UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Modelo computacional para apoio à decisão clínica no diagnóstico de transtornos psicóticos

Isabelle Carvalho

Tese de Doutorado do Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional (PPG-CCMC)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Isabelle Carvalho

Modelo computacional para apoio à decisão clínica no diagnóstico de transtornos psicóticos

Tese apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Doutora em Ciências – Ciências de Computação e Matemática Computacional. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientador: Prof. Dr. João Luís Garcia Rosa

USP – São Carlos
Outubro de 2020

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

C331m Carvalho, Isabelle
 Modelo computacional para apoio à decisão clínica
 no diagnóstico de transtornos psicóticos / Isabelle
 Carvalho; orientador João Luís Garcia Rosa. -- São
 Carlos, 2020.
 104 p.

 Tese (Doutorado - Programa de Pós-Graduação em
 Ciências de Computação e Matemática Computacional) --
 Instituto de Ciências Matemáticas e de Computação,
 Universidade de São Paulo, 2020.

 1. Mineração de Dados. 2. Transtornos Psicóticos.
 3. Apoio ao Diagnóstico Clínico. I. Garcia Rosa, João
 Luís, orient. II. Título.

Isabelle Carvalho

**Computational model for clinical decision support in the
diagnosis of psychotic disorders**

Doctoral dissertation submitted to the Instituto de
Ciências Matemáticas e de Computação – ICMC-
USP, in partial fulfillment of the requirements for the
degree of the Doctorate Program in Computer Science
and Computational Mathematics. *FINAL VERSION*

Concentration Area: Computer Science and
Computational Mathematics

Advisor: Prof. Dr. João Luís Garcia Rosa

USP – São Carlos
October 2020

*Dedico esse trabalho aos meus pais Antônio e Rose, à minha irmã Thaisa,
e a todos que acreditam que o conhecimento é a nossa principal riqueza.*

AGRADECIMENTOS

Agradeço a Deus, pela saúde e força em todo o caminhar.

Aos meus pais e minha irmã, Antônio, Rose e Thaisa. Muito obrigada pelo apoio incondicional.

À minha cachorrinha, Nina, pela alegria contagiante.

À minha amiga, Mariane Neiva, pelo companheirismo e por compartilhar, todos os dias, as conquistas e contratempos.

Às minhas amigas, Ana Camila Magon, Ketlin Fabri dos Santos, Gabriela Guerreiro Saggiore e Letícia Iskandar Ázar, por terem sempre um abraço reconfortante, mesmo de longe, em 31 anos de amizade.

À minha amiga, Francielle Vargas, pelos conselhos, palavras de encorajamento e risadas.

Às minhas amigas, Fabiana Góes e Nathália Aprile, pelas longas conversas acolhedoras.

Ao meu amigo Rafael Brússolo, pela paciência e exemplo de resiliência e dedicação.

Aos meus colegas do grupo de pesquisa BCI-BIOCOM pela convivência.

À CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo apoio financeiro.

Ao Prof. Domingos Alves e equipe, pela colaboração no desenvolvimento do trabalho.

À minha coorientadora, Profa. Cristina Marta Del-Ben, e colaboradoras, Rosana Shuhama e Camila Loureiro, pelo suporte clínico e enriquecimento nas questões multidisciplinares do trabalho.

Ao meu orientador, Prof. João Luís Garcia Rosa, pela orientação e dedicação, muito obrigada!

Por fim, agradeço a todos que me ajudaram e torceram por mim para a conclusão de mais essa etapa em minha vida.

Com carinho,
Isabelle Carvalho

*“Por vezes sentimos que aquilo que fazemos não é senão uma gota de água no mar.
Mas o mar seria menor se lhe faltasse uma gota.”
(Madre Teresa de Calcutá)*

RESUMO

CARVALHO, I. **Modelo computacional para apoio à decisão clínica no diagnóstico de transtornos psicóticos**. 2020. 104 p. Tese (Doutorado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2020.

Atualmente, um dos grandes gargalos em saúde mental é a busca por fatores causais multifatoriais para auxílio na identificação e diferenciação do diagnóstico de transtornos mentais. Este trabalho tem como objetivo identificar, modelar e avaliar, com base em algoritmos de extração de regras, um conjunto mínimo relevante e suas relações entre variáveis de sinais e sintomas, variáveis relacionadas a fatores de risco socioambientais e propriedades de material biológico a fim de caracterizar transtornos psicóticos em primeiro episódio, em particular esquizofrenia, transtorno bipolar e transtorno depressivo.

Os métodos consistem de 4 principais etapas [1] Pré-processamento; [2] Extração de padrões; [3] Avaliação e [4] Desenvolvimento de uma ferramenta web. O conjunto de dados inicial era composto por 488 indivíduos descritos por 357 atributos e envolvendo 9 diferentes grupos de características. Para classificação de transtornos psicóticos (caso e controle), foram apresentadas 6 regras finais descritas por 10 características em 2 grupos distintos de dados; nessa análise, o algoritmo de indução de regras RIPPER se destacou dos demais, tendo maior desempenho geral e regras majoritárias com alto valor de suporte (acima de 80%). Para classificação de identificação de diagnósticos (esquizofrenia, transtorno bipolar, transtorno depressivo e controle), foram apresentadas 14 regras finais, descritas por 31 características em 5 grupos distintos de dados; nessa análise, os algoritmos PART e RIPPER mostraram-se bons candidatos para exploração desse tipo de conjunto de dados, em sua maioria, obtiveram performances satisfatórias (acima de 70%). Por fim, viabilizou-se uma ferramenta web - a PEP HELP - para apoio à decisão clínica no diagnóstico de esquizofrenia, transtorno depressivo e transtorno bipolar em primeiro episódio psicótico, que incorpora os modelos de decisão construídos.

Dessa maneira, os algoritmos de extração de regras mostraram-se ferramentas promissoras para exploração de variáveis clínicas no contexto de transtornos psicóticos, obtendo características e relações relevantes, com boa acurácia e com alinhamento na literatura clínica da área. Os achados do trabalho poderão apoiar o processo diagnóstico em saúde mental.

Palavras-chave: Mineração de Dados, Transtornos Psicóticos, Apoio ao Diagnóstico Clínico.

ABSTRACT

CARVALHO, I. **Computational model for clinical decision support in the diagnosis of psychotic disorders.** 2020. 104 p. Tese (Doutorado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2020.

Nowadays, one of the major issue in mental health is the search for multifactorial causal factors to aid the identification and differentiation in the diagnosis of mental disorders. This work aims to identify, model, and evaluate, based on rule extraction algorithms, a relevant minimum set and its relationships among variables of signs and symptoms, variables related to socioenvironmental risk factors, and properties of biological material, in order to characterize psychotic disorders in the first episode, in particular schizophrenia, bipolar disorder, and depressive disorder.

The methods were developed in 4 main steps: [1] Pre-processing; [2] Extraction of patterns; [3] Evaluation and [4] Development of a web tool. The initial data set consisted of 488 individuals described by 357 attributes and involving 9 different groups of characteristics. For the classification of psychotic disorders (case and control), 6 final rules were presented, described by 10 characteristics in 2 different data groups. In this analysis, the RIPPER rules induction algorithm stood out, with the highest performance and majority rules with a high support value (above 80%). For classification of diagnostic identification (schizophrenia, bipolar disorder, depressive disorder, and control), 14 final rules were presented, described by 31 characteristics in 5 different data groups. In this analysis, the PART and RIPPER algorithms proved to be good candidates for the exploration of this type of data set, obtained a satisfactory performance (above 70%). In addition, a web tool - the PEP HELP - was made available to support the clinical decision in the diagnosis of schizophrenia, depressive disorder, and bipolar disorder, in the first psychotic episode, which incorporates the built decision models.

In this way, the rule extraction algorithms proved to be promising tools to explore clinical variables in the context of psychotic disorders, obtaining a relevant group of characteristics and relationships, with good precision and alignment in the clinical literature of the area. The results of this work might support the diagnostic process in mental health.

Keywords: Data Mining, Psychotic Disorders, Clinical Decision Support.

