4.1 Levantamento Bibliográfico e Revisão Sistemática da Literatura

Esta etapa consistiu em realizar um levantamento bibliográfico através de uma Revisão Sistemática da Literatura. O objetivo dessa RSL foi identificar pesquisas que tenham como foco as técnicas e métodos computacionais, tanto oriundos da Ciência da Computação quanto da Estatística, que sejam aplicáveis ao problema de predizer se uma pessoa pode ter depressão ou não ou até mesmo caracterizar o perfil de uma pessoa com depressão. Uma RSL propicia a estruturação de trabalhos relevantes que respondem questões pertinentes à área e auxiliam na pesquisa e tratamento clínico desse transtorno tão complexo por seus multi-fatores relacionados.

Para levantar os principais trabalhos que adotam abordagens computacionais no diagnóstico de pessoas com depressão, quatro perguntas, apresentadas na Subseção 3.0.1, nortearam a RSL. Tais perguntas abrangem questões como as seguintes: 1) as principais características relacionadas a pessoas com depressão, 2) os principais métodos computacionais utilizados na análise; 3) que tipo de bases de dados estão sendo utilizadas neste contexto e 4) que tipos de instrumentos são utilizados para a investigação da depressão.

O resultado da RSL foi apresentado no Capítulo anterior.

4.2 Descrição da base de dados

A base de dados utilizada neste trabalho foi obtida em parceria com o Programa de Pós-Graduação em Psicologia: Cognição e Comportamento da Universidade Federal de Minas Gerais (UFMG). A base contém informações de crianças e adolescentes locais entre 10 e 16 anos, sendo 158 do sexo masculino e 219 do sexo feminino, totalizando 377

Figura 14 – Metodologia adotada no trabalho.

Fonte: Elaborado pelo autor.

instâncias com diferentes sintomatologias depressivas e 75 atributos*.

A Figura 15 ilustra os atributos que compõem a base de dados utilizada no estudo

*Uma descrição completa de todos os atributos da base de dados encontra-se em https://goo.gl/z2wUKg

e as Tabelas 2, 3, 4 e 5 detalham cada um desses atributos.

Figura 15 – Combinação de atributos que compõem a base de dados.

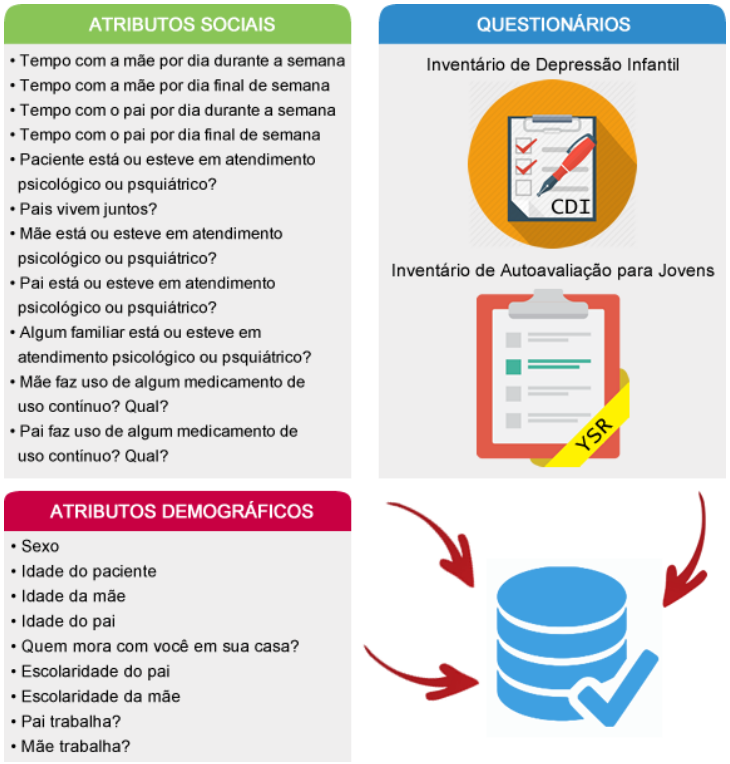

Fonte: Elaborado pelo autor.

A Tabela 2 ilustra os atributos demográficos tais como a idade e o gênero do paciente, idade e informações sobre a escolaridade dos pais, se os pais trabalham e com quem a criança ou adolescente mora.

A Tabela 3 apresenta os atributos sociais, tais como: o tempo de contato do paciente com os pais (representado por horas), informações sobre o uso de medicações, se os pais, alguém da família e/ou o paciente já estiveram em atendimento psicológico ou psiquiátrico, que tipo de remédios eles tomam, dentre outras informações.

E, finalmente, as Tabelas 4 e 5 descrevem as pontuações obtidas pelos inventários CDI e YSR, descritos na Subseção 3.0.4.4. Outras questões consideradas importantes pela comunidade de saúde mental (ASSOCIATION et al., 2013) também foram incluídas, principalmente fatores como ansiedade, problemas sociais, falta de atenção, agressividade, problemas de conduta, que são apresentadas na Tabela 6.

Como pode ser observado, os atributos, em sua grande maioria, possuem valores categóricos, em que as respostas para cada pergunta são representadas por um número que corresponde a uma lista de possíveis respostas.

A Tabela 7 apresenta os valores mínimo, máximo e a média de cada atributo numérico presente no conjunto de dados.

Tabela 2 – Descrição, tipo e possíveis valores dos atributos demográficos.

ATRIBUTOS DEMOGRÁFICOS		
Descrição dos atributos	**Tipo**	**Possíveis Valores**
Sexo	Categórico	Masculino, feminino
Idade	Numérico	Em anos
Idade da mãe	Numérico	Em anos
Escolaridade da mãe	Categórico	[Não estudou], [Ensino Fundamental Incompleto], [Ensino Fundamental Completo], [Ensino Médio Incompleto], [Ensino Médio Completo], [Superior Incompleto], [Superior Completo], [Não Sabe]
Mãe trabalha?	Categórico	Sim, não
Idade do pai	Numérico	Em anos
Escolaridade do pai	Categórico	[Não estudou], [Ensino Fundamental Incompleto], [Ensino Fundamental Completo], [Ensino Médio Incompleto], [Ensino Médio Completo], [Superior Incompleto], [Superior Completo], [Não Sabe]
Pai trabalha?	Categórico	Sim, não

Fonte: Elaborado pelo autor.

4.2.1 Pré-processamento

Visando obter um modelo mais consistente, antes de iniciar efetivamente a aplicação dos algoritmos de classificação, realizou-se o pré-processamento da base. Eliminar atributos que não contribuem para a caracterização dos perfis, mesclar atributos caso seja necessário, otimizar ou criar novas codificações de representação, tratar a existência de dados ausentes e analisar instâncias inconsistentes que não se encaixam nos grupos identificados foram as estratégias adotadas nessa etapa.

A Figura 16 ilustra de uma forma mais detalhada as etapas de pré-processamento utilizadas para o tratamento da base de dados. Etapas essas que são apresentadas nas seções seguintes.

Todo o pré-processamento da base de dados foi realizado utilizando-se a linguagem Python[†], através do ambiente Jupyter Notebook. As etapas do processamento da base de dados estão descritas sequencialmente nas próximas seções:

[†]Linguagem de programação de alto nível, interpretada e de *script*, na versão Python 3.

Tabela 3 – Descrição, tipo e valores permitidos dos atributos sociais.

ATRIBUTOS SOCIAIS		
Descrição	**Tipo**	**Possíveis Valores**
Tempo em horas que você passa com a sua mãe por dia durante a semana?	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]
Tempo em horas que você passa com a sua mãe por dia no final de semana?	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]
Tempo em horas que você passa com seu pai por dia durante a semana?	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]
Tempo em horas que você passa com seu pai por dia no final de semana?	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]
Você está ou esteve em atendimento psicológico ou psiquiátrico?	Categórico	Sim, não
Pais vivem juntos ou separados	Categórico	Juntos, Separados/divorciados
A mãe está ou esteve em atendimento psicológico ou psiquiátrico?	Categórico	Sim, não
Alguém da família da mãe está ou esteve em atendimento psicológico ou psiquiátrico?	Categórico	Sim, não
A mãe toma algum tipo de medicação de uso contínuo?	Categórico	Sim, não
Qual remédio a mãe toma?	Texto	Livre
Tempo em horas que a mãe passa com seu(s) filho(s) por dia durante a semana	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]
Tempo em horas que a mãe passa com seu(s) filho(s) por dia durante o final de semana	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]
O pai está ou esteve em atendimento psicológico ou psiquiátrico?	Categórico	Sim, não
Alguém da família do pai está ou esteve em atendimento psicológico ou psiquiátrico?	Categórico	Sim, não
O pai toma algum tipo de medicação de uso contínuo?	Categórico	Sim, não
Qual remédio o pai toma?	Texto	Livre
Tempo em horas que o pai passa com seu(s) filho(s) por dia durante a semana	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]
Tempo em horas que o pai passa com seu(s) filho(s) por dia durante o final de semana	Categórico	[0 a 3], [4 a 7], [8 a 11], [12 a 15], [16 a 19], [20 ou mais]

Fonte: Elaborado pelo autor.

4.3 Padronização de Valores Ausentes

A ausência de dados pode ser bastante prejudicial ao desempenho do classificador, podendo levar a padrões, conclusões ou tomadas de decisões equivocadas. Dados ausentes

Tabela 4 – Descrição, tipo e valores permitidos dos atributos que representam as questões do CDI.

QUESTÕES DO QUESTIONÁRIO CDI		
Questões	**Tipo**	**Possíveis Valores**
Questão 1	Categórico	[0 - Eu fico triste de vez em quando], [1 - Eu fico triste muitas vezes], [2 - Eu estou sempre triste]
Questão 2	Categórico	[0 - Para mim tudo se resolverá bem], [1 - Eu não tenho certeza se as coisas darão certo para mim], [2 - Nada vai dar certo para mim]
Questão 3	Categórico	[0 - Eu faço bem a maioria das coisas], [1 - Eu faço errado a maioria das coisas], [2 - Eu faço tudo errado]
Questão 4	Categórico	[0 - Eu me divirto com muitas coisas], [1 - Eu me divirto com algumas coisas], [2 - Nada é divertido para mim]
Questão 5	Categórico	[0 - Eu sou mau (má) de vez em quando], [1 - Eu sou mau (má) com frequência], [2 - Eu sou sempre mau (má)]
Questão 6	Categórico	[0 - De vez em quando eu penso que coisas ruins vão me acontecer], [1 - Eu temo que coisas ruins me aconteçam], [2 - Eu tenho certeza que coisas terríveis me acontecerão]
Questão 7	Categórico	[0 - Eu gosto de mim mesmo], [1 - Eu não gosto muito de mim], [2 - Eu me odeio]
Questão 8	Categórico	[0 - Normalmente, eu não me sinto culpado pelas coisas ruins que acontecem], [1 - Muitas coisas ruins que acontecem são por minha culpa], [2 - Tudo de mal que acontece é por minha culpa]
Questão 9	Categórico	[0 - Eu não penso em me matar], [1 - Eu penso em me matar], [2 - Eu quero me matar]
Questão 10	Categórico	[0 - Eu sinto vontade de chorar de vez em quando], [1 - Eu sinto vontade de chorar frequentemente], [2 - Eu sinto vontade de chorar diariamente]
Questão 11	Categórico	[0 - Eu me sinto preocupado de vez em quando], [1 - Eu me sinto preocupado frequentemente], [2 - Eu me sinto sempre culpado]
Questão 12	Categórico	[0 - Eu gosto de estar com pessoas], [1 - Frequentemente, eu não gosto de estar com pessoas], [2 - Eu não gosto de estar com pessoas]
Questão 13	Categórico	[0 - Eu tomo decisões facilmente], [1 - É difícil para mim tomar decisões], [2 - Eu não consigo tomar decisões]
Questão 14	Categórico	[0 - Eu tenho boa aparência], [1 - Minha aparência tem alguns aspectos negativos], [2 - Eu sou feio (feia)]
Questão 15	Categórico	[0 - Fazer os deveres de casa não é um grande problema para mim], [1 - Com frequência eu tenho que ser pressionado para fazer os deveres de casa], [2 - Eu tenho que me obrigar a fazer os deveres de casa]
Questão 16	Categórico	[0 - Eu durmo bem à noite], [1 - Eu tenho dificuldade para dormir algumas noites], [2 - Eu tenho sempre dificuldades para dormir à noite]
Questão 17	Categórico	[0 - Eu me canso de vez em quando], [1 - Eu me canso frequentemente], [2 - Eu estou sempre cansado (cansada)]
Questão 18	Categórico	[0 - Eu como bem], [1 - Alguns dias eu não tenho vontade de comer], [2 - Quase sempre eu não tenho vontade de comer]
Questão 19	Categórico	[0 - Eu não temo sentir dor nem adoecer], [1 - Eu temo sentir dor e ficar doente], [2 - Eu estou sempre temeroso de sentir dor e ficar doente]
Questão 20	Categórico	[0 - Eu não me sinto sozinho (sozinha)], [1 - Eu me sinto sozinho(a) muitas vezes], [2 - Eu sempre me sinto sozinho (sozinha)]
Questão 21	Categórico	[0 - Eu me divirto na escola frequentemente], [1 - Eu me divirto na escola de vez em quando], [2 - Eu nunca me divirto na escola]
Questão 22	Categórico	[0 - Eu tenho muitos amigos], [1 - Eu tenho muitos amigos e gostaria de ter mais], [2 - Eu não tenho amigos]
Questão 23	Categórico	[0 - Meus trabalhos escolares são bons], [1 - Meus trabalhos escolares não são tão bons como eram antes], [2 - Eu tenho me saído mal em matérias em que costumava ser bom (boa)]
Questão 24	Categórico	[0 - Sou tão bom quanto outras crianças], [1 - Se eu quiser, posso ser tão bom quanto outras crianças], [2 - Não posso ser tão bom quanto outras crianças]
Questão 25	Categórico	[0 - Eu tenho certeza que sou amado (a) por alguém], [1 - Eu não tenho certeza se alguém me ama], [2 - Ninguém gosta de mim realmente]
Questão 26	Categórico	[0 - Eu sempre faço o que me mandam], [1 - Eu não faço o que me mandam com frequência], [2 - Eu nunca faço o que me mandam]
Questão 27	Categórico	[0 - Eu não me envolvo em brigas], [1 - Eu me envolvo em brigas com frequência], [2 - Eu estou sempre me envolvendo em brigas]
Escore Total	Numérico	

Fonte: Elaborado pelo autor com dados extraído de (KOVACS, 2003).