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação do processo KDD.	26
Figura 2 – Visão geral: materiais e métodos.	33
Figura 3 – Distribuição das características de acordo com a fonte de dados.	36
Figura 4 – Distribuição das classes - pré-balanceamento.	46
Figura 5 – Distribuição das classes - pós-balanceamento.	46
Figura 6 – Fluxograma de regras: <i>Wrapper</i> DT e C4.5 (sem e com poda)	55
Figura 7 – Fluxograma de regras: <i>Wrapper</i> DT e Tabela de Decisão	56
Figura 8 – Fluxograma de regras: <i>Wrapper</i> DT e RIPPER	57
Figura 9 – Fluxograma de regras: <i>Wrapper</i> DT e PART	58
Figura 10 – Fluxograma de regras: <i>Wrapper</i> DT e RIDOR	59
Figura 11 – Fluxograma de regras: <i>Wrapper</i> Match e RIPPER	59
Figura 12 – Fluxograma de regras: <i>Wrapper</i> Match e PART	60
Figura 13 – Fluxograma de regras: <i>Wrapper</i> Match e RIDOR	61
Figura 14 – Fluxograma de regras: <i>Wrapper</i> SVM-S e C4.5 (com poda)	67
Figura 15 – Fluxograma de regras: <i>Wrapper</i> SVM-S/MLP e Tabela de Decisão	69
Figura 16 – Fluxograma de regras: <i>Wrapper</i> SVM-S e RIPPER	70
Figura 17 – Fluxograma de regras: <i>Wrapper</i> SVM-S e PART	72
Figura 18 – Fluxograma de regras: <i>Wrapper</i> SVM-S e RIDOR	74
Figura 19 – Fluxograma de regras: <i>Wrapper</i> MLP e C4.5 (com poda)	75
Figura 20 – Fluxograma de regras: <i>Wrapper</i> MLP e RIPPER	76
Figura 21 – Fluxograma de regras: <i>Wrapper</i> MLP e PART (1/2)	78
Figura 22 – Fluxograma de regras: <i>Wrapper</i> MLP e PART (2/2)	79
Figura 23 – Fluxograma de regras: <i>Wrapper</i> MLP e RIDOR	80
Figura 24 – Ferramenta PEP HELP: Tela inicial.	87
Figura 25 – Ferramenta PEP HELP: Recuperação de senha.	87
Figura 26 – Ferramenta PEP HELP: Solicitação de acesso.	88
Figura 27 – Ferramenta PEP HELP: Painel principal e HELP Diagnóstico - questões OPCRIT (1/2).	89
Figura 28 – Ferramenta PEP HELP: Painel principal e HELP Diagnóstico - questões OPCRIT (2/2).	90
Figura 29 – Ferramenta PEP HELP: HELP Diagnóstico - questões CAPE.	91
Figura 30 – Ferramenta PEP HELP: HELP Diagnóstico - questões CTQ.	91
Figura 31 – Ferramenta PEP HELP: HELP Diagnóstico - questões CEQ.	92

Figura 32 – Ferramenta PEP HELP: HELP Diagnóstico - questões DFAR.	92
Figura 33 – Ferramenta PEP HELP: HELP Diagnóstico - página de consulta.	93
Figura 34 – Ferramenta PEP HELP: HELP Diagnóstico - relatório da consulta.	93
Figura 35 – Ferramenta PEP HELP: Página Sobre - breve apresentação da ferramenta. .	94
Figura 36 – Ferramenta PEP HELP: Página Links úteis.	94

LISTA DE TABELAS

Tabela 1 – Regras de associação: uso de maconha e primeiro episódio psicótico.	29
Tabela 2 – Panorama geral: Natureza das variáveis	36
Tabela 3 – Representação da matriz de confusão	41
Tabela 4 – Cronograma de atividades	43
Tabela 5 – Filtragem: Quantidade de atributos por subconjunto - classificação caso/controle	47
Tabela 6 – Filtragem: Quantidade de atributos por subconjunto - classificação diagnósticos	47
Tabela 7 – <i>Wrapper</i> : Número de atributos por subconjunto - classificação caso/controle	48
Tabela 8 – <i>Wrapper</i> : Número de atributos por subconjunto - classificação diagnósticos	48
Tabela 9 – <i>Wrapper</i> : Acurácia - classificação caso/controle	49
Tabela 10 – <i>Wrapper</i> : Acurácia - classificação diagnósticos	49
Tabela 11 – <i>Wrapper</i> : Test t pareado - classificação caso/controle	50
Tabela 12 – <i>Wrapper</i> : Test t pareado - classificação diagnósticos	50
Tabela 13 – <i>Wrapper</i> : Performance do subconjunto Match - classificação caso/controle	50
Tabela 14 – Número de atributos por conjunto - classificação caso/controle	52
Tabela 15 – Modelos de extração de regras: Acurácia - classificação caso/controle	52
Tabela 16 – Modelos de extração de regras: Teste t - classificação caso/controle	53
Tabela 17 – Número de regras por conjunto - classificação caso/controle	53
Tabela 18 – Pontuação de performance - classificação caso/controle	54
Tabela 19 – Avaliação das Regras - classificação caso/controle	62
Tabela 20 – Modelo Final - classificação caso/controle	64
Tabela 21 – Número de atributos por conjunto - classificação diagnósticos	64
Tabela 22 – Modelos de extração de regras: Acurácia - classificação diagnósticos	64
Tabela 23 – Modelos de extração de regras: Test t - classificação diagnósticos	65
Tabela 24 – Número de regras por conjunto - classificação diagnósticos	65
Tabela 25 – Pontuação de performance - classificação diagnósticos	66
Tabela 26 – Avaliação das Regras - classificação diagnósticos - Transtorno Bipolar	82
Tabela 27 – Avaliação das Regras - classificação diagnósticos - Esquizofrenia	83
Tabela 28 – Avaliação das Regras - classificação diagnósticos - Transtorno Depressivo	84
Tabela 29 – Avaliação das Regras - classificação diagnósticos - Controle	85
Tabela 30 – Modelo final - classificação diagnósticos	86

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Contextualização	21
1.2	Lacuna	22
1.3	Objetivo	23
1.4	Hipótese	23
1.5	Contribuições Teóricas e Práticas	23
1.6	Estruturação do documento	24
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Mineração de Dados	25
2.2	Mineração de Dados para Apoio à Decisão Clínica em Psiquiatria	27
3	MATERIAIS E MÉTODOS	33
3.1	OS DADOS	34
3.1.1	<i>Descrição</i>	34
3.1.2	<i>Caracterização</i>	35
3.1.3	<i>Extrapolção dos resultados</i>	36
3.2	DEFINIÇÃO DO MODELO DE DECISÃO	37
3.2.1	<i>Pré-processamento</i>	37
3.2.2	<i>Extração de padrões de comportamento</i>	39
3.2.3	<i>Avaliação</i>	41
3.3	FERRAMENTA WEB	42
3.4	CRONOGRAMA	43
4	RESULTADOS	45
4.1	PRÉ-PROCESSAMENTO	45
4.1.1	<i>Construção de um banco de dados relacional</i>	45
4.1.2	<i>Tratamento dos atributos</i>	45
4.1.3	<i>Balanceamento das classes</i>	46
4.1.4	<i>Seleção de atributos</i>	47
4.1.4.1	<i>Método: Filtragem</i>	47
4.1.4.2	<i>Método: Wrapper</i>	47
4.2	EXTRAÇÃO DE PADRÕES DE COMPORTAMENTO	51
4.2.1	<i>CLASSIFICAÇÃO: CASO/CONTROLE</i>	51

4.2.1.1	<i>Avaliação dos Modelos</i>	51
4.2.1.2	<i>Avaliação das Regras</i>	54
4.2.2	CLASSIFICAÇÃO: DIAGNÓSTICOS	64
4.2.2.1	<i>Avaliação dos Modelos</i>	64
4.2.2.2	<i>Avaliação das Regras</i>	66
4.3	A FERRAMENTA PEP HELP	87
4.3.1	CONSULTA AOS ESPECIALISTAS DE DOMÍNIO	94
5	CONSIDERAÇÕES FINAIS	95
5.1	Nota: colaboração - Portal COVID-19 BRASIL	96
REFERÊNCIAS		97

INTRODUÇÃO

1.1 Contextualização

Os transtornos mentais com a presença de episódios psicóticos constituem sérios problemas de saúde pública no mundo, com alta morbimortalidade. Em 2018, um estudo multicêntrico de incidência, com foco na população entre 18 e 64 anos, descreveu uma taxa de 21,4 casos por 100.000 pessoas-ano (JONGSMA *et al.*, 2018). Globalmente, estima-se que 264 milhões de pessoas são afetadas pela depressão, 45 milhões de pessoas são afetadas pelo transtorno bipolar e 22 milhões de pessoas são afetadas pela esquizofrenia (JAMES *et al.*, 2018). No Brasil, a prevalência da população com esquizofrenia é cerca de 0,8%, o que significa que o transtorno acomete mais de 1,6 milhão de brasileiros (MATOS *et al.*, 2015).

Esses indivíduos podem apresentar um ou mais episódios psicóticos ao longo de sua vida e geralmente essa situação é um dos pontos mais críticos do transtorno. O episódio psicótico se refere à presença proeminente de delírios, alucinações, fala desorganizada e comportamento desorganizado (incluindo catatonia), com ausência ou percepção mínima do paciente sobre a natureza desses sintomas, caracterizando um amplo comprometimento do julgamento crítico da realidade (AMERICAN PSYCHIATRIC ASSOCIATION, 2013).

Para definição de um diagnóstico psiquiátrico, os médicos avaliam a história e a presença de um conjunto de sinais e sintomas e sua gravidade. O paciente apresenta queixas subjetivas e o médico as classifica, além dos comportamentos observados, com base em critérios diagnósticos operacionais. Nesse processo, os médicos devem liderar a conversa com os pacientes de maneira clara e precisa. Além disso, é necessário entender a expressão dos sintomas em diferentes culturas (JABLENSKY, 2016). Os sintomas psiquiátricos relatados pelo paciente, avaliados e observados pelo clínico, constituem a principal fonte de informação utilizada para diagnosticar e conduzir o tratamento (STEPHAN *et al.*, 2016).

Um grande desafio ocorre devido a quantidade de informações que podem ser apresenta-

das nesse processo e na diferenciação em suas relações e relevância. Qualquer ganho na precisão de um diagnóstico é um alto ganho para o prognóstico do paciente.

Dessa maneira, os requisitos para a tomada de decisão devem cobrir dados precisos, conhecimentos profissionais relevantes e habilidades para resolver problemas. O diagnóstico não envolve apenas decidir o que é verdade sobre um paciente, mas também os dados que são necessários para determinar o que é verdadeiro (MUSEN; MIDDLETON; GREENES, 2014; KONONENKO, 2001).

Temos, então, uma forte aliada nessa gestão do conhecimento: a utilização de ferramentas computacionais. As técnicas de mineração de dados (especialmente os algoritmos de reconhecimento de padrões) podem auxiliar os usuários cujo maior desafio é extrair rapidamente as informações mais completas possíveis da grande quantidade de dados disponíveis. Essas técnicas são cada vez mais usadas para auxiliar o tratamento médico devido ao seu potencial de apresentar modelos que apoiam a decisão diagnóstica e diferenciar distúrbios específicos que representam raciocínio especializado (KOPROWSKI; FOSTER, 2018).

Desde do final da década de 1950, a computação e a medicina trabalham em conjunto com o objetivo de impulsionar o diagnóstico clínico. Os modelos de apoio à decisão diagnóstica em várias áreas médicas estão continuamente sendo estudados, como em gastroenterologia (TENÓRIO *et al.*, 2011), oncologia (AMATO *et al.*, 2013), doenças crônicas (como hipertensão e diabetes) (AMATO *et al.*, 2013), em multimorbididades (FRACCARO *et al.*, 2015), no atendimento ao paciente - fornecendo estrutura para planos de cuidados e documentação (MÜLLER-STAU; GRAAF-WAAR; PAANS, 2016), para apoiar a qualidade de vida (REIS *et al.*, 2016) e também auxiliar no diagnóstico da doença de Alzheimer, apneia do sono e doenças cardíacas (SATO; SATO, 2015; SCHADT; BJÖRKEGREN, 2012; MARTÍNEZ; ROBERTO; BERMÚDEZ, 2012).

No entanto, em psiquiatria, a utilização de técnicas computacionais para apoio ao diagnóstico ainda é recém-explorada, principalmente no estudo de transtornos psicóticos (HUYS; MAIA; FRANK, 2016). Essa interdisciplinaridade se direcionou para construir sistemas que pudessem atuar como coadjuvantes na tomada de decisão clínica. Um sistema diagnóstico permite o apoio à decisão explorando todos os dados disponíveis, aplicando o raciocínio empregado por um especialista e provendo uma possível identificação de um diagnóstico complexo (HUYS; MAIA; FRANK, 2016; RAZZOUK *et al.*, 2006).

1.2 Lacuna

Há uma busca à identificação de características que aumentará a precisão do processo diagnóstico em psiquiatria, a fim de reduzir uma instabilidade estimada em cerca de 40% (JABLENSKY, 2016; PINA-CAMACHO *et al.*, 2015). O ponto principal é a obtenção de um conjunto de dados para a classificação diagnóstica em saúde mental capaz de incorporar relatos de sinais e sintomas e variáveis relacionadas a fatores genéticos e ambientais. Além da incorporação,

visa-se também estudar modelos diagnósticos capazes de apontar com precisão as ligações entre essas características (SIMMONS; QUINN, 2014; CUTHBERT, 2014; CUTHBERT; INSEL, 2013).

No entanto, é difícil processar todas as possibilidades e relações entre os dados “apenas pelos olhos humanos” e as técnicas de mineração de dados podem auxiliar na descoberta de conhecimento em bancos de dados cujo desafio é a quantidade de dados e/ou sutileza dessas relações (MUSEN; MIDDLETON; GREENES, 2014; KONONENKO, 2001).

1.3 Objetivo

Identificar, modelar e avaliar, com base em algoritmos de extração de regras, um conjunto mínimo relevante e suas relações entre variáveis de sinais e sintomas, variáveis relacionadas a fatores de risco socioambientais e propriedades de material biológico a fim de caracterizar transtornos psicóticos em primeiro episódio psicótico (PEP).

1.4 Hipótese

A utilização de técnicas de mineração de dados para descoberta de conhecimento em variáveis relacionadas ao diagnóstico de transtornos psicóticos auxiliará no reconhecimento dos casos de transtornos psicóticos em PEP e também na diferenciação entre os diagnósticos de esquizofrenia, transtorno depressivo e transtorno bipolar em PEP.

1.5 Contribuições Teóricas e Práticas

A principal contribuição teórica do trabalho foi a construção de modelos de decisão para o apoio ao diagnóstico de transtornos psicóticos. Com isso, foi apresentado um caminho de exploração das técnicas de descoberta de conhecimento por meio de algoritmos de indução de regras, isso é, um método não caixa preta que permite a exploração desse tipo de dado. Consequentemente obteve-se toda a riqueza das análises na identificação de um conjunto mínimo relevante e suas relações. E também, apontamentos de características chaves na diferenciação dos diagnósticos de esquizofrenia, transtorno bipolar e transtorno depressivo.

Com base nas contribuições teóricas, como contribuição prática, viabilizou-se uma ferramenta web (PEP-HELP) que incorpora o melhor modelo de decisão construído para apoio ao diagnóstico clínico de transtornos psicóticos.

1.6 Estruturação do documento

Esse capítulo - *Capítulo 1* - apresenta a introdução do trabalho e contém uma contextualização do tema, lacuna, objetivo, hipótese e pontos de contribuição. O *Capítulo 2* apresenta os eixos teóricos e os trabalhos da literatura que foram alicerce para a tese. O *Capítulo 3* descreve os recursos e métodos que foram utilizados. O *Capítulo 4* apresenta resultados e discussões. O *Capítulo 5* expõe as considerações finais; e, por fim, são apresentadas as *Referências*.

FUNDAMENTAÇÃO TEÓRICA

2.1 Mineração de Dados

O modelo tradicional para transformação de dados em informação consiste em um processamento manual dos elementos pelos especialistas que, então, produzem relatórios para análise. Com o volume de dados armazenados crescendo diariamente, acabamos nos tornando ricos em dados mas pobres em informação, isso porque, descobrir padrões nesses repositórios de forma manual deixou de ser uma opção e tornou-se crucial o poder de explorá-los. Nesse contexto, a mineração de dados vem ganhando cada vez mais espaço apresentando técnicas de apoio a essa tarefa (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996; HAN; PEI; KAMBER, 2011; GUPTA; CHANDRA, 2020).

A mineração de dados combina conhecimento de diversas áreas, utilizando métodos estatísticos tradicionais de análise de dados e técnicas e algoritmos de inteligência artificial, aprendizado de máquina e reconhecimento de padrões. O foco é na descoberta de propriedades e relações úteis provenientes dos dados.

O processo geral de transformação dos dados brutos em informações úteis é chamado de Descoberta de Conhecimento em Bases de Dados (do inglês *Knowledge-Discovery in Databases* - *KDD*); a mineração de dados é parte integrante desse processo. FAYYAD; PIATETSKY-SHAPIRO; SMYTH (1996) definem KDD como um processo não trivial de identificação de novos padrões válidos, úteis e compreensíveis. Na Figura 1 podemos ver uma representação do processo de KDD.

No geral, as fases do KDD consistem em (HAN; PEI; KAMBER, 2011; FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996; CAMILO; SILVA, 2009):

- **Entender o negócio:** qual o objetivo que se deseja atingir.
- **Entender os dados:** deve-se conhecer os dados visando descrever de forma clara o

Figura 1 – Representação do processo KDD.