Tabela 5 – Descrição e tipo dos atributos referente ao questionário YSR.

ATRIBUTOS DO QUESTIONÁRIO YSR	
Descrição dos atributos	**Tipo**
Total de Ansiedade e depressão (Internalizante)	Numérico
Total de Retraimento e depressão (Internalizante)	Numérico
Total de Queixas somáticas (Internalizante)	Numérico
Total de Problemas sociais	Numérico
Total de Problemas de Pensamento	Numérico
Total de Problemas de Atenção	Numérico
Total de Comportamento de quebrar regras (Externalizante)	Numérico
Total de Comportamento agressivo (Externalizante)	Numérico
Total de Problemas internalizantes	Numérico
Total de Problemas externalizantes	Numérico
Total de Outros problemas	Numérico

Fonte: Elaborado pelo autor com dados extraídos de (ROCHA; ARAúJO; SILVARES, 2008).

Tabela 6 – Descrição das outras questões consideradas importantes pela comunidade de saúde mental.

OUTRAS QUESTÕES IMPORTANTES	
Descrição dos atributos	**Tipo**
Total da Escala orientada pelo DSM de Problemas Afetivos	Numérico
Total da Escala orientada pelo DSM de Problemas de Ansiedade	Numérico
Total da Escala orientada pelo DSM de Problemas somáticos	Numérico
Total da Escala orientada pelo DSM de Problemas de Hiperatividade/Déficit de Atenção	Numérico
Total da Escala orientada pelo DSM de Problemas de Comportamento opositor-desafiador	Numérico
Total da Escala orientada pelo DSM de Problemas de Conduta	Numérico
Total da Escala de Qualidades Positivas de Problemas Obsessivo-Compulsivo	Numérico
Total da Escala de Qualidades Positivas de Problemas de Estresse pós-traumático	Numérico
Total da Escala de Qualidades Positivas de Qualidades Positivas	Numérico

Fonte: Elaborado pelo autor com dados extraídos de (ASSOCIATION et al., 2013).

podem ocorrer em um ou mais atributos, em várias instâncias ou de forma aleatória.

Essa ausência de dados pode ser ocasionado por circunstâncias não controladas, como por exemplo por questão de privacidade ou recusa por parte da pessoa na coleta dos dados, ou se perderem devido a falhas que ocorrem em sistemas de medidas manuais ou automatizados.

Na base original dados ausentes eram representados por "." ou "999". Nesse caso, optou-se por transformar todos os dados ausentes em um símbolo comumente utilizado no ambiente WEKA utilizado neste trabalho, a indicação "?".

Tabela 7 – Valores mínimo, máximo e média dos atributos numéricos.

Descrição dos atributos	Mín.	Máx.	Média
ATRIBUTOS SOCIAIS			
Idade da criança/adolescente	10	16	12,42
Idade da mãe	26	54	38,44
Idade do pai	25	78	42,57
ATRIBUTOS DO QUESTIONÁRIO YSR			
Ansiedade e Depressão	50	100	61,95
Retraimento e Depressão	50	100	56,35
Queixas Somáticas	50	90	57,95
Problemas Sociais	50	90	56,76
Problemas de Pensamentos	50	95	56,43
Problemas de Atenção	50	100	56,25
Comportamento de Quebrar Regras	50	79	53,29
Comportamento Agressivo	50	89	56,88
Problemas Internalizantes	32	94	58,95
Problemas Externalizantes	29	80	52,22
Outros Problemas	29	87	55,82
OUTRAS QUESTÕES			
Escala Orientada DSM de Problemas Afetivos	50	95	57,4
Escala Orientada DSM Problemas de Ansiedade	50	80	58,74
Escala Orientada DSM de Problemas Somáticos	50	87	57,68
Escala Orientada DSM de Problemas de Hiperatividade/Déficit de Atenção	50	80	56,14
Escala Orientada DSM de Problemas de Comportamento Opositor-Desafiador	50	80	54,78
Escala Orientada DSM Problemas de Conduta	50	78	54,17
Escala Qualidades Positivas de Problemas Obsessivo-Compulsivo	50	87	59,47
Escala Qualidades Positivas de Problemas de Estresse Pós-traumático	50	91	58,87
Escala Qualidades Positivas de Qualidades Positivas	25	65	53,83

Fonte: Elaborado pelo autor.

4.4 Remoção de Atributos com Poucas Informações

Em uma análise prévia observou-se que dois atributos eram de texto livre, atributos que indicam os nomes dos remédios administrados pela mãe ou pelo pai do indivíduo analisado. Nesses campos foram observadas ausência de resposta em 90% e 96% das instâncias, respectivamente, além da falta de padronização da quantidade de remédios e erros na escrita dos nomes comerciais ou do princípio ativo. Por acreditar que, em princípio, esses atributos não iriam contribuir para o modelo, eles foram removidos da base de dados. Outras formas de tratar esses atributos podem ser consideradas posteriormente.

4.5 Tratamento da Inconsistência dos Dados

Analisando a base de dados identificou-se duas situações onde havia valores preenchidos erroneamente. Em três instâncias a pergunta era fechada, ou seja, as opções de resposta só poderiam assumir as opções predefinidas. Como é o caso da escolaridade

Figura 16 – Etapas realizadas do pré-processamento da base de dados.

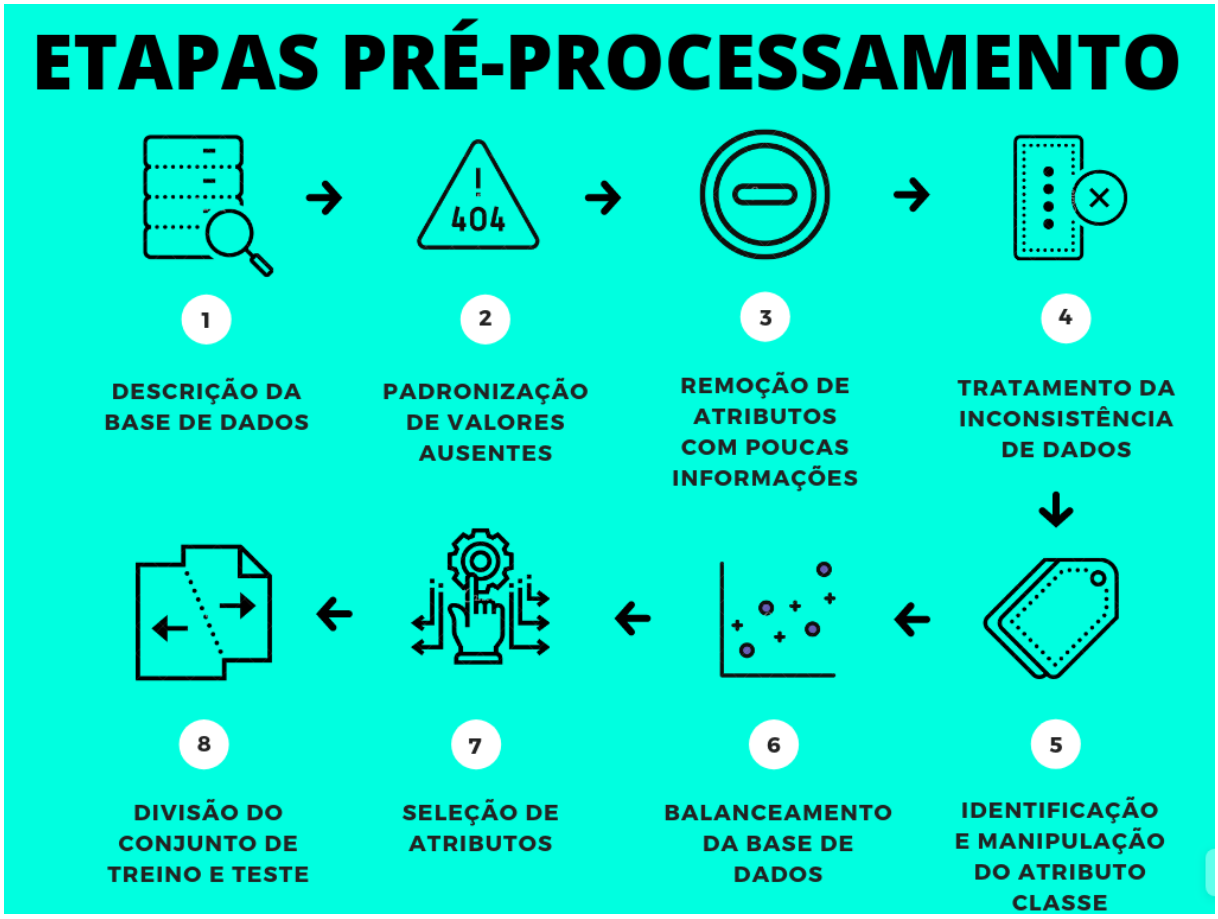

Fonte: Elaborado pelo autor.

do pai ou da mãe da criança/adolescente, onde o valor informado para o atributo não correspondia a um valor de resposta predefinido. Como não foi possível determinar um valor padrão, os campos foram considerados como *missing*.

No segundo caso, em duas instâncias os valores preenchidos no campo não correspondiam aos esperados (eram maior que o limite para o contexto apresentado). Os atributos representam o número de horas por dia que a criança ou adolescente passa com a mãe no fim de semana e com o pai durante a semana. Por se tratar de valores diários, o número não deveria ser maior que 24. Nesses casos, assumiu-se o maior valor do contexto, 24. Dado o pequeno tamanho da base, em nenhum momento foi considerado o descarte completo da instância.

4.6 Identificação e Manipulação do Atributo Classe

Inicialmente a base de dados não possuía explicitamente nenhum atributo para classificação dos pacientes. Ao aplicar o CDI, um atributo obtido é o “CDI Soma”, equi-

valente ao *score* ou pontuação do entrevistado nesse inventário. O questionário CDI possui 27 itens que quantificam sintomas como humor deprimido, capacidade hedônica, funções vegetativas, autoavaliação e comportamentos interpessoais. Cada item consiste em três instruções classificadas em ordem crescente de 0 a 2, crianças e adolescentes selecionam o que melhor caracterizou seus sintomas nas últimas duas semanas. As pontuações dos itens são combinadas em uma pontuação total de depressão, que varia de 0 a 54. Quanto maior for a pontuação do CDI, maiores são as chances do paciente apresentar um estado depressivo mais alto (BANG; PARK; KIM, 2015). Porém, somente a pontuação do CDI não determina a existência ou não da depressão, e sim indícios, características da depressão que apoiam a avaliação feita pelo profissional. Nessa etapa foi identificado uma instância que não possuía informações do CDI, logo, ela foi removida.

A Figura 17 mostra um gráfico da distribuição dos indivíduos entrevistados, considerando o atributo "CDI Soma".