Fonte: Elaborada pelo autor.

problema e também identificar quais são os dados relevantes. É primordial conhecer o tipo do dado com o qual se irá trabalhar para que as etapas sejam executadas da maneira mais adequada.

- **Preparar os dados:** visa preparar os dados para que os métodos de Mineração de Dados sejam aplicados. É referente aos processos de limpeza dos dados como, por exemplo, filtrar, combinar e preencher valores vazios. Segundo [MCCUE \(2014\)](#), a etapa de preparação dos dados pode ser responsável por até 80% de todo o processo.
- **Modelar:** nessa fase as técnicas de mineração serão aplicadas. Essas técnicas consistem na realização da análises e na aplicação de algoritmos que, sob certas limitações computacionais, produzem um conjunto de padrões sobre os dados. A modelagem do problema é estruturada de acordo com determinadas tarefas, como: (i) **Descrição:** descreve os padrões e tendências revelados pelos dados. É geralmente utilizada em conjunto com as técnicas de análise exploratória para comprovar a influência de certas variáveis no resultado; (ii) **Classificação:** visa identificar a qual classe um determinado conjunto de características pertence; (iii) **Regressão:** é similar à classificação porém usada quando o registro a ser identificado é um valor numérico contínuo; (iv) **Predição:** visa presumir o valor futuro de um determinado atributo; (v) **Agrupamento:** visa identificar e aproximar os registros similares, separando-os em grupos; e (vi) **Associação:** consiste em identificar atributos relacionados.
- **Avaliar:** é a etapa de pós-processamento e conta com a participação de especialistas dos dados, conhecedores do negócio e tomadores de decisão. É necessário fazer testes e validações visando obter a confiabilidade dos modelos encontrados.
- **Extrapolar:** Após finalizado o modelo, é fundamental que o público-alvo conheça os resultados.

Ao final do processo KDD, somos capazes de extrair, de forma otimizada, a informação contida, e muitas vezes implícita nos dados, fornecendo a análise inteligente desses dados e também novas formas de exploração, apoiando, assim, pesquisas em diversos domínios de aplicação, como, por exemplo, na medicina computacional ([KONONENKO, 2001](#)).

2.2 Mineração de Dados para Apoio à Decisão Clínica em Psiquiatria

Os conhecimentos da medicina computacional, que explora a intersecção entre a medicina e a computação, têm permitido discussões mais profundas sobre os fatores de risco das doenças. Por meio da capacidade das ferramentas da computação serem adaptadas e aplicadas no contexto da saúde, nos tornamos capazes de capturar tudo o que sabemos sobre uma doença e desenvolver terapias melhoradas e adequadas às necessidades dos indivíduos (WINSLOW *et al.*, 2012).

No método clínico, o paciente procura o médico com um conjunto de queixas, esse o entrevista e identifica seus sintomas, sendo ou não subsidiado por meio de exames complementares, determinados no laboratório. A partir disso, é formulada uma hipótese diagnóstica (CÂMARA, 2007). Em saúde mental, o desfecho diagnóstico é concebido primordialmente em termos experienciais humanos e não em marcadores objetivos da doença (BZDOK; MEYER-LINDENBERG, 2018). Originalmente, foi o alemão Emil Kraepelin que observou como os sintomas se organizavam para formar doenças mentais, caracterizando padrões ou síndromes que permitiam um diagnóstico nessa área. O método clínico em psiquiatria, analisado por meio da obra de Kraepelin, partiu de três hipóteses complementares que embasam os processos diagnósticos da psiquiatria atual. A primeira e segunda hipóteses estabelecem que a doença é definida por um padrão de sintomas e sua evolução também acontece de acordo com um padrão. A terceira hipótese estabelece que as síndromes específicas possuem um substrato anatomopatológico ou fisiopatológico e isso ainda é um problema essencial da psiquiatria (CÂMARA, 2007; SANISLOW *et al.*, 2020).

O desafio de ajudar um paciente considerando a complexidade do ato diagnóstico é, para a maioria dos psiquiatras, um dos grandes apelos da especialidade (CRADDOCK; MYNORS-WALLIS, 2014). Em 2015, HESLIN *et al.* realizaram um estudo com o objetivo de analisar a estabilidade diagnóstica de psicose utilizando dados de uma amostra de incidência de casos e reclassificando-os após 10 anos. Os diagnósticos de esquizofrenia, distúrbio esquizoafetivo, transtorno bipolar e a psicose induzida por drogas tiveram um aumento no número de casos após 10 anos, indicando uma tendência de migração de outros diagnósticos para essas categorias. Isso significa que a incidência desses diagnósticos pode estar sendo subestimada nos estudos, sendo capaz de confundir o quadro etiológico geral. A partir dessa investigação, HESLIN *et al.* apresentaram que além de não haver diagnósticos etiologicamente condicionados em psiquiatria, ainda falta um quadro descritivo adequado dos transtornos e expõem um alerta de que a falta de classificação psiquiátrica baseada etiologicamente tem contribuído para a instabilidade nos diagnósticos ao longo do tempo.

Durante muito tempo, a geração de conhecimento em neurociência básica e a tomada de decisão clínica em psiquiatria foram fundamentadas em estatísticas clássicas. No entanto, os métodos de mineração de dados podem ser particularmente ajustados às ambições da psiquiatria de precisão, por poderem traduzir diretamente a descoberta de padrões complexos em conjuntos

de dados (BZDOK; MEYER-LINDENBERG, 2018). Alguns trabalhos a seguir apresentam a exploração desses métodos, especialmente no estudo de transtornos mentais.

Em 2006, RAZZOUK *et al.* desenvolveram um sistema de apoio à decisão clínica (SADC) para o diagnóstico de esquizofrenia. A aquisição e estruturação do conhecimento que visava identificar os sinais e sintomas mais relevantes e suas relações foram feitas exclusivamente por meio de consulta a especialistas. Inicialmente, 3 especialistas foram consultados, porém houve desacordo na identificação de relevância e as informações de apenas 1 deles foram escolhidas como base para a construção das 9 perguntas finais pertencentes ao SADC. Apesar das limitações, por tratar-se de uma abordagem escassa em modelagem de conhecimento, enviesada pela experiência de um único profissional, o SADC apresentou uma taxa relativamente baixa de erros de classificação (18-34%) e um desempenho razoável no diagnóstico de esquizofrenia, com uma acurácia de 66-82%.

Visando uma construção mais robusta de um modelo de apoio clínico para o diagnóstico de esquizofrenia, em 2015, PINA-CAMACHO *et al.* desenvolveram um modelo baseado em Máquina de Vetores de Suporte (do inglês: *Support Vector Machine* – SVM) para avaliar os valores preditivos diferenciais em um grande conjunto de dados clínicos, neuropsicológicos, neuroimagem e bioquímicos, em pacientes com esquizofrenia em primeiro episódio psicótico (PEP).

Foram exploradas 1050 características em um grupo de 123 indivíduos (81 indivíduos que apresentavam esquizofrenia e 42 controles). A construção do modelo preditivo passou pela etapa de pré-processamento, com normalização e filtragem dos atributos. Dos 1050 atributos iniciais, 243 foram selecionados como mais relevantes e foram objetos de entrada para a predição. A classificação diagnóstica contou com a abordagem *hold-out*, onde o conjunto de dados foi dividido em duas partes distintas: treinamento (80% do conjunto) e teste (20% do conjunto) e, assim, os autores apresentaram acurácia de 81% no modelo SVM construído.

Apesar das variáveis de neuroimagem e bioquímicas não terem proporcionado valor preditivo adicional, pois foram eliminadas na identificação de relevância pela seleção de atributos, PINA-CAMACHO *et al.* mostraram a exploração da técnica como promissora e apresentaram este como o primeiro estudo a usar um modelo de SVM como uma ferramenta estatística multivariada para identificar variáveis particulares de diferentes fontes, a fim de prever um diagnóstico de esquizofrenia em pacientes em PEP.

A investigação de diversas influências causais nos transtornos psicóticos é recente, principalmente relações como o uso da maconha e a psicose. Em 2016, ALGHAMDI *et al.* estimaram que o risco de apresentar distúrbios psicóticos é aproximadamente três vezes maior para aqueles que são usuários diários de maconha, em comparação com aqueles que não são usuários. Com o objetivo de entender como os padrões de uso (como frequência ou idade) se relacionam no risco dos distúrbios, os autores propuseram uma abordagem de modelagem de predição e detecção de padrões para o estudo do PEP associado ao uso de maconha.