Figura 17 – Distribuição do CDI Soma

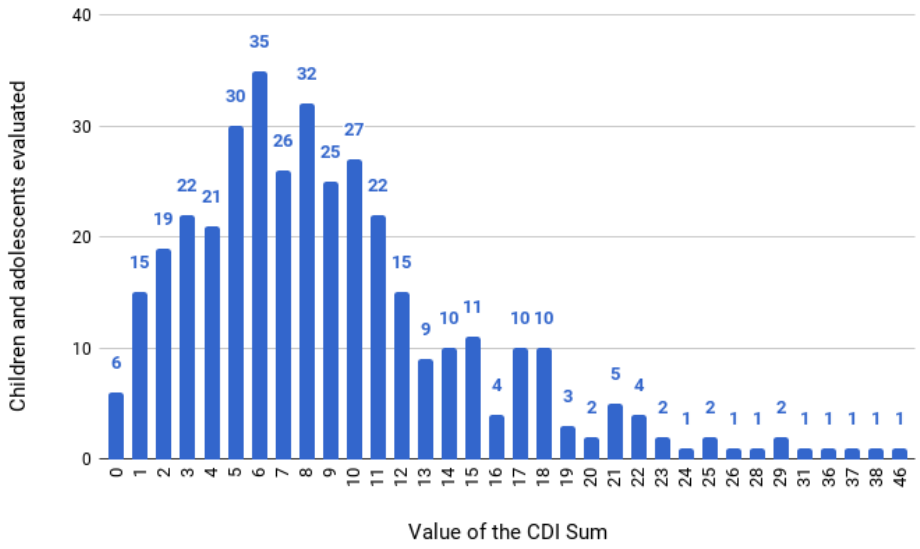

Fonte: Elaborado pelo autor.

Analisa-se através do gráfico que o menor e maior valor obtidos nessa base, respectivamente, são 0 e 46. Ainda não há unanimidade no valor de corte que determine a subdivisão, já que esse valor pode variar conforme a amostra. A recomendação de Kovacs (KOVACS, 2003) é o uso do percentil 85 para a indicação de sintomatologia alta.

A Figura 18 apresenta a quantidade de instâncias cuja pontuação é maior que os valores dos percentis. Assim, na amostra considerada, 63 indivíduos foram classificados com sintomatologia alta.

A proporção da base assemelha-se às condições reais, em que o número de pessoas

Figura 18 – Número de indivíduos em que o CDI Soma é maior que o percentil

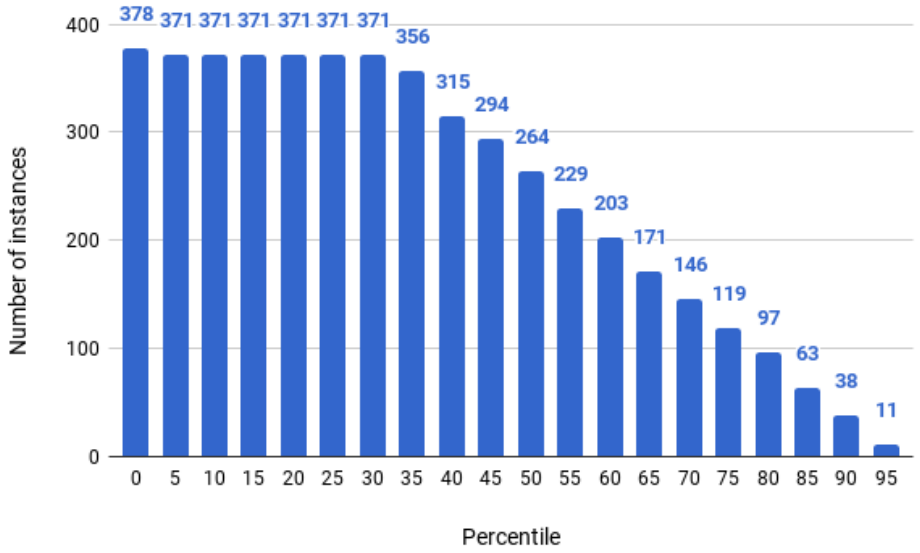

Fonte: Elaborado pelo autor.

com indícios da doença, apesar de significativo, é muito inferior à população saudável, tornando desbalanceada a quantidade dos elementos presente nesses dois grupos.

4.7 Balanceamento da Base de Dados

Após as etapas anteriores, a base de dados ficou distribuída com 314 e 63 indivíduos pertencentes a classe "BAIXA" e "ALTA", respectivamente. Com o objetivo de evitar que os algoritmos aprendessem melhor a classe majoritária, e com isso a acurácia da classe minoritária fosse prejudicada, optou-se pelo balanceamento das classes. No intuito de caracterizar um perfil, a utilização de dados sintéticos não se mostra interessante, portanto realizamos um recorte aleatório na amostra da classe "BAIXA" de 63 indivíduos, igualando aos números da classe "ALTA", ou seja, aplicamos uma técnica *undersampling* aleatória (BATISTA; PRATI; MONARD, 2004).

4.8 Divisão do Conjunto de Treino e Teste

Para uma melhor validação dos modelos gerados, optou-se pela divisão da base de dados em dois grupos um para treinamento e validação do modelo, e outro de teste com dados que não foram vistos ou avaliados pelo modelo anteriormente. A divisão realizada pode ser visualizada na Tabela 8.

Considerando-se a base balanceada, 10 instâncias da cada classe ALTA e 50 da classe BAIXA foram separadas para teste, e outras 53 instâncias, de cada classe foram

Tabela 8 – Número de instâncias por classe para os conjuntos de treinamento e teste

Classe	Antes Balanceamento	Depois Balanceamento	Criação do Modelo	Teste
ALTA	63	63	53	10
BAIXA	314	63	53	50
Total	**377**	**126**	**106**	**60**

Fonte: Elaborado pelo autor.

utilizadas na construção do modelo, como apresentado na Tabela 8.

4.9 Algoritmos Genéticos para seleção de atributos

Conjuntos de dados compostos por centenas de atributos tornaram-se comuns nos problemas de classificação, e este é o caso da classificação da sintomatologia da depressão. Em geral, os algoritmos de aprendizado de máquina usados para classificação têm a qualidade de seus resultados diminuída se todos os atributos do conjunto de dados, usualmente em número elevado, forem usados para treiná-los (WITTEN et al., 2016). Os métodos de seleção de atributos surgiram precisamente para contornar esse problema. Eles pesquisam os atributos relevantes, removendo dados irrelevantes, redundantes ou ruidosos. Assim, em geral, os desempenhos computacional e de classificação dos algoritmos de aprendizado de máquina são aprimorados pela seleção de atributos (KALOUSIS; PRADOS; HILARIO, 2007). Além disso, a compreensibilidade dos modelos gerados por alguns tipos de algoritmos, como aqueles que constroem árvores de decisão ou que geram regras, é aumentada (WITTEN et al., 2016).

Algoritmos genéticos (AG) têm sido utilizados de uma maneira bastante eficiente na seleção de características a partir de uma base de dados (Dos Santos; Nobre; Zárate, 2018)(Vaishali et al., 2017)(Zhang et al., 2018). Os AG são uma técnica de busca baseada na seleção natural darwiniana: os mais aptos têm mais chance de sobreviver e deixar descendentes para a próxima geração de uma população (SASTRY; GOLDBERG; KENDALL, 2005)(LINDEN, 2012). No AG, a população é representada pelos indivíduos (cromossomos) que são criados e submetidos aos operadores genéticos: seleção, *crossover* e mutação.

Os operadores dos algoritmos genéticos fazem uso da "qualidade" de cada indivíduo como solução do problema em questão, a qual é denominada *fitness*. Os AG são indicados para problemas difíceis nos quais se torna inviável, computacionalmente, encontrar a solução ótima para um dado problema, visto que possibilitam abranger várias regiões do espaço de busca, sem a necessidade de realizar todas as combinações possíveis.

Neste trabalho, para a seleção das melhores características foi utilizado o *Non-dominated Sorting Genetic Algorithm II* (NSGA-II), um algoritmo que trabalha com vários objetivos simultaneamente. Para o nosso problema, optamos por trabalhar com apenas um objetivo que é encontrar o melhor subconjunto de características maximizando a sua *fitness*, neste caso a *f-measure*. A escolha do NSGA-II foi motivada por este ser o "estado da arte" dos AG (DEB et al., 2002). A sua implementação foi feita na linguagem *Python*, utilizando a biblioteca DEAP, disponível pela *Université Laval* (FORTIN et al., 2012).

Nos algoritmos genéticos, a população é representada pelos indivíduos que são criados e submetidos aos operadores de seleção, *crossover* e mutação. Estes operadores utilizam a "qualidade" de cada indivíduo como solução do problema em questão, chamada de *fitness*, imitando um processo de evolução natural que, eventualmente, deve gerar, ao longo de gerações, um indivíduo que caracteriza uma boa solução para o problema proposto. A seguir, são apresentadas as principais escolhas de implementação do algoritmo genético utilizado.

4.9.1 Representação dos Indivíduos

Um indivíduo dos AG representa uma possível solução para o problema a ser resolvido. A Figura 19 apresenta um exemplo de representação de indivíduos utilizados neste trabalho. Cada indivíduo é representado por um vetor de 75 posições em que cada uma corresponde a uma característica (atributo) da base de dados. Cada uma dessas posições pode assumir o valor 0 ou 1, indicando a presença ou ausência daquela determinada característica.

Figura 19 – Representação de três indivíduos.

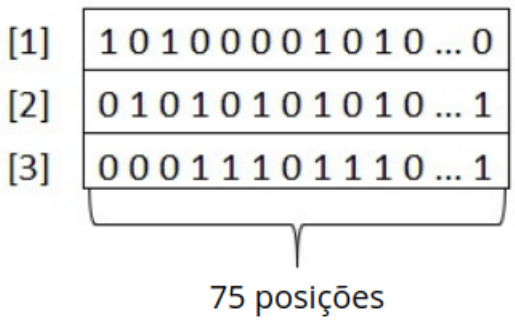

Fonte: Elaborado pelo autor.

4.9.2 Fitness

A *fitness* é uma função que indica o quão "bom" (adaptado) é um indivíduo enquanto solução para o problema, ou seja, sua qualidade. A escolha de uma boa função de *fitness* é crucial para o desempenho dos AG. Através desta métrica podemos diferenciar uma solução promissora de uma não tão adequada para o problema (HAMDANI et al., 2011). Para este trabalho, utilizamos o classificador $k-$NN com a métrica de *f-measure*[‡] para avaliar a influência da seleção de características no seu desempenho. O classificador $k-$NN foi utilizado por não demandar um custo adicional de ajustes de parâmetros e consequentemente tornar viável a execução de um conjunto grande de experimentos. Ele também foi utilizado por (SANTOS et al., 2018) e mostrou ser eficiente.

4.9.3 Parâmetros dos Experimentos

Foram executados testes preliminares para definir quais intervalos dos parâmetros seriam os mais adequados para a realização dos experimentos. Definimos como critério de parada o número de gerações do AG. Os experimentos foram realizados com 10 sementes randômicas diferentes para cada conjunto de parâmetros, escolhido a fim de aumentar a confiabilidade dos resultados. Os parâmetros utilizados estão apresentados no Quadro 6.

Quadro 6 – Parâmetros dos experimentos utilizados pelo AG.

Inicialização da população:	Aleatório
Representação:	Binário
Operador de *Crossover:*	*Two Points*
Probabilidade *crossover (Pc):*	65%, 70%, 75%, 80%
Operador de mutação:	*One Point*
Probabilidade de mutação *(Pm):*	1%, 5%, 10%
Tamanho da população:	200, 300, 500, 1000
Número de gerações:	200, 300, 500, 1000
Método de seleção de crossover	*Tournament* ($size = 2$)
Composição da nova geração:	Indivíduos não dominados
Critério de parada:	Número de gerações

Fonte: Elaborado pelo autor.

4.10 Descrição dos Métodos

Os experimentos envolvendo o método de Máquina de Vetores de Suporte, o SVM, foi conduzido utilizando uma implementação baseada no algoritmo *libSVM*[§], disponibilizado pela biblioteca de aprendizado de máquina de código aberto para a linguagem de

[‡] $f - Measure = \frac{2 \times Precisão \times Sensibilidade}{2 \times (Precisão + Sensibilidade)}$

[§] Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html

programação *Python* denominado *scikit-learn*. O algoritmo foi selecionado com base em sua ampla aceitação na literatura e adequação aos objetivos propostos. A mesma biblioteca foi utilizada para os experimentos envolvendo a Rede Neural *Multi-layer Perceptron*[¶].

Para o treinamento do classificador SVM, foi necessário ajustar três parâmetros principais, o valor de C ($C = 25$), parâmetro de suavização da margem de separação do hiperplano, o *gamma* ($gamma = 0.001$), que é a largura da Gaussiana, e o tipo de *kernel* ($kernel = rbf$). Estes parâmetros são de grande importância para que sejam encontrados bons resultados em sua execução, pois eles estão diretamente ligados à etapa de treinamento e classificação do algoritmo.