Inicialmente, [ALGHAMDI et al.](#) tinham disponíveis 1106 registros (489 pacientes em PEP, 370 controles e 247 registros não rotulados) descritos por 255 atributos (atributos demográficos, relacionados à medicação, genéticos e relacionados a experiências do indivíduo com a maconha). Para a construção dos modelos, os dados passaram pela etapa de pré-processamento que consistiu-se em atividades como remoção de dados ausentes, verificação de consistência, normalização das variáveis e seleção de atributos. Ao final dessas atividades, o conjunto de dados apresentava 777 registros e 29 atributos.

A modelagem de predição explorou os classificadores *Boosted Classification Trees*, *Random Forests* e *Support Vector Machine*, visando identificar os grupos pacientes versus controle e estudar modelos com e sem a inclusão das variáveis relacionadas à experiência do indivíduo com maconha. A avaliação dessa construção foi feita por meio das métricas de acurácia, curva ROC, valor de precisão e índice Kappa. [ALGHAMDI et al.](#) apontaram que a precisão de todos os modelos diminuía cerca de 7% se os atributos relacionados ao uso da maconha não eram usados no processo de construção.

Nos modelos que apresentaram melhores desempenhos foi investigado o vínculo entre os atributos relacionados ao uso da maconha e o PEP, através de análises de associação e técnicas de inferência bayesiana, levando à detecção de 6 regras descritas pela Tabela 1.

Tabela 1 – Regras de associação: uso de maconha e primeiro episódio psicótico.

Fonte: Adaptada de [Alghamdi et al. \(2016\)](#).

Regras	Probabilidade de PEP
Se USA MACONHA=SIM E USA DIARIAMENTE=SIM E TIPO=SKUNK	85%
Se USA MACONHA=SIM E IDADE É DE 1 A 14 ANOS=SIM E TIPO=SKUNK	81,95%
Se USA MACONHA=SIM E TIPO=SKUNK	79,95%
Se USA MACONHA=SIM E USA DIARIAMENTE=SIM	74,95%
Se USA MACONHA=SIM E USA DIARIAMENTE=SIM E IDADE PRIMEIRA VEZ=15	73,95%
Se USA MACONHA=SIM E DURAÇÃO=PELO MENOS 6 MESES	71,95%

Porém, foram utilizados apenas os atributos relacionados à experiência com maconha para a construção dessas regras. Os autores apresentam ainda algumas limitações a cerca das incertezas presentes nos dados, representadas pela alta proporção de valores faltantes e a necessidade de analisar as variações de desempenho de previsão, explorando outras técnicas de pré-processamento e modelos preditivos.

Essa busca pelos fatores causais dos transtornos psicóticos visa também impactar na detecção de uma continuidade clara entre características clínicas de duas categorias diagnósticas. Em 2018, [JAUHAR et al.](#) propuseram analisar sintomas clínicos, por meio da aplicação de técnicas computacionais, para prover diferenças na construção diagnóstica entre esquizofrenia e psicose afetivas. Em duas categorias de análise foram estudados 202 pacientes (120 pacientes com esquizofrenia e 82 pacientes com psicose afetiva):

1. O aprendizado não supervisionado construindo um agrupamento hierárquico. Os autores apresentaram um primeiro ciclo que agrupou dois conjuntos de dados [i] agrupamento com

- características de diagnóstico maníaco/psicótico (p -valor=0,94) e [ii] agrupamento com características de diagnóstico depressivo (p -valor=0,92). Eliminando as características referentes ao diagnóstico depressivo, a técnica foi reaplicada e foram apresentados outros dois conjuntos de dados [i] agrupamento com características de diagnóstico maníaco (p -valor=0,84) e [ii] agrupamento com características de diagnóstico psicótico (p -valor=0,88).
2. O aprendizado supervisionado explorando a regressão logística regularizada. Os autores exploraram duas atividades: [i] utilizando todo o conjunto de dados e diferenciando com precisão de 83,66% os diagnósticos de esquizofrenia e psicose afetiva e [ii] removendo as características referentes ao diagnóstico depressivo, identificadas pela análise de agrupamento, diferenciando nessa atividade os diagnósticos estudados com 74,75% de precisão.

[JAUHAR et al.](#) concluíram que foi possível, por meio das síndromes da psicopatologia clínica, diferenciar o diagnóstico de esquizofrenia e psicose afetiva, com razoável acurácia, usando técnicas de aprendizado de máquina não supervisionadas e supervisionadas. Os autores reforçaram a força de seus resultados baseando-se na qualidade dos dados explorados devido ao instrumento de coleta e aos especialistas envolvidos. Apesar disso, são reconhecidas as dificuldades inerentes à classificação psiquiátrica e altamente reforçada a importância de iniciativas recentes que propõem combinar classificação com pesquisa científica básica e abordagens transdiagnósticas.

Ainda na busca por características diferenciais no diagnóstico em psiquiatria, em 2019, [STAMATE et al.](#) aplicaram técnicas de mineração de dados para classificar transtornos psicóticos. Foram estudados 472 indivíduos (260 pacientes diagnosticados com transtorno psicótico e 212 controles saudáveis) descritos por variáveis emocionais e demográficas. A etapa de pré-processamento contou com levantamento de completude dos dados e seleção de atributos. A construção dos modelos explorou 5 métodos (*Random Forests*, *Support Vector Machines*, *Gaussian Processes*, *Logistic Regression* e *Neural Networks*).

[STAMATE et al.](#) apresentaram 82% como o melhor resultado de precisão para classificar transtornos psicóticos, explorando o método SVM com núcleo radial. Ao avaliar o poder discriminativo das variáveis entre os modelos, foi revelado que o nível das emoções mostrou-se ter bom poder preditivo para: ansioso, inseguro, suspeito, deprimido, solitário e alegre. Os efeitos de flutuação do humor como a medida de velocidade (mudança de humor) e aceleração (mudança de velocidade) também tiveram sucesso em aumentar o poder preditivo dos modelos.

Os autores apresentaram também esse como sendo o primeiro estudo que aplicou técnicas de mineração de dados a informações sobre as experiências de vida diária dos participantes, baseando-se nas flutuações das emoções (estados mentais momentâneos) e o validaram como prova de conceito de que essas técnicas poderiam aproveitar o poder dos dados na previsão de doenças mentais como uma ferramenta de auto-monitoramento de baixo custo e alto impacto.

Reforçaram ainda os estágios iniciais desse tipo de exploração em psiquiatria, prevendo alto poder de extração de conhecimento nesse tipo de dado por meio dessas técnicas.

À medida que ganharmos confiança na capacidade dos modelos computacionais para prever os processos biológicos humanos, eles nos ajudarão ainda mais nas tomadas de decisão, nos levando a métodos mais eficazes e confiáveis para o diagnóstico de doenças, estratificação de risco e terapia ([WINSLOW *et al.*, 2012](#); [CAO](#); [SCHWARZ, 2020](#)).

Diante disso, a tese desenvolvida visou contribuir nessa área de conhecimento, visto que os transtornos mentais têm etiologia multifatorial, que podem estar fortemente relacionada às diversas circunstâncias da vida das pessoas, e com alto potencial em contribuir para o processo de decisão diagnóstica ([BRAVEMAN; GOTTLIEB, 2014](#)).

MATERIAIS E MÉTODOS

A Figura 2 é uma visão geral dos materiais e métodos detalhados nas próximas seções.

Figura 2 – Visão geral: materiais e métodos.

Fonte: Elaborada pelo autor.

A sessão 3.1 apresenta e caracteriza a base de dados utilizada. A sessão 3.2 descreve os métodos de cada etapa da construção do modelo de decisão (pré-processamento, análise e avaliação). A sessão 3.3 descreve os recursos do desenvolvimento da ferramenta web - baseada no modelo de decisão estruturado - para apoio a decisão clínica no diagnóstico de esquizofrenia, transtorno bipolar e transtorno depressivo. Por fim, a sessão 3.4 apresenta o cronograma que descreve as atividades envolvidas e suas disposições durante o período da pesquisa.

3.1 OS DADOS

3.1.1 Descrição

Os dados foram provenientes da colaboração com o grupo de pesquisa STREAM do Departamento de Neurociências e Ciências do Comportamento da Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo.

O grupo STREAM é integrante do projeto multicêntrico *European Network of National Schizophrenia Networks Studying Gene-Environment Interactions* (EU-GEI), um consórcio internacional para investigar etiologia, mecanismos e prognóstico de transtornos relacionados ao primeiro episódio psicótico (TALAMONE; CAINELLI, 2012; JONGSMA *et al.*, 2018). Esse grupo de estudo tem como objetivo identificar a interação entre determinantes genéticos, clínicos e ambientais envolvidos no desenvolvimento, na gravidade e na evolução desses transtornos. Nossa colaboração visa contribuir com ferramentas de análises e exploração desses dados.

Os instrumentos de avaliação dos pacientes para coleta dos dados e que foram base para esse estudo estão descritos a seguir. Todos os instrumentos foram selecionados e adaptados pelo grupo que gerencia o consórcio EU-GEI. Posteriormente, foram enviados aos países participantes do estudo, incluindo o Brasil, para tradução e adaptação. Os instrumentos que ainda não possuíam versão brasileira foram traduzidos para a língua portuguesa e adequados à realidade brasileira pelos pesquisadores do grupo STREAM.

Variáveis que representam sinais e sintomas

- Inventário de Critérios Operacionais para Doenças Psicóticas (*Operational Criteria Checklist for Psychotic Illness* - OPCRIT): avalia a presença de sintomas psicóticos no último mês. O instrumento faz a avaliação de alteração de: aparência e comportamento; linguagem e forma do pensamento; afeto e características associadas; crenças e ideias anormais; e, percepções alteradas (FARMER *et al.*, 1993).
- Avaliação de Experiências Psíquicas na Comunidade (*Community Assessment of Psychic Experiences* - CAPE): avalia sentimentos, pensamentos e experiências mentais. Os itens analisados são avaliados em duas colunas. A coluna A corresponde a frequência em que determinado sentimento, pensamento e/ou experiência mental ocorreu durante a vida e a coluna B corresponde ao grau de sofrimento quando o sentimento e/ou experiência estava presente (KONINGS *et al.*, 2006).
- Reconhecimento Facial de Emoções Atenuadas (*Degraded Facial Affect Recognition Task* - DFAR): o teste mede o reconhecimento de expressões faciais emocionais. O indivíduo deve reconhecer as emoções (neutra, alegria, medo ou raiva) que são mostradas em 64 rostos (WOUT *et al.*, 2004).

Variáveis que representam fatores de risco socioambientais

- Escala Sociodemográfica (SOCDEM): uma avaliação detalhada para a coleta de informações sociodemográficas: lugar de nascimento e dos pais, classe social e dos pais, história de migração, habitação e circunstâncias de vida (MALLET, 1997).
- Questionário de *Bullying*: descreve situações envolvendo a prática e o sofrimento do *bullying* (BIFULCO; BROWN; HARRIS, 1994).
- Questionário de Experiências com Maconha (*Cannabis Expectancy Questionnaire* - CEQ): visa detalhar o padrão de uso da maconha, incluindo data de início, frequência, gastos e sintomas relacionados ao seu consumo (BARKUS *et al.*, 2006; FORTI *et al.*, 2009).
- Lista Tabaco e Álcool (*Tobacco and Alcohol List* - TAL): aborda o padrão de uso de tabaco e álcool. É composta por perguntas a respeito do tipo, quantidade e frequência de uso do tabaco e perguntas que investigam a frequência, quantidade e o tipo de álcool consumidos (JANE-LLOPIS *et al.*, 2006).
- Questionário sobre Traumas na Infância (*Childhood Trauma Questionnaire* - CTQ): investiga cinco componentes traumáticos: abuso físico, abuso emocional, abuso sexual, negligência física e negligência emocional (GRASSI-OLIVEIRA; STEIN; PEZZI, 2006; BERNSTEIN *et al.*, 2003).

Variáveis que representam material biológico

Esse conjunto se baseia em análises de biomarcadores glutamatérgicos por meio de amostras de sangue. Foram avaliadas as concentrações plasmáticas das subunidades NR1 e NR2 NMDAR (*N-methyl-D-aspartate receptor*), pois há evidências de que existe associação entre as concentrações dessas unidades no sangue e manifestação de psicose (LOUREIRO *et al.*, 2018).

3.1.2 Caracterização

O universo de estudo é composto por dois grupos (caso e controle) com um total de 488 indivíduos. O grupo caso contém 197 indivíduos (40,4%) que apresentam esquizofrenia (46%), transtorno bipolar (33%) ou transtorno depressivo (21%), em primeiro episódio psicótico. O grupo controle é constituído por 291 indivíduos (59,6%) que são indivíduos saudáveis de base populacional.

No geral, cada indivíduo apresenta um total de 357 características, descritas de acordo com a fonte de dados na Figura 3 e de acordo com a natureza das variáveis na Tabela 2. Essas características são anônimas, não é possível identificar os participantes do estudo.

Figura 3 – Distribuição das características de acordo com a fonte de dados.

Fonte: Elaborada pelo autor.

Tabela 2 – Panorama geral: Natureza das variáveis

Informação	Quantidade
Variáveis de natureza qualitativa	91 de 357 atributos = 25,5%
Variáveis de natureza quantitativa	266 de 357 atributos = 74,5%

3.1.3 Extrapolação dos resultados

Uma das nossas principais limitações foi o tamanho do conjunto de dados. Porém, isso se dá ao fato dos dados de pacientes em PEP serem raros - deve ser certificado que não houve qualquer interação anterior medicamentosa e/ou de tratamento.

É justificada a escolha dessa característica do dado pois ao se considerar as primeiras etapas do transtorno psicótico para o diagnóstico é possível uma detecção mais segura sobre as causas do transtorno, excluindo os efeitos da cronicidade da psicose e de medicamentos sobre o resultado. Assim, permite-se que os resultados apresentados possam subsidiar a assistência ao paciente e permitir uma intervenção mais rápida e eficaz em seu tratamento (PERUZZO *et al.*, 2015; PETTERSSON-YEO *et al.*, 2013).

Desta forma, são apresentadas pela primeira vez no contexto brasileiro, técnicas de mineração de dados em uma abordagem ampla e integrada dos diferentes componentes da etiologia e mecanismos envolvidos em transtornos psicóticos em primeiro episódio.

A colaboração com os pesquisadores do STREAM e EU-GEI consolidou a interação da pesquisa com alguns dos principais centros de pesquisa da Europa, China e Austrália, solidificando a internacionalização das instituições brasileiras envolvidas no trabalho (TALAMONE; CAINELLI, 2012; JONGSMA *et al.*, 2018). Esse consórcio multicêntrico internacional, com protocolos metodologicamente consistentes e uniformes assegurou a confiabilidade e qualidade dos dados investigados para garantir a extrapolação dos resultados. Entende-se por extrapolação, nesse contexto, a capacidade em estimar os valores do universo em estudo a partir de valores

amostrais explorados.

3.2 DEFINIÇÃO DO MODELO DE DECISÃO

3.2.1 Pré-processamento

O objetivo da etapa de pré-processamento é melhorar a qualidade dos dados por meio da identificação e tratamento de problemas que podem estar presentes (BATISTA *et al.*, 2003). Sendo assim, foram desenvolvidas quatro atividades nesta etapa:

1. Construção de um banco de dados relacional a fim de unir, estruturar e facilitar a manipulação dos dados.
2. Tratamento dos atributos com o objetivo de reduzir redundâncias e melhorar a integridade e o desempenho das operações nos dados. Nessa tarefa, foram utilizadas quatro medidas para categorização:
 - a) Resposta binária: quando a característica pode ser representada por duas opções mutuamente exclusivas. Por exemplo, a questão “você já usou maconha na vida?” tem como possibilidades a resposta não (representado pelo valor 0) ou a resposta sim (representado pelo valor 1).
 - b) Respostas múltiplas: quando a característica pode ser representada por vários rótulos. Por exemplo, a questão “local de nascimento do pai” tem como opção de resposta qualquer país. Nesse caso, o questionário utilizado já apresenta opções pré-definidas e categorizadas, ou seja, cada opção de resposta tem seu rótulo correspondente; essas opções são limitadas e um rótulo com “outra opção” é escolhido quando nenhuma das opções anteriores da lista é contemplada.
 - c) Respostas ordenadas: quando a variável pode representar rótulos onde a ordem é importante. Por exemplo, o questão “você já pensou que estava sendo perseguido de alguma forma? (frequência)” pode ter 4 valores quantitativos em escala, de 0 a 3, onde o valor 3 significa a frequência mais alta e 0 significa a frequência nula.
 - d) Os valores vazios e inconsistentes foram substituídos por valores inválidos.
3. Balanceamento das classes pois ao se apresentar dados com um maior número de exemplos para uma determinada classe, pode-se enviesar os modelos explorados. O balanceamento foi realizado por meio da construção de: [i] subamostras aleatórias, mantendo o número de exemplos de cada classe com base no número de exemplos da classe minoritária e/ou, [ii] sobre-amostras, construção sintética de novas instâncias de acordo com as instâncias existentes. É selecionado aleatoriamente um caso existente e seus k-vizinhos. A partir disso, novamente é selecionado aleatoriamente um desses k-vizinhos e um novo exemplo

é criado entre a combinação do caso original e o vizinho escolhido (FACELI *et al.*, 2011; WITTEN *et al.*, 2016; CHAWLA *et al.*, 2002).