Para o uso do algoritmo *Multi-layer Perceptron*, foram ajustados o número de neurônios artificiais e o número de camadas ocultas, definindo duas camadas ocultas, a primeira com 3 neurônios e a segunda com 5. Também foi ajustado o número máximo de iterações ($max_iter = 125$) e o parâmetro de penalidade ($alpha = 0.1$). Para a otimização de peso, foi utilizado o solucionador *lbfgs* ($solver = lbfgs$), que para conjuntos de dados pequenos, pode convergir mais rapidamente e ter um desempenho melhor.

Para ajustar os parâmetros do SVM e da *Multi-layer Perceptron* foi utilizado o algoritmo *Grid Search*[‖] (CHANG; LIN, 2011) também disponibilizado pela biblioteca *scikit-learn*. Esse algoritmo realiza uma busca exaustiva sobre valores de parâmetros especificados para um classificador para identificar o melhor valor a ser utilizado como parâmetro de execução do algoritmo.

Dada a complexidade do SVM e da RNA e a necessidade de entender a importância de cada atributo para as previsões, após treinar e validar os modelos obtidos classificadores SVM e RNA, empregamos o *framework* SHAP (LUNDBERG; LEE, 2017) para ajudar a interpretar a saída dos classificadores. A apresentação dos resultados dos experimentos conduzidos neste trabalho é apresentado no Capítulo 5.

4.11 Métricas de avaliação da qualidade dos modelos

Para avaliação da qualidade dos modelos obtidos, foram utilizadas as métricas de precisão, sensibilidade e *F-measure* (CARVALHO et al., 2011).

A Precisão (Equação 1) mede a proporção de instâncias classificadas em determinada classe que são realmente da classe.

$$Pr = \frac{VP}{VP + FP} \tag{4.1}$$

[¶]Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.neural$_n$etwork.MLPClassifier.html
[‖]Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.model$_s$election.GridSearchCV.html.

A Sensibilidade (Equação 2) estabelece a proporção de instâncias corretamente classificadas, dentre todas as instâncias de uma classe.

$$Sen = \frac{VP}{VP + FN} \tag{4.2}$$

Por sua vez, o F-measure (Equação 3) representa a média harmônica entre precisão e sensibilidade.

$$F - Measure = \frac{2 \times Pr \times Sen}{Pr + Sen} \tag{4.3}$$

onde VP= Verdadeiros Positivos, FP=Falsos Positivos e FN = Falsos Negativos.

O desempenho dos classificadores foi obtido utilizando-se o método de amostragem validação cruzada de 10 dobras, sendo as partições geradas de modo aleatório. Desse modo, para cada base de dados, os valores das medidas de desempenho dos classificadores correspondem às médias dos valores obtidos em cada uma das partições.

5 RESULTADOS E DISCUSSÕES

A Tabela 9 apresenta os resultados médios e por classe (em porcentagem) das métricas de avaliação do desempenho dos modelos avaliados.

Tabela 9 – Métricas de avaliação dos modelos, em porcentagem

Classificador	Classe	Precisão	Sensibilidade	F-Measure
SVM	ALTA	90.4	88.7	89.5
	BAIXA	88.9	90.6	89.7
	Média	**89.6**	**89.6**	**89.6**
RNA	ALTA	95.9	88.7	92.2
	BAIXA	89.5	96.2	92.7
	Média	**92.7**	**92.5**	**92.4**

Fonte: Resultados da Pesquisa.

A partir do resultado do treinamento dos modelos pode-se notar uma melhor precisão para a classe "ALTA" para ambos os classificadores, onde o classificador SVM acertou 90,4% das instâncias que foram classificadas dentro desta classe, e a RNA acertou 95,9%. O classificador SVM classificou de forma errada menos de 10% das entradas, e a RNA menos de 5%. Nota-se também que a sensibilidade para a classe "BAIXA" foi superior em relação à classe "ALTA" para ambos os classificadores, o SVM acertou 90,6% das instâncias pertencentes à classe "BAIXA" e a RNA acertou 96,2%.

Vale ressaltar que uma boa precisão e sensibilidade para a classe "ALTA" é muito importante porque um bom diagnóstico para a sintomatologia alta pode sugerir com mais rapidez o tratamento adequado. Ou seja, os profissionais da saúde, família e educadores podem intervir de uma forma mais precoce no tratamento destes pacientes.

A Tabela 10 exibe os resultados alcançados para a base de teste, ou seja, foram reservadas 10 instâncias de cada classe não utilizadas na construção do modelo para teste (Ver Seção 4.8).

Conforme pode ser observado, o desempenho do SVM, analisando-se os valores médios da precisão e sensibilidade para os dados de teste, ficaram em 92,2% e 90% respectivamente, resultados superiores aos da etapa de treinamento. Já a RNA, para o mesmo conjunto de dados, obteve valores médios de precisão e sensibilidade de 90% e

Tabela 10 – Avaliação dos modelos nos dados de teste, valores em porcentagem

Classificador	Classe	Precisão	Sensibilidade	F-Measure
SVM	ALTA	64.3	90.0	75.0
	BAIXA	97.8	90.0	93.8
	Média	**92.2**	**90.0**	**90.6**
RNA	ALTA	52.9	90.0	66.7
	BAIXA	97.7	84.0	90.3
	Média	**90.0**	**85.0**	**86.4**

Fonte: Elaborado pelo autor.

85% respectivamente. Observando-se a sensibilidade percebe-se que o SVM e a RNA classificou corretamente 90% das instâncias que eram da classe "ALTA", o que é muito importante para um diagnóstico mais preciso e ágil, como já mencionado anteriormente. No entanto, a precisão da classe "ALTA", para os dois classificadores, ficou baixa: 64,3% para o SVM e 52,9% para a RNA. Isso indica uma alta taxa de falsos positivos para esta classe, sinalizando que usuários com depressão baixa foram classificados como tendo depressão alta, mas a métrica de F-measure, média harmônica entre sensibilidade e precisão, ficou em 66,7% para esta classe com a RNA e 75% com o SVM. E se analisarmos a média das duas classes, o F-measure ficou acima de 85% nos dois algoritmos avaliados.

Na parte seguinte do estudo, identificamos os atributos mais relevantes no modelo com base nos resultados do conjunto de teste. As Figuras 20 e 21 apresentam os valores SHAP para os melhores atributos e todos os exemplos desse conjunto, classificados com base no impacto na saída dos classificadores SVM e RNA, respectivamente.

O eixo horizontal representa o impacto (valor SHAP) de um atributo, com valores positivos significando que os valores do recurso aumentarão a probabilidade da classe positiva (*ALTA*), enquanto valores negativos significam o contrário. Os atributos foram ordenados verticalmente pelo impacto médio, o maior impacto na parte superior. Os pontos em cada distribuição de um atributo representam um único paciente, com alta densidade representada pelo empilhamento de pontos. As cores dos pontos representam valores alto (vermelho) e baixo (azul) dos atributos. A Figura 20 mostra claramente como os valores altos ou baixos dos atributos afetam seus valores SHAP.

Para entender melhor a Figura 20, vejamos o atributo CDI20_T1, que é o atributo de maior impacto para o modelo. Os pontos representados pela cor vermelha indicam valores mais altos para o atributo, enquanto os pontos representados pela cor azul representam valores mais baixos. O atributo CDI20_T1, que caracteriza o sentimento de solidão, possui os seguintes valores: *0) Não me sinto sozinho*, *1) Sinto-me muito sozinho* e *2) Sempre me sinto sozinho*. Portanto, quanto maior o valor do atributo, maior o sentimento de solidão. Valores altos desse atributo (pontos vermelhos) indicam uma maior probabilidade

Figura 20 – Impacto dos atributos mais relevantes para a classificação das instâncias do conjunto de testes utilizando o classificador SVM. Para cada atributo, a dispersão vertical representa pontos de dados com o mesmo valor SHAP para esse atributo. Valores SHAP mais altos significam maior probabilidade de uma previsão de classe positiva (HIGH).

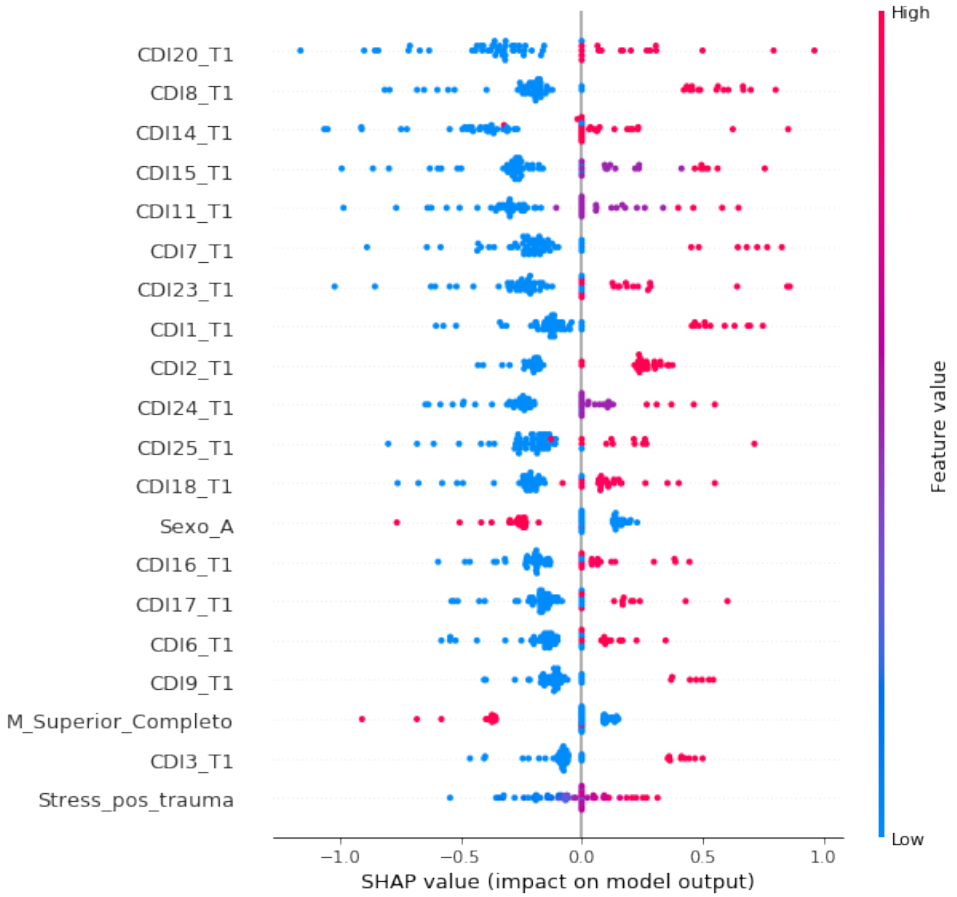

Fonte: Elaborado pelo autor com dados extraídos da pesquisa.

de uma previsão da classe ALTA, enquanto valores baixos (pontos azuis) indicam uma maior probabilidade de uma previsão da classe BAIXA.

Uma informação importante representada nas figuras é que, dentre os 20 atributos mais relevantes do modelo, 17 são do CDI, sendo CDI20_T1 (sentimentos de solidão), CDI8_T1 (sentimento de culpa) e CDI14_T1 (autoestima), as três características com maior impacto na previsão pelo SVM, seguido pelos atributos CDI15_T1 (perda de prazer ou interesse em algumas atividades), CDI11_T1 (sentimento de preocupação), CDI7_T1 (também sobre autoestima), CDI23_T1 (sentimento de inutilidade), CDI1_T1 (tristeza), CDI2_T1 (autoconfiança), CDI24_T1 (autoestima), CDI25_T1 (sentimento de inutilidade e autoestima), CDI18_T1 (apetite), Sexo_A, CDI16_T1 (distúrbio do sono), CDI17_T1 (fadiga ou perda de energia), CDI6_T1 (pensamentos negativos), CDI19_T1 (pensamentos de morte), M_Superior_Completo (escolaridade mãe),

Figura 21 – Impacto dos atributos mais relevantes para a classificação das instâncias do conjunto de testes utilizando o classificador *Multi-layer Perceptron*. Para cada atributo, a dispersão vertical representa pontos de dados com o mesmo valor SHAP para esse atributo. Valores SHAP mais altos significam maior probabilidade de uma previsão de classe positiva (HIGH).

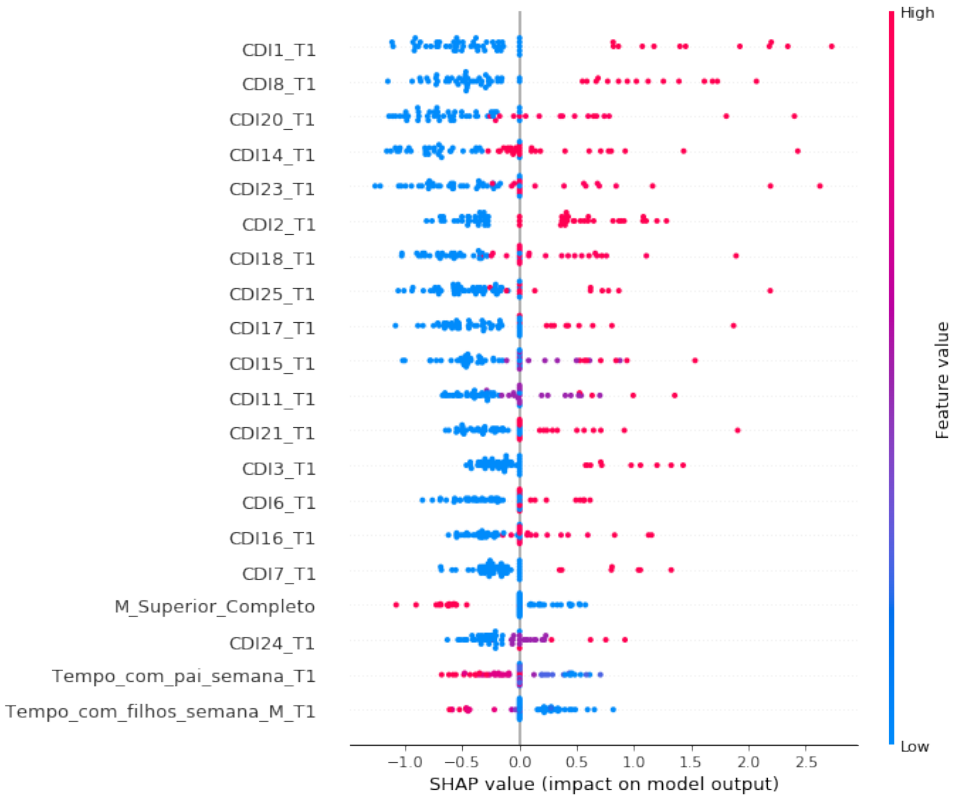

Fonte: Elaborado pelo autor com dados extraídos da pesquisa.

CDI3_T1 (autoestima) e Stress_pos_trauma (pontuação total YSR de problemas de estresse pós-traumático).

Dentre esses atributos é interessante citar o *Sexo_A*, onde, segundo o gráfico apresentado pelo SHAP, valores baixos para esse atributo indicam uma maior probabilidade de previsão para a classe positiva ("ALTA"). O atributo está codificado como sendo *0: para o sexo feminino e 1: para o sexo masculino*, ou seja, o resultado sugere que crianças e adolescentes do sexo feminino são mais propícios a desenvolverem uma sintomatologia depressiva alta, o que corrobora com o estudo de (NOBLE, 2005), no qual estudos epidemiológicos mostraram que a prevalência ao longo da vida de um transtorno depressivo em mulheres é quase o dobro do que em homens. Outra situação interessante entre esses atributos mais relevantes encontrados pela RNA (Figura 21), é a presença de dois atributos relacionados ao tempo despendido pelos pais com os filhos, o que pode também estar associado ao sentimento de solidão vivenciado pelo jovem. Esses resultados corroboram os achados (BABORE et al., 2016) (TICUSAN, 2012) (YOON; CHO; YOON, 2019) de

que a autoestima é um importante preditor para a depressão e sugere intervenções contínuas para aumentar a autoestima na adolescência, o que pode reduzir bastante o grau de depressão. Em (MATTHEWS et al., 2016), os autores propõem uma investigação na idade adulta jovem sobre a associação entre isolamento social e solidão e como eles se relacionam com a depressão e concluem que ambos estavam associados à depressão. Em um outro estudo (QUALTER et al., 2010), os autores apresentam resultados de que a solidão durante a infância podem tornar crianças predispostas a sintomas depressivos na adolescência.

Um outro atributo relevante para a classificação, e compartilhado entre os dois modelos, é o atributo *M_Superior_Completo*, que está relacionado à escolaridade da mãe da criança ou adolescente. Como é possível visualizar pelas Figuras 20 e 21, valores baixos para esse atributo significam uma maior probabilidade de uma previsão para a classe positiva ("ALTA"), ou seja, jovens no qual a mãe não possui ensino superior são mais propensos a possuir uma alta sintomatologia. Esse resultado pode se apoiar em (SHIN et al., 2008), onde os autores apresentam um estudo com o objetivo de avaliar as relações entre vários fatores psicossociais, problemas de comportamento e sintomas depressivos relatados pelos pais para investigar a depressão em crianças coreanas e identificam que os baixos níveis de escolaridade dos pais estiveram fortemente correlacionados com a prevalência de depressão nessas crianças.

Um fato importante é que, dentre os atributos mais relevantes encontrados pelo SHAP para os classificadores SVM e rede neural, 17 atributos são compartilhados entre eles, ou seja, dos 20 atributos mais relevantes encontrados utilizando-se a rede neural, 17 deles também foram encontrados pelo SVM.

E, como uma forma de validar os atributos apontados pelo SHAP como relevantes à classificação, utilizamos o AG para selecionar os melhores atributos a partir da base de dados original. O nosso interesse foi ver se estes atributos encontrados pelo SHAP poderiam ser obtidos pelo algoritmo genético, muito utilizado em seleção de atributos.

Após a execução do AG, seguindo a metodologia apresentada no Capítulo 4.9, tem-se um conjunto de soluções candidatas para o problema (população) com um valor médio para a *fitness* (*f-measure*). O conjunto de parâmetros escolhido foi aquele do AG cuja população teve a melhor *fitness* média. A Figura 22 apresenta o comportamento da *fitness* durante a evolução para o melhor conjunto de parâmetros: população = 500, gerações = 500, probabilidade de cruzamento = 0.75 e probabilidade de mutação = 0.05.

Observamos, a partir da Figura 22, que o percentual de diversidade (indica a quantidade de indivíduos gerados que são diferentes dos seus pais) teve uma convergência próxima da geração 50 em aproximadamente 38%. Além disso, não houve melhorias significativas na *fitness* máxima dos indivíduos a partir da geração 150, aproximadamente. Um

comportamento similar é observado para os indivíduos com pior *fitness*, que convergiram próximo à geração 50.

Figura 22 – Experimentos. *Fitness* (*f-Measure*) e diversidade conforme a população evolui através de gerações. Os resultados são a média de 10 execuções.

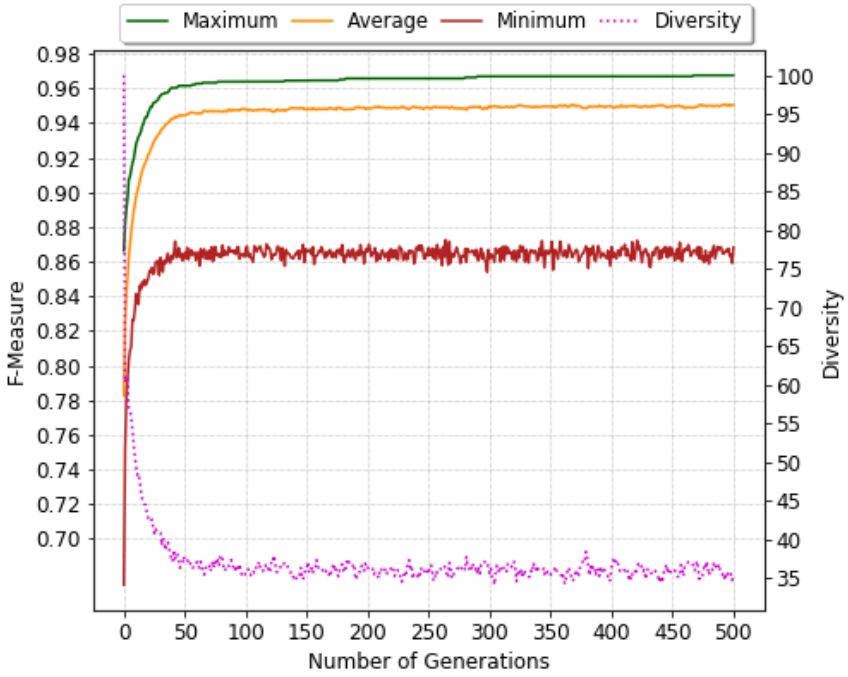

Fonte: Elaborado pelo autor.

Com base em todos os 1920 testes executados (192 x 10 randomizações) com os AG, computamos a frequência de ocorrência das características nos indivíduos da última geração da população de cada execução. Assim, foram coletadas as características *presentes* em 1920 x 500 indivíduos. O AG com melhor desempenho encontrou um conjunto de 55 características (apresentadas na Tabela 11), que foram aquelas utilizadas pelo melhor indivíduo (*f-measure* média de 96.75%).

Como uma forma de comparação ao SHAP, onde selecionamos os 20 atributos mais relevantes para a classificação, apresentamos na Figura 23 uma lista com os 20 atributos (entre os 55 selecionados) que apareceram com maior frequência entre os testes.

Ao comparar as 55 características encontradas pelo AG com as 20 características mais frequentes em todas as execuções (Figura 23), notamos que o melhor AG fez uso de 19 das 20 características que tiveram maior frequência, ou seja, 95% das 20 melhores características foram utilizadas na melhor execução.

Para uma melhor visualização, a Figura 24 apresenta uma ilustração dos atributos comuns encontrados pelo SHAP para cada classificador e os 20 atributos mais frequentes selecionados pelo AG. Nota-se que entre todos os atributos selecionados, 11 são compartilhados entre os três algoritmos.

Tabela 11 – Atributos selecionados pelo algoritmo genético.

Descrição	Tipo	Descrição	Tipo
Sexo_A	Categórico	Problemas_conduta_DSM_A_T_T1	Numérico
Tempo_com_mae_semana_T1	Numérico	Problemas_Obsessivo_compulsivo_A_T_T1	Numérico
Tempo_com_pai_final_T1	Numérico	Idade_Mae_T1	Numérico
Seus_pais_T1	Categórico	Familia_psic_Mae_T1	Categórico
CDI1_T1	Categórico	Tempo_com_filhos_semana_M_T1	Numérico
CDI2_T1	Categórico	Tempo_com_filhos_final_M_T1	Numérico
CDI3_T1	Categórico	Tempo_com_filho_semana_P_T1	Numérico
CDI6_T1	Categórico	Tempo_com_filho_final_P_T1	Numérico
CDI8_T1	Categórico	Mora_com_Mae	Categórico
CDI9_T1	Categórico	Mora_com_Avos	Categórico
CDI10_T1	Categórico	Mora_com_Outros	Categórico
CDI11_T1	Categórico	Escol_P_Nao_Estudou	Categórico
CDI14_T1	Categórico	Escol_P_Fundamental_Incompleto	Categórico
CDI15_T1	Categórico	Escol_P_Fundamental_Completo	Categórico
CDI19_T1	Categórico	Escol_P_Medio_Incompleto	Categórico
CDI20_T1	Categórico	Escol_M_Fundamental_Completo	Categórico
CDI24_T1	Categórico	Escol_M_Medio_Incompleto	Categórico
CDI25_T1	Categórico	Escol_M_Medio_Completo	Categórico
CDI26_T1	Categórico	Escol_M_Superior_Completo	Categórico
CDI27_T1	Categórico	Escol_M_Nao_Sabe	Categórico
Ansiedade_depressao_A_T_T1	Numérico	Escol_P_T1_Nao_Estudou	Categórico
Atencao_A_T_T1	Numérico	Escol_P_T1_Fundamental_Incompleto	Categórico
Quebrar_regras_A_T_T1	Numérico	Escol_P_T1_Fundamental_Completo	Categórico
Internalizantes_A_T_T1	Numérico	Escol_P_T1_Medio_Incompleto	Categórico
Externalizantes_A_T_T1	Numérico	Escol_P_T1_Superior_Completo	Categórico
Outros_problemas_A_T_T1	Numérico	Escol_M_T1_Fundamental_Incompleto	Categórico
Problemas_DAH_DSM_A_T_T1	Numérico	Escol_M_T1_Fundamental_Completo	Categórico
Escol_M_T1_Superior_Completo	Categórico		

Fonte: Elaborado pelo autor.

Entre os 11 atributos comuns encontrados, podemos rotulá-los de uma forma diferente para tentar deixar um pouco mais claro como sendo atributos referentes ao sentimento de tristeza (CDI1_T1), confiança (CDI2_T1 e CDI25_T1), autoestima (CDI14_T1 e CDI24_T1), pensamentos negativos (CDI6_T1), sentimentos de culpa, preocupação e solidão (CDI8_T1, CDI11_T1 e CDI20_T1), perda de prazer ou interesse em algumas atividades (CDI15_T1) e escolaridade da mãe (M_Superior_Completo). Além dos atributos comuns entre as três abordagens, também podemos citar alguns outros atributos, como os CDI11_T1 e CDI20_T1 (autoestima), CDI16_T1 (distúrbio do sono), CDI17_T1 (fadiga ou perda de energia), CDI18_T1 (alteração no apetite) e CDI23_T1 (sentimento de inutilidade), que são comuns entre a abordagem SHAP para os classificadores SVM e RNA e o atributo CDI9_T1 (pensamentos de morte) comum entre a abordagem com AG e o SHAP do classificador SVM.