4. Seleção de atributos que permite a remoção de características irrelevantes e redundantes (por exemplo, altamente correlacionadas) do conjunto de dados. Dois métodos de seleção de atributos foram utilizados:

- a) Filtragem: são algoritmos de pré-processamento gerais que não dependem de qualquer conhecimento do algoritmo de aprendizado a ser usado e a meta é selecionar um subconjunto de atributos que represente o conjunto completo. Esses métodos são altamente explorados pela literatura em investigações sobre as influências entre as características do problema e o desfecho estudado (LI *et al.*, 2017). Três métricas foram estudadas:

- i. Análise de Correlação: seleciona características que estão altamente correlacionadas com a classe e não correlacionadas entre si. A correlação, medida por meio do coeficiente de correlação de Pearson, explora a relação de quando alterações no valor de uma variável implica em alterações no valor da outra (WITTEN *et al.*, 2016).
- ii. Análise de Ganho de Informação: a maneira de medir a relevância do atributo, nesse caso, é quantificando seu ganho de informação em relação à classificação. O ganho de informação mede a informação que duas variáveis compartilham, ou seja, ele mede o quanto saber de uma dessas variáveis reduz a incerteza sobre a outra (WITTEN *et al.*, 2016).
- iii. Teste Qui-Quadrado: avalia individualmente as características em relação às classes, mediante o cálculo do teste estatístico Qui-Quadrado. O princípio básico deste teste é comparar proporções, isto é, as possíveis divergências entre as frequências observadas e esperadas para um certo evento (WITTEN *et al.*, 2016).

- b) *Wrapper*: são algoritmos que envolvem a seleção de atributos em torno de um algoritmo de indução e utilizam a acurácia resultante para avaliar o desempenho em adicionar ou remover um atributo do subconjunto em construção (DAS, 2001). Para essa abordagem foram utilizados cinco modelos de classificação que são altamente explorados na literatura: K-vizinhos Mais Próximos, Rede Bayesiana, Máquina de Vetores de Suporte, Árvores de Decisão e Rede Neural.

- i. K-vizinhos Mais Próximos (KNN): um objeto é classificado pela maioria dos votos de seus vizinhos. As configurações de $k = 1, 3, 5$ e 10 foram exploradas para analisar empiricamente as diferenças de desempenho.
- ii. Rede Bayesiana (RB): são modelos de representação do conhecimento que utilizam como base o teorema de Bayes. Esses modelos usam probabilidades

condicionais e conjugadas extraídas de fatos e relacionamentos para fazer inferências a partir de novas instâncias (FRIEDMAN; GEIGER; GOLDSZMIDT, 1997).

- iii. Máquina de Vetores de Suporte (SVM): é um classificador binário não probabilístico. Os exemplos são representados como pontos no espaço e mapeados para cada categoria seja dividida por um espaço livre o mais amplo possível, ou seja, o modelo SVM é capaz de encontrar uma separação entre as classes por meio de uma função de mapeamento de espaço (função do kernel) (SCHOLKOPF; SMOLA, 2001). Neste estudo foram testadas quatro funções do kernel: linear, polinomial, radial, sigmoidal.
- iv. Árvore de Decisão (DT): Possui como entrada uma situação descrita e um conjunto de atributos. Como resultado é gerado um gráfico (“um caminho de decisão”) que fornece o valor de uma variável de destino por meio de regras de decisão inferidas a partir dos dados (PODGORELEC *et al.*, 2002). Neste grupo de modelos foram explorados os algoritmos C4.5 e Florestas Aleatórias (RF);
- v. Rede Neural - Perceptron Multicamada (MLP): É composto por camadas de neurônios conectados entre si por pesos (sinapses) e o aprendizado ocorre através do algoritmo de retropropagação (HAYKIN, 2009).

Como a abordagem *Wrapper* depende dos algoritmos de aprendizagem, os mesmos modelos utilizados durante a construção dos subconjuntos foram explorados para a avaliação dos mesmos a fim de selecionar as melhores performances para a extração de padrões. A avaliação dos subconjuntos baseou-se nas métricas de acurácia e teste t pareado de acordo com a área sob a curva ROC (AUC) (FACELI *et al.*, 2011).

3.2.2 Extração de padrões de comportamento

O ponto principal dessa etapa é reconhecer padrões nos diversos conjuntos de dados por meio de algoritmos de construção de regras para auxiliar no diagnóstico de transtornos psicóticos.

No geral, a construção de regras usa algoritmos de aprendizado de máquina supervisionados para descrever as relações entre os conceitos explorados. Ou seja, a partir de um conjunto de dados, é possível inferir padrões de comportamento para uma determinada classe de objeto. Geralmente, essas regras são apresentadas na forma *IF* condição *THEN* conclusão. A escolha dessa abordagem se deve ao fato de que sua representação ser semelhante ao conhecimento humano, facilitando a interpretação dos resultados ao usuário final (profissionais da saúde mental) (DAUD; CORNE, 2009; WITTEN *et al.*, 2016).

Seis algoritmos serão explorados nessa etapa:

1. C4.5

É uma árvore de decisão gerada a partir do conjunto de dados rotulados, ela fornece “um caminho” até a variável de destino aprendendo regras simples. A seleção de melhor escolha de característica para construção das regras e também para o critério de parada são examinadas de acordo com a diferença na entropia de Shannon (ganho de informação normalizado) (WITTEN *et al.*, 2016).

2. Tabela de Decisão

Estabelece regras de decisão - na forma de uma tabela - que define um conjunto de ações a serem tomadas, com base em um conjunto de condições, ou seja, revela as condições que são relevantes ou irrelevantes para o resultado. Utiliza-se para construção das regras o método de busca informada *Best-First Search* e o erro da validação cruzada (KOHAVI, 1995).

3. *Repeated Incremental Pruning to Produce Error Reduction* (RIPPER)

Constrói regras adicionando uma a uma à base e também cada condição é adicionada por vez à regra atual. A escolha da melhor condição acontece de acordo com a maximização da medida do ganho de informação da regra (VIJAYARANI; DIVYA, 2011).

4. *One Rule* (OneR)

É gerada uma árvore de decisão de um nível. É construída uma única regra para cada valor de atributo. O erro de cada atributo usando a regra é calculado e, finalmente, os atributos de erro mínimo são usados na classificação (BUDDHINATH; DERRY, 2006).

5. PART

Baseado no algoritmo C4.5, gera-se uma lista de decisões usando a técnica de dividir para conquistar. Uma árvore de decisão parcial é construída em cada iteração e a melhor folha transformada em regra. Assim, na medida em que cria-se uma regra, remove-se as instâncias que essa cobre e continua-se criando regras recursivamente para as instâncias restantes até que todas sejam contempladas (FRANK; WITTEN, 1998).

6. *Ripple Down Rule Learner* (RIDOR)

É gerada uma regra padrão primeiro e depois as exceções para a regra padrão com a menor taxa de erro (ponderada). Em seguida, gera-se as “melhores” exceções para cada exceção e as itera até criar o modelo. Assim, ele executa uma expansão de exceção em forma de árvore (GAINES; COMPTON, 1995).

3.2.3 Avaliação

Essa etapa visa avaliar os padrões encontrados pelos modelos explorados anteriormente para assim identificarmos as regras de maior relevância. Duas estratégias foram utilizadas para avaliar os modelos:

1. Acurácia (Ac)

A acurácia apresenta a proporção de previsões corretas. O cálculo é derivado da matriz de confusão (Tabela 3) e representado pela Equação 3.1.

Tabela 3 – Representação da matriz de confusão

		Valor previsto	
		positivo	negativo
Valor verdadeiro	positivo	verdadeiros positivos (vp)	falsos negativos (fn)
	negativo	falsos positivos (fp)	verdadeiros negativos (vn)

$$Ac = \frac{vp + vn}{vp + fp + vn + fn} \quad (3.1)$$

2. Teste t pareado por meio da métrica da área sob a curva ROC

- Teste t pareado

O Teste t pareado (corrigido) compara as performances dos modelos de acordo com uma métrica, verificando se as diferenças de desempenho dos algoritmos par a par construídos são estatisticamente significativas com uma confiança de 95% (NADEAU; BENGIO, 2000; SOKOLOVA; JAPKOWICZ; SZPAKOWICZ, 2006).