Outros atributos encontrados pela RNA, que de alguma forma também tem relação com alguns atributos encontrados pela abordagem com AG, mesmo que diferentes, porém em um mesmo contexto são os atributos *Tempo_com_pai_semana_T*1, que indica a quantidade de horas que a criança passa com seu pai por dia durante a semana e

Figura 23 – Frequências dos 20 atributos mais utilizados pelo AG nos experimentos.

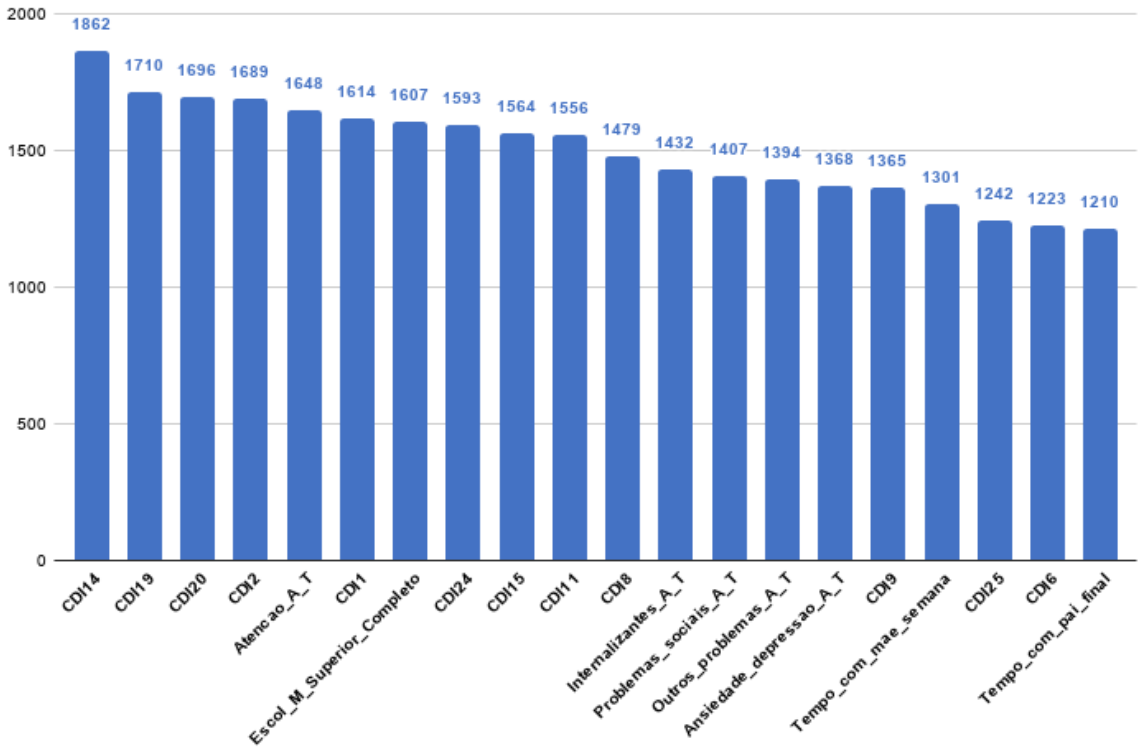

Fonte: Elaborado pelo autor.

o atributo $Tempo_com_filhos_semana_M_T1$, que indica o tempo que a mãe passa com seu(s) filho(s) por dia durante a semana, ambos encontrados pelo SHAP com RNA, e os atributos encontrados pelo AG, $Tempo_com_mae_semana_T1$, que indica a quantidade de horas que a criança passa com sua mãe por dia durante a semana e o atributo $Tempo_com_pai_final_T1$, que mede o tempo que a criança ou adolescente passa com seu pai por dia durante o final de semana, o que, como já citado anteriormente, corrobora com o estudo de (QUALTER et al., 2010), onde os autores apresentam resultados de que a solidão durante a infância podem tornar crianças predispostas a sintomas depressivos na adolescência, o que pode ser validado na Figura 21 (dois últimos atributos), que mostram que quanto menor o tempo "gasto" com os filhos, maior é a probabilidade de previsão para a classe positiva ("ALTA").

Figura 24 – Atributos comuns relevantes para a classificação identificados pelo SHAP para o classificador *Multi-layer Perceptron* e o classificador SVM e atributos encontrados pelo AG através da seleção de características.

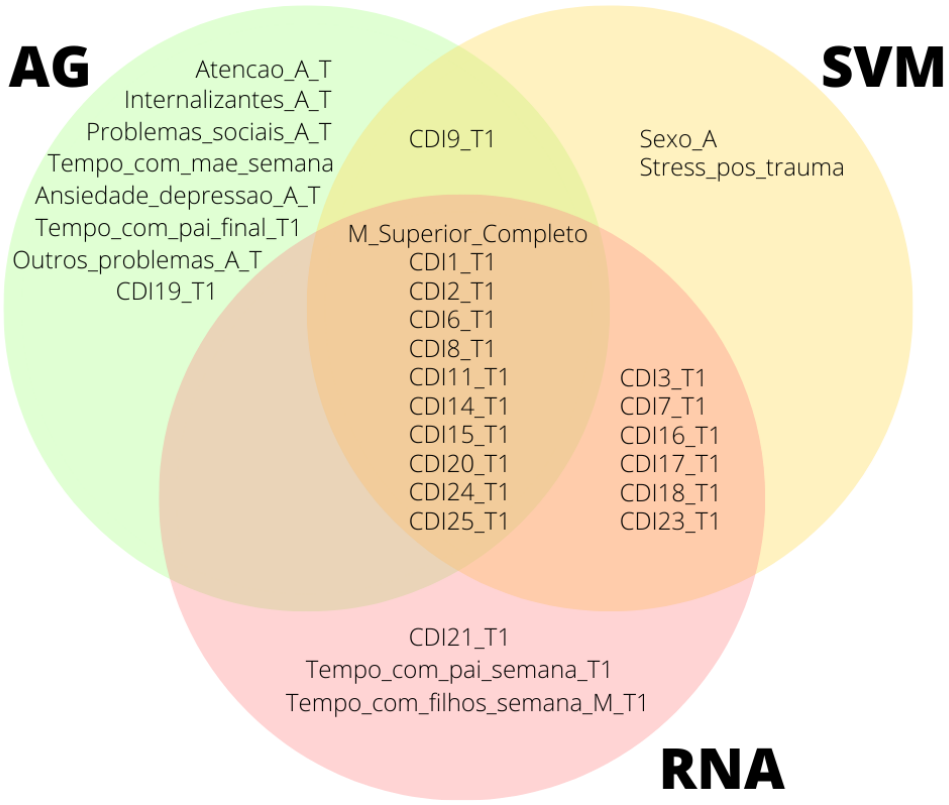

Fonte: Elaborado pelo autor.

REFERÊNCIAS

ACHENBACH, T. M.; EDELBROCK, C. S. Manual for the youth self-report and profile. Burlington: University of Vermont. Department of Psychiatry, 1987.

ADLER, P. et al. Auditing Black-box Models for Indirect Influence. 2016.

AGATONOVIC-KUSTRIN, S.; BERESFORD, R. Basic concepts of artificial neural network (ann) modeling and its application in pharmaceutical research. Journal of pharmaceutical and biomedical analysis, Elsevier, v. 22, n. 5, p. 717–727, 2000.

AMO, S. de. Técnicas de mineração de dados. Jornada de Atualizaçao em Informatica, 2004.

ANDERSON, R. N.; SMITH, B. L. et al. Deaths: leading causes for 2002. National vital statistics reports, Citeseer, v. 53, n. 17, p. 1–90, 2005.

APA. Depression. American Psychiatric Association, 2017. `https://www.psychiatry.org/psychiatrists/practice/quality-improvement/quality-measures-for-mips-quality-category`.

ARBATLI, A. D.; AKIN, H. L. Rule extraction from trained neural networks using genetic algorithms. Nonlinear Analysis: Theory, Methods & Applications, Pergamon, v. 30, n. 3, p. 1639–1648, 1997.

ARNOLD, S. E. et al. Plasma biomarkers of depressive symptoms in older adults. Translational Psychiatry, v. 2, n. 1, p. e65, jan 2012. ISSN 21583188. Disponível em: <http://www.nature.com/doifinder/10.1038/tp.2011.63>.

ASSOCIATION, A. P. American Psychiatric Association. 2018. Disponível em: <https://www.psychiatry.org/psychiatrists/practice/dsm/history-of-the-dsm>.

ASSOCIATION, A. P. et al. Diagnostic and statistical manual of mental disorders (DSM-5®). Washington, D.C: American Psychiatric Pub, 2013.

AUGASTA, M. G.; KATHIRVALAVAKUMAR, T. Reverse engineering the neural networks for rule extraction in classification problems. Neural processing letters, Springer, v. 35, n. 2, p. 131–150, 2012.

AVANCI, J. et al. Childhood depression. exploring the association between family violence and other psychosocial factors in low-income brazilian schoolchildren. Child and adolescent psychiatry and mental health, BioMed Central, v. 6, n. 1, p. 26, 2012.

BABORE, A. et al. Depressive symptoms, self-esteem and perceived parent–child relationship in early adolescence. Frontiers in Psychology, v. 7, p. 982, 2016. ISSN 1664-1078.

BANG, Y. R.; PARK, J. H.; KIM, S. H. Cut-off scores of the children's depression inventory for screening and rating severity in korean adolescents. Psychiatry investigation, Korean Neuropsychiatric Association, v. 12, n. 1, p. 23, 2015.

BARAKAT, N.; BRADLEY, A. P. Rule extraction from support vector machines: a review. Neurocomputing, Elsevier, v. 74, n. 1-3, p. 178–190, 2010.

BARAKAT, N.; DIEDERICH, J. Eclectic rule-extraction from support vector machines. International Journal of Computational Intelligence, Citeseer, v. 2, n. 1, p. 59–62, 2005.

BATISTA, G. E. A. P. A.; PRATI, R. C.; MONARD, M. C. A study of the behavior of several methods for balancing machine learning training data. SIGKDD Explor. Newsl., ACM, New York, NY, USA, v. 6, n. 1, p. 20–29, jun. 2004. ISSN 1931-0145. Disponível em: <http://doi.acm.org/10.1145/1007730.1007735>.

BECH, P. et al. The sensitivity and specificity of the major depression inventory, using the present state examination as the index of diagnostic validity. Journal of affective disorders, Elsevier, v. 66, n. 2, p. 159–164, 2001.

BECK, A. T.; ALFORD, B. A. Depressão: causas e tratamento. 2. ed. Porto Alegre: Artmed Editora, 2011. 344 p.

BECK, A. T.; STEER, R. A.; BROWN, G. K. Beck depression inventory-ii. San Antonio, v. 78, n. 2, p. 490–498, 1996.

BIRMAHER, B. et al. Childhood and adolescent depression: a review of the past 10 years. part i. Journal of the American Academy of Child & Adolescent Psychiatry, Elsevier, v. 35, n. 11, p. 1427–1439, 1996.

BREIMAN, L. Random forests. Machine learning, Springer, v. 45, n. 1, p. 5–32, 2001.

BREIMAN, L. et al. Classification and Regression Trees. Taylor & Francis, 1984. (The Wadsworth and Brooks-Cole statistics-probability series). ISBN 9780412048418. Disponível em: <https://books.google.com.br/books?id=JwQx-WOmSyQC>.

BYUN, H.; LEE, S.-W. Applications of support vector machines for pattern recognition: A survey. In: Pattern recognition with support vector machines. Berlin, Heidelberg: Springer, 2002. p. 213–236.

CARVALHO, A. et al. Inteligência artificial–uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 2011.

CATLIN, G.; WILL, P. The national population health survey: highlights of initial developments. Health Reports, v. 4, n. 3, p. 313–319, 1992.

CHANG, C.-C.; LIN, C.-J. Libsvm: a library for support vector machines. ACM transactions on intelligent systems and technology (TIST), Acm, v. 2, n. 3, p. 27, 2011.

CHUNG, H.-K. et al. The association between serum 25-hydroxyvitamin D concentrations and depressive symptoms in Korean adults: findings from the fifth Korea National Health and Nutrition Examination Survey 2010. PLoS one, v. 9, n. 6, p. e99185, jun 2014. ISSN 1932-6203.

COHEN, W. W. Fast effective rule induction. In: Machine Learning Proceedings 1995. Lake Tahoe, CA: Elsevier, 1995. p. 115–123.

COMIJS, H. C. et al. Childhood abuse in late-life depression. Journal of affective disorders, Elsevier, v. 147, n. 1-3, p. 241–246, 2013.

CORTES, C.; VAPNIK, V. Support-Vector Networks. Machine Learning, v. 20, n. 3, p. 273–297, 1995. ISSN 1573-0565.

CORTEZ, P.; EMBRECHTS, M. J. Using sensitivity analysis and visualization techniques to open black box data mining models. Information Sciences, v. 225, p. 1 – 17, 2013. ISSN 0020-0255.

COUTINHO MARIA P. L., O. M. X. P. D. R. Indicadores psicométricos doinventário de depressão infantil em amostra infanto-juvenil. Revistas Científicas de América Latina y el Caribe, España y Portugal., v. 13, n. 2, p. 269–276, 2014. Disponível em: <http://www.redalyc.org:9081/html/3350/335031819014/>.

CRAVEN, M.; SHAVLIK, J. W. Extracting tree-structured representations of trained networks. In: Advances in neural information processing systems. [S.l.: s.n.], 1996. p. 24–30.

CRAVEN, M. W.; SHAVLIK, J. W. Extracting tree-structured representations of trained networks. In: Proceedings of the 8th International Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 1995. (NIPS'95), p. 24–30.

CUMMINS, N. et al. Diagnosis of depression by behavioural signals: A multimodal approach. In: Proceedings of the 3rd ACM International Workshop on Audio/Visual Emotion Challenge. New York, NY, USA: Association for Computing Machinery, 2013. (AVEC '13), p. 11–20. ISBN 9781450323956.

DAVIS, R.; BUCHANAN, B.; SHORTLIFFE, E. Production rules as a representation for a knowledge-based consultation program. Artificial Intelligence, v. 8, n. 1, p. 15 – 45, 1977. ISSN 0004-3702. Disponível em: <http://www.sciencedirect.com/science/article/pii/0004370277900030>.

DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. IEEE transactions on evolutionary computation, IEEE, v. 6, n. 2, p. 182–197, 2002.

DERTAT, A. Applied Deep Learning - Part 1: Artificial Neural Networks. 2017. Towards Data Science, Online. Acessado em: 21 de Abril, 2020.

DIPNALL, J. F. et al. Fusing data mining, machine learning and traditional statistics to detect biomarkers associated with depression. PLoS ONE, v. 11, n. 2, p. e0148195, feb 2016. ISSN 19326203. Disponível em: <http://dx.plos.org/10.1371/journal.pone.0148195>.

Dos Santos, B. C.; Nobre, C. N.; Zárate, L. E. Multi-objective genetic algorithm for feature selection in a protein function prediction context. In: 2018 IEEE Congress on Evolutionary Computation (CEC). [S.l.: s.n.], 2018. p. 1–6.

DUENYAS, S.; MARGALIOT, M. Knowledge extraction from support vector machines: A fuzzy logic approach. In: Fifty Years of Fuzzy Logic and its Applications. Cham: Springer, 2015. p. 361–385.

FANG, P. et al. Increased Cortical-Limbic Anatomical Network Connectivity in Major Depression Revealed by Diffusion Tensor Imaging. PLoS ONE, v. 7, n. 9, p. e45972, sep 2012. ISSN 19326203. Disponível em: <http://dx.plos.org/10.1371/journal.pone.0045972>.

FAYYAD, U. et al. Advances in knowledge discovery and data mining. Menlo Park, CA: The MIT Press, 1996.

FLINT, J.; KENDLER, K. S. The genetics of major depression. Neuron, Elsevier, v. 81, n. 3, p. 484–503, 2014.

FORTIN, F.-A. et al. Deap: Evolutionary algorithms made easy. J. Mach. Learn. Res., JMLR.org, v. 13, n. 1, p. 2171–2175, jul. 2012. ISSN 1532-4435.

FORTUNY, E. J. de; MARTENS, D. Active learning-based pedagogical rule extraction. IEEE transactions on neural networks and learning systems, IEEE, v. 26, n. 11, p. 2664–2677, 2015.

FREITAS, A. A. Comprehensible classification models: A position paper. SIGKDD Explor. Newsl., ACM, New York, NY, USA, v. 15, n. 1, p. 1–10, mar. 2014. ISSN 1931-0145.

FUNG, G.; SANDILYA, S.; RAO, R. B. Rule extraction from linear support vector machines. In: ACM. Proceedings of the eleventh ACM SIGKDD international conference on Knowledge discovery in data mining. New York, NY, USA, 2005. p. 32–40.

FUNG, G. M.; MANGASARIAN, O. L. Multicategory proximal support vector machine classifiers. Machine learning, Springer, v. 59, n. 1-2, p. 77–97, 2005.

GALIATSATOS, D. et al. Classification of the most Significant Psychological Symptoms in Mental Patients with Depression using Bayesian Network. New York, NY, USA: ACM, 2015. 1–8 p. (EANN '15). Disponível em: <http://doi.acm.org/10.1145/2797143.2797159>.

GALL, R. Machine Learning Explainability vs Interpretability: Two concepts that could help restore trust in AI. 2018. KDnuggets, Online. Acessado em: 7 de Dezembro, 2019.

GKOTSIS, G. et al. Characterisation of mental health conditions in social media using informed deep learning. Scientific reports, Nature Publishing Group, v. 7, p. 45141, 2017.

GOLDSCHMIDT, R.; PASSOS, E. Data Mining: Um Guia Prático-Conceitos, Técnicas, Ferramentas, Orientações e Aplicações. Rio de Janeiro: Campus, 2005.

GOODFELLOW, I. et al. Deep learning. Cambridge: MIT press, 2016.

GUERRA, M. et al. A comparative cross-cultural study of the prevalence of late life depression in low and middle income countries. Journal of affective disorders, Elsevier, v. 190, p. 362–368, 2016.

GUIDOTTI, R. et al. A survey of methods for explaining black box models. ACM Computing Surveys (CSUR), ACM, v. 51, n. 5, p. 93, 2018.

GUIDOTTI, R. et al. A survey of methods for explaining black box models. ACM Comput. Surv., ACM, New York, NY, USA, v. 51, n. 5, p. 93:1–93:42, ago. 2018. ISSN 0360-0300.

HAMDANI, T. M. et al. Hierarchical genetic algorithm with new evaluation function and bi-coded representation for the selection of features considering their confidence rate. Applied Soft Computing, v. 11, n. 2, p. 2501 – 2509, 2011. ISSN 1568-4946. The Impact of Soft Computing for the Progress of Artificial Intelligence.

HAMILTON, M. A rating scale for depression. Journal of neurology, neurosurgery, and psychiatry, BMJ Publishing Group, v. 23, n. 1, p. 56, 1960.

HAN, J.; KAMBER, M. Data mining: concepts and techniques. Beijing: Morgan Kaufmann, 2006.

HEARST, M. A. et al. Support vector machines. IEEE Intelligent Systems and their applications, IEEE, v. 13, n. 4, p. 18–28, 1998.

HEDLUND, J. L.; VIEWEG, B. W. The hamilton rating scale for depression: a comprehensive review. Journal of Operational Psychiatry, v. 10, n. 2, p. 149–165, 1979.

HOSSEINIFARD, B.; MORADI, M. H.; ROSTAMI, R. Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal. Computer Methods and Programs in Biomedicine, v. 109, n. 3, p. 339–345, mar 2013. ISSN 01692607. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S0169260712002507>.

HUYSMANS, J. et al. An empirical evaluation of the comprehensibility of decision table, tree and rule based predictive models. Decision Support Systems, Elsevier, v. 51, n. 1, p. 141–154, 2011.

HUYSMANS, J. et al. An empirical evaluation of the comprehensibility of decision table, tree and rule based predictive models. Decision Support Systems, v. 51, p. 141–154, 04 2011.

IBGE. Instituto Brasileiro de Geografia e Estatística - Pesquisa Nacional de Saúde. 2020. 2020-05-13. Disponível em: <https://sidra.ibge.gov.br/tabela/4699>.

Junqué de Fortuny, E.; Martens, D. Active learning-based pedagogical rule extraction. IEEE Transactions on Neural Networks and Learning Systems, v. 26, n. 11, p. 2664–2677, Nov 2015. ISSN 2162-2388.

KALOUSIS, A.; PRADOS, J.; HILARIO, M. Stability of feature selection algorithms: a study on high-dimensional spaces. Knowledge and Information Systems, v. 12, n. 1, p. 95–116, May 2007. ISSN 0219-3116.

KESSLER, R. C.; AVENEVOLI, S.; MERIKANGAS, K. R. Mood disorders in children and adolescents: an epidemiologic perspective. Biological psychiatry, Elsevier, v. 49, n. 12, p. 1002–1014, 2001.

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

KITCHENHAM, B. et al. Systematic literature reviews in software engineering - a systematic literature review. Inf. Softw. Technol., Butterworth-Heinemann, Newton, MA, USA, v. 51, n. 1, p. 7–15, jan. 2009. ISSN 0950-5849.

KOLEVA, H. et al. Risk factors for depressive symptoms during pregnancy. Archives of Women's Mental Health, v. 14, n. 2, p. 99–105, apr 2011. ISSN 14341816. Disponível em: <http://link.springer.com/10.1007/s00737-010-0184-0>.

KOVACS, M. Children's depression inventory: Manual. North Tonawanda, NY: Multi-Health Systems, 1992.

KOVACS, M. Childrenś Depression Inventory (CDI): Technical Manual Update. North Tonawanda, NY: Multi-Health Systems, Incorporated, 2003. Disponível em: <https://books.google.com.br/books?id=fZN5tAEACAAJ>.

KRAUSE, J.; PERER, A.; NG, K. Interacting with predictions: Visual inspection of black-box machine learning models. In: Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems. New York, NY, USA: ACM, 2016. (CHI '16), p. 5686–5697. ISBN 978-1-4503-3362-7.

KRISHNAN, S.; WU, E. Palm: Machine learning explanations for iterative debugging. In: . [S.l.: s.n.], 2017. p. 1–6.

KROENKE, K. et al. The phq-8 as a measure of current depression in the general population. Journal of Affective Disorders, v. 114, n. 1, p. 163 – 173, 2009. ISSN 0165-0327. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0165032708002826>.

LEWINSOHN, P. M.; ROHDE, P.; SEELEY, J. R. Treatment of adolescent depression: frequency of services and impact on functioning in young adulthood. Depression and anxiety, Wiley Online Library, v. 7, n. 1, p. 47–52, 1998.

LINDEN, R. Algoritmos Genéticos. [S.l.]: Editora Ciência Moderna Ltda, 2012.

LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. In: Advances in Neural Information Processing Systems 30. [S.l.]: Curran Associates, Inc., 2017.

MAES, M. et al. A review on the oxidative and nitrosative stress (o&ns) pathways in major depression and their possible contribution to the (neuro) degenerative processes in that illness. Progress in Neuro-Psychopharmacology and Biological Psychiatry, Elsevier, v. 35, n. 3, p. 676–692, 2011.

MALAQUIAS, K. et al. Classification and characterization of children and adolescents with depressive symptomatology using machine learning. In: IEEE. 2019 IEEE International Conference on Systems, Man and Cybernetics (SMC). [S.l.], 2019. p. 534–539.

MARTENS, D. et al. Comprehensible credit scoring models using rule extraction from support vector machines. European Journal of Operational Research, v. 183, n. 3, p. 1466 – 1476, 2007. ISSN 0377-2217. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0377221706011878>.

MATTHEWS, T. et al. Social isolation, loneliness and depression in young adulthood: a behavioural genetic analysis. Social Psychiatry and Psychiatric Epidemiology, 2016.

MATZA, L. S. et al. Development and validation of a patient-report measure of fatigue associated with depression. Journal of Affective Disorders, v. 134, n. 1-3, p. 294–303, nov 2011. ISSN 01650327. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S0165032711003600 http://www.ncbi.nlm.nih.gov/pubmed/21820183>.

MAUST, D. et al. Psychiatric rating scales. In: Handbook of Clinical Neurology. [S.l.]: Elsevier, 2012. v. 106, p. 227–237.

MILLER, A. H.; MALETIC, V.; RAISON, C. L. Inflammation and its discontents: the role of cytokines in the pathophysiology of major depression. Biological psychiatry, Elsevier, v. 65, n. 9, p. 732–741, 2009.

MIN, J. A. et al. Clinical characteristics associated with different strengths of loudness dependence of auditory evoked potentials (LDAEP) in major depressive disorder. Psychiatry Research, v. 200, n. 2-3, p. 374–381, dec 2012. ISSN 01651781. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S0165178112003496>.

MOORE, P. J. et al. Forecasting depression in bipolar disorder. IEEE Transactions on Biomedical Engineering, IEEE, v. 59, n. 10, p. 2801–2807, 2012.

MORAES, E. V. de; CAMPOS, R. N.; AVELINO, M. M. Sintomas depressivos na gestação: Influência dos aspectos social, comportamental, psicológico e obstétrico. Revista Brasileira de Ginecologia e Obstetricia, v. 38, n. 6, p. 293–300, jul 2016. ISSN 01007203. Disponível em: <http://www.thieme-connect.de/DOI/DOI?10.1055/s-0036-1585072>.

NOBLE, R. E. Depression in women. Metabolism, v. 54, n. 5, Supplement, p. 49 – 52, 2005. Depression: Genetics, Pathophysiology, and Clinical Manifestations.

NÚÑEZ, H.; ANGULO, C.; CATALÀ, A. Rule extraction from support vector machines. In: Esann. [S.l.: s.n.], 2002. p. 107–112.

NÚÑEZ, H.; ANGULO, C.; CATALÀ, A. Rule-based learning systems for support vector machines. Neural Processing Letters, v. 24, n. 1, p. 1–18, Aug 2006. ISSN 1573-773X. Disponível em: <https://doi.org/10.1007/s11063-006-9007-8>.

ORRU, G. et al. Using support vector machine to identify imaging biomarkers of neurological and psychiatric disease: a critical review. Neuroscience & Biobehavioral Reviews, Elsevier, v. 36, n. 4, p. 1140–1152, 2012.

PANNEKOEK, J. N. et al. Reduced anterior cingulate gray matter volume in treatment-naive clinically depressed adolescents. NeuroImage: Clinical, Elsevier, v. 4, p. 336–342, 2014.

PATEL, M. J. et al. Machine learning approaches for integrating clinical and imaging features in late-life depression classification and response prediction. International Journal of Geriatric Psychiatry, v. 30, n. 10, p. 1056–1067, oct 2015. ISSN 10991166. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/25689482 http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4683603 http://doi.wiley.com/10.1002/gps.4262>.

PATEL, M. J.; KHALAF, A.; AIZENSTEIN, H. J. Studying depression using imaging and machine learning methods. NeuroImage: Clinical, Elsevier, v. 10, p. 115–123, 2016.

PATEL, M. J.; KHALAF, A.; AIZENSTEIN, H. J. Studying depression using imaging and machine learning methods. NeuroImage: Clinical, v. 10, p. 115–123, 2016. ISSN 2213-1582. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2213158215300206 http://linkinghub.elsevier.com/retrieve/pii/S2213158215300206>.

PATEL, V. et al. Mental health of young people: a global public-health challenge. The Lancet, Elsevier, v. 369, n. 9569, p. 1302–1313, 2007.

PAUNIO, T. et al. Poor sleep predicts symptoms of depression and disability retirement due to depression. Journal of affective disorders, Elsevier, v. 172, p. 381–389, 2015.

PEYROT, W. J. et al. Strong effects of environmental factors on prevalence and course of major depressive disorder are not moderated by 5-httlpr polymorphisms in a large dutch sample. Journal of affective disorders, Elsevier, v. 146, n. 1, p. 91–99, 2013.

PORTO, J. A. D. Conceito e diagnóstico. Revista Brasileira de Psiquiatria, SciELO Brasil, v. 21, p. 06–11, 1999.

QUALTER, P. et al. Childhood loneliness as a predictor of adolescent depressive symptoms: an 8-year longitudinal study. European Child & Adolescent Psychiatry, Springer, v. 19, n. 6, p. 493–501, 2010.

QUEVEDO, J.; NARDI, A. E.; SILVA, A. G. da. Depressão-: Teoria e Clínica. [S.l.]: Artmed Editora, 2018.

QUINLAN, J. R. C4.5: Programs for Machine Learning. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1993. ISBN 1-55860-238-0.

RIBEIRO, M. T.; SINGH, S.; GUESTRIN, C. Nothing Else Matters: Model-Agnostic Explanations By Identifying Prediction Invariance. 2016.

RITCHIE, H.; ROSER, M. Mental health. Our World in Data, 2020. Https://ourworldindata.org/mental-health.

ROCHA, M. M. d.; ARAúJO, L. G. d. S.; SILVARES, E. F. d. M. Um estudo comparativo entre duas traduções brasileiras do inventário de auto-avaliação para jovens (ysr). Psicologia: teoria e prática, scielopepsic, v. 10, p. 14 – 24, 06 2008. ISSN 1516-3687. Disponível em: <http://pepsic.bvsalud.org/scielo.php?script=sci_arttext&pid=S1516-36872008000100002&nrm=iso>.

ROCHA, M. M. da. Um estudo comparativo entre duas traduções brasileiras do inventário de auto-avaliação para jovens (ysr). Revista Psicologia-Teoria e Prática, v. 10, n. 1, 2009.

SANTOS, B. C. et al. Seleção de características utilizando algoritmo genético multiobjetivo e k-nn para predição de função de proteína. 2018.

SANTOS, N.; FERREIRA, L.; PRATES, R. Um panorama sobre métodos de avaliação de sistemas colaborativos. Anais do Simpósio Brasileiro de Sistemas colaborativos (SBSC 2012), 2012.

SARKAR, D. A brief introduction into human interpretable machine and model interpretation. Maio 2018. Online. Acessado em: 29 de Março, 2019.

SASTRY, K.; GOLDBERG, D.; KENDALL, G. Genetic algorithms. In: _____. Search Methodologies: Introductory Tutorials in Optimization and Decision Support Techniques. Boston, MA: Springer US, 2005. p. 97–125. ISBN 978-0-387-28356-2.

SAÚDE, O. M. da. CID-10: Classificação Estatística Internacional de Doenças com disquete Vol. 1. São Paulo: Edusp, 1994.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. Neural networks, Elsevier, v. 61, p. 85–117, 2015.

SELVARAJU, R. R. et al. Grad-cam: Why did you say that? visual explanations from deep networks via gradient-based localization. CoRR, abs/1610.02391, 2016.

SENGUPTA, P.; BENJAMIN, A. Prevalence of depression and associated risk factors among the elderly in urban and rural field practice areas of a tertiary care institution in Ludhiana. Indian Journal of Public Health, v. 59, n. 1, p. 3, 2015. ISSN 0019-557X. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/25758724 http://www.ijph.in/text.asp?2015/59/1/3/152845>.

SEPPÄLÄ, J. et al. Association between vitamin b12 levels and melancholic depressive symptoms: a Finnish population-based study. BMC psychiatry, v. 13, n. 1, p. 145, dec 2013. ISSN 1471-244X.

SHAPLEY, L. S. A value for n-person games. Contributions to the Theory of Games, v. 2, n. 28, p. 307–317, 1953.

SHEIKH, J. I.; YESAVAGE, J. A. Geriatric depression scale (gds): recent evidence and development of a shorter version. Clinical Gerontologist: The Journal of Aging and Mental Health, Haworth Press, 1986.

SHIMIZU, H.; NAKAYAMA, K. I. Artificial intelligence in oncology. Cancer Science, n/a, n. n/a, 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/cas.14377>.

SHIN, Y. M. et al. Predictors of self-reported depression in korean children 9 to 12 years of age. Yonsei medical journal, v. 49, n. 1, p. 37–45, 2008.

SILVA, M. T. et al. Prevalence of depression morbidity among brazilian adults: a systematic review and meta-analysis. Revista Brasileira de Psiquiatria, v. 36, n. 3, p. 262–270, 2014. Disponível em: <https://www.ncbi.nlm.nih.gov/pubmed/25119639>.

SPITZER, R. L. et al. Validation and utility of a self-report version of prime-md: the phq primary care study. Jama, American Medical Association, v. 282, n. 18, p. 1737–1744, 1999.

STEWART, J. C. et al. A prospective evaluation of the directionality of the depression–inflammation relationship. Brain, behavior, and immunity, Elsevier, v. 23, n. 7, p. 936–944, 2009.

SUNMOO, Y.; BASIRAH, T. et al. Using a data mining approach to discover behavior correlates of chronic disease: a case study of depression. Studies in health technology and informatics, NIH Public Access, v. 201, p. 71, 2014.

TAN, P.-N.; STEINBACH, M.; KUMAR, V. Introduction to Data Mining, (First Edition). Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2005. ISBN 0321321367.

THIAGARAJAN, J. J. et al. TreeView: Peeking into Deep Neural Networks Via Feature-Space Partitioning. 2016.

TICUSAN, M. Low self-esteem, premise of depression appearance at adolescents. Procedia - Social and Behavioral Sciences, v. 69, p. 1590 – 1593, 2012. ISSN 1877-0428. International Conference on Education Educational Psychology (ICEEPSY 2012).

TÖRÖK, E. et al. The association between workplace bullying and depressive symptoms: The role of the perpetrator. BMC Public Health, v. 16, n. 1, p. 993, dec 2016. Disponível em: <http://bmcpublichealth.biomedcentral.com/articles/10.1186/s12889-016-3657-x>.

TUNG, C.; LU, W. Analyzing depression tendency of web posts using an event-driven depression tendency warning model. Artificial Intelligence in Medicine, v. 66, p. 53–62, jan 2016. ISSN 18732860. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S0933365715001414>.

Vaishali, R. et al. Genetic algorithm based feature selection and moe fuzzy classification algorithm on pima indians diabetes dataset. In: 2017 International Conference on Computing Networking and Informatics (ICCNI). [S.l.: s.n.], 2017. p. 1–5.

VAPNIK, V. The nature of statistical learning theory. [S.l.]: Springer science & business media, 2013.

WANG, J. et al. Development and validation of prediction algorithms for major depressive episode in the general population. Journal of Affective Disorders, v. 151, n. 1, p. 39–45, oct 2013. ISSN 01650327 15732517. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0165032713004242>.

WANG, S.-H. et al. Text mining for identifying topics in the literatures about adolescent substance use and depression. BMC public health, BioMed Central, v. 16, n. 1, p. 279, 2016.

WANG, T. et al. A bayesian framework for learning rule sets for interpretable classification. Journal of Machine Learning Research, v. 18, n. 70, p. 1–37, 2017.

WHO. Depression. World Health Organization, 2018. http://www.who.int/mediacentre/factsheets/fs369/en/.

WINOKUR, A. et al. Insulin resistance after oral glucose tolerance testing in patients with major depression. Am J Psychiatry, Citeseer, v. 145, n. 3, p. 325–330, 1988.

WITTEN, I. H. et al. Data Mining: Practical machine learning tools and techniques. San Francisco, CA: Morgan Kaufmann, 2016.

WORLD HEALTH ORGANIZATION. Depression and other common mental disorders: global health estimates. 2017. http://www.who.int/iris/handle/10665/254610. [Online; accesso 26-Maio-2018].

YANG, L. et al. Decision Tree Based Depression Classification from Audio Video and Language Information. In: Proceedings of the 6th International Workshop on Audio/Visual Emotion Challenge - AVEC '16. New York, NY, USA: ACM, 2016. (AVEC '16), p. 89–96. ISBN 9781450345163. Disponível em: <http://doi.acm.org/10.1145/2988257.2988269 http://dl.acm.org/citation.cfm?doid=2988257.2988269>.

YANIKKEREM, E. et al. Antenatal depression: Prevalence and risk factors in a hospital based Turkish sample. Journal of the Pakistan Medical Association, v. 63, n. 4, p. 472–477, apr 2013. ISSN 00309982. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/23905444>.

YIN, X.; HAN, J. Cpar: Classification based on predictive association rules. In: SDM'03, v. 3, p. 331–335, 03 2003.

YOON, M.; CHO, S.; YOON, D. Child maltreatment and depressive symptomatology among adolescents in out-of-home care: The mediating role of self-esteem. Children and Youth Services Review, v. 101, p. 255 – 260, 2019. ISSN 0190-7409.

YOON, S.; TAHA, B.; BAKKEN, S. Using a data mining approach to discover behavior correlates of chronic disease: A case study of depression. In: Studies in Health Technology and Informatics. [s.n.], 2014. v. 201, p. 71–78. ISBN 9781614994145. ISSN 18798365. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/24943527 http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4580372>.

YUSOF, S. et al. Depressive symptoms among cancer patients undergoing chemotherapy. Procedia-Social and Behavioral Sciences, Elsevier, v. 234, p. 185–192, 2016.

ZENG, L. L. et al. Unsupervised classification of major depression using functional connectivity MRI. Human Brain Mapping, v. 35, n. 4, p. 1630–1641, apr 2014. ISSN 10970193. Disponível em: <http://doi.wiley.com/10.1002/hbm.22278>.

Zhang, X. et al. A hybrid feature selection algorithm for classification unbalanced data processsing. In: 2018 IEEE International Conference on Smart Internet of Things (SmartIoT). [S.l.: s.n.], 2018. p. 269–275.

ZHOU, B. et al. Learning Deep Features for Discriminative Localization. 2015.

ZHOU, L. et al. Identifying Patients with Depression Using Free-text Clinical Documents. In: Studies in Health Technology and Informatics. [s.n.], 2015. v. 216, p. 629–633. ISBN 9781614995630. ISSN 18798365. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/26262127>.