- Área sob a curva ROC

A curva ROC é um gráfico bidimensional em que o eixo horizontal representa a taxa de erro da classe negativa (1-especificidade) e o eixo vertical contém os valores da proporção positiva verdadeira (sensibilidade). A especificidade está relacionada ao quanto um classificador é eficaz na identificação de rótulos negativos e a sensibilidade ao quanto ele é eficaz na identificação de rótulos positivos. Assim, o desempenho do classificador é medido pela área sob a curva ROC que visa analisar a capacidade de evitar classificações errôneas (HALL *et al.*, 2009).

Os modelos que obtiveram maior desempenho tiveram suas regras analisadas individualmente de acordo com:

- Ponderação da regra. As regras geradas em cada modelo foram classificadas por sua força de decisão. Há uma pontuação para cada regra e consequentemente as que são capazes de melhor distinguir as classes exploradas apresentaram maiores pontuações no modelo de decisão.

- Comparação com a literatura clínica da área de diagnóstico de transtornos psicóticos.
- Consulta a especialistas.

Por fim, ao definirmos o modelo de decisão identificamos características e relações relevantes para um conjunto de regras adequadas no auxílio ao diagnóstico de transtornos psicóticos em primeiro episódio.

3.3 FERRAMENTA WEB

A última fase teve como atividade a automatização dos modelos finais de decisão encontrados. Trata-se do desenvolvimento de uma ferramenta web para apoio à decisão clínica no diagnóstico de esquizofrenia, transtorno depressivo e transtorno bipolar, em primeiro episódio psicótico: a PEP HELP (apresentada no capítulo 4, sessão 4.3).

A PEP HELP foi desenvolvida utilizando PHP, Python, JavaScript, HTML e CSS.

O PHP (Hypertext Preprocessor) e Python são linguagens de código aberto, multiplataformas e com muitos recursos. Elas possibilitam integração com banco de dados e contêm grande apoio em documentações e soluções no quesito desenvolvimento de ferramenta web (ACHOUR *et al.*, 2006; ROSSUM, 1995).

A linguagem JavaScript é também utilizada no desenvolvimento web e tem como suas principais vantagens a simplicidade, rapidez de resposta e fácil interoperabilidade com outras linguagens (FLANAGAN, 2006).

HTML (*Hypertext Markup Language*) e CSS são linguagens de apoio no desenvolvimento web. HTML é uma linguagem de marcação, onde são estruturados os conteúdos e definidas instruções aos navegadores. CSS (*Cascading Style Sheets*) é uma linguagem de estilos que instrui os navegadores quanto a estética das páginas, construindo um layout sistematizado (POWELL, 2010).

RESULTADOS

4.1 PRÉ-PROCESSAMENTO

4.1.1 *Construção de um banco de dados relacional*

A ferramenta utilizada foi o sistema gerenciador de banco de dados (SGBD) relacional MySQL. O MySQL é gratuito, multi-plataforma e possui código fonte aberto ([MYSQL, 2001](#)).

Os dados foram originalmente cedidos em planilhas eletrônicas. Cada planilha representava um questionário aplicado. Como resultado foi desenvolvido um SGBD contendo 9 tabelas e assim, os dados para exploração foram construídos pela junção dessas tabelas, contendo 357 atributos e 488 registros.

4.1.2 *Tratamento dos atributos*

Essa atividade permitiu que o conjunto de dados obtivesse alto grau de confiabilidade e qualidade. Para isso foram analisadas três dimensões básicas: completude, consistência e correção.

A completude é a presença de todos os valores necessários para a representação do dado. A consistência é a inexistência de contradições entre os valores representantes de um dado específico e também entre as regras que caracterizam um dado e os valores armazenados. A correção é a ausência de erros nos valores ([LIMA et al., 2009](#); [BATINI et al., 2009](#)).

Os dados foram tratados de acordo com as transformações descritas na subseção 3.2.1, do capítulo 3 e ao final, tivemos uma completude de 75% (25% dos campos eram nulos ou inválidos) e as dimensões correção e consistência foram estabelecidas pela correspondência dos rótulos em cada campo aos questionários, previamente validados pelo grupo STREAM.

4.1.3 Balanceamento das classes

As Figuras 4a e 4b apresentam a distribuição inicial das classes no conjunto de dados.

Figura 4 – Distribuição das classes - pré-balanceamento.

Fonte: Elaborada pelo autor.

Há desproporcionalidade na quantidade de exemplos para cada classe. Em 4a (N=394) foi realizado o balanceamento por meio da construção de sub-amostras aleatórias. Em 4b (N=360) a classe de diagnóstico majoritária (n=90; esquizofrenia (E)) foi a base para o balanceamento, a classe controle teve sub-amostras construídas aleatoriamente a partir do conjunto inicial e as demais classes de diagnósticos (transtorno bipolar (TB) e transtorno depressivo(TD)) tiveram a construção sintética de alguns casos a partir dos exemplos existentes. As Figuras 5a e 5b apresentam a configuração final de distribuição das classes.

Figura 5 – Distribuição das classes - pós-balanceamento.

Fonte: Elaborada pelo autor.

4.1.4 Seleção de atributos

4.1.4.1 Método: Filtragem

Os subconjuntos foram construídos utilizando o método de busca *Ranker*, que classifica os atributos de acordo com a eficácia na classificação e a técnica *10-Cross-Validation*, para diminuir a variância no desempenho do método e assim, aumentar a capacidade de generalização dos resultados (WITTEN *et al.*, 2016). Cada atributo, de acordo com a métrica do algoritmo de seleção, obtinha uma pontuação de influência para classificação e, quando dois ou mais atributos apresentavam mesma pontuação apenas um deles era mantido.

A Tabela 5 mostra a quantidade de atributos de acordo com a métrica analisada cuja distribuição das classes é caso/controle e a Tabela 6 cuja distribuição das classes é a identificação do diagnóstico ¹. O subconjunto Match é composto pelos atributos em comum dos conjuntos anteriores.

Tabela 5 – Filtragem: Quantidade de atributos por subconjunto - classificação caso/controle

Subconjunto	# atributos
Análise de Correlação	195
Análise de Ganho de Informação	124
Teste Qui-Quadrado	289
Match	93

Tabela 6 – Filtragem: Quantidade de atributos por subconjunto - classificação diagnósticos

Subconjunto	# atributos
Análise de Correlação	171
Análise de Ganho de Informação	124
Teste Qui-Quadrado	230
Match	62

Com a seleção de atributos via Teste Qui-Quadrado obtivemos a menor filtragem, em média, 27% dos atributos foram removidos. Em contrapartida, com a métrica de Ganho de Informação houve remoção de 65% na quantidade de atributos. Todos os conjuntos construídos nessa atividade foram analisados na etapa de extração de padrões.

4.1.4.2 Método: Wrapper

Para a abordagem *Wrapper* foram utilizados o método de busca Guloso e a técnica *10-Cross-Validation*. Esses procedimentos podem gerar soluções localmente ótimas que se aproximam da solução globalmente ótima em um período de tempo razoável (WITTEN *et al.*, 2016).

¹ Os resultados foram apresentados de acordo com a execução, ou seja, a ordenação das tabelas seguiu as descrições do capítulo 3.

As Tabelas 7 e 8 apresentam a quantidade de atributos por subconjunto considerando respectivamente a classificação caso/controle e diagnósticos. Em ambas análises a menor filtragem ocorreu com o algoritmo 10-NN, em média 85% dos atributos foram removidos. Obtivemos a maior filtragem com o algoritmo DT, removendo, em média, 95% dos atributos do conjunto original.

Tabela 7 – *Wrapper*: Número de atributos por subconjunto - classificação caso/controle

Subconjunto	# atributos
1NN	22
3NN	28
5NN	39
10NN	45
RB	32
SVM-L	36
SVM-P	30
SVM-R	19
SVM-S	21
DT	8
RF	23
MLP	26

SVM-L: SVM-linear; SVM-P SVM-polinomial; SVM-R: SVM-radial; SVM-S: SVM-sigmoidal.

Tabela 8 – *Wrapper*: Número de atributos por subconjunto - classificação diagnósticos

Subconjunto	# atributos
1NN	41
3NN	43
5NN	50
10NN	58
RB	43
SVM-L	45
SVM-P	53
SVM-R	49
SVM-S	34
DT	28
RF	53
MLP	31

O objetivo é conseguirmos alta performance com o menor número de atributos possível a fim de também identificarmos as relações entre eles com clareza. Assim, foram selecionados dois conjuntos de cada distribuição de classificação dessa tarefa para a extração de padrões, avaliados por meio das métricas apresentadas a seguir.

As Tabelas 9 e 10 apresentam a acurácia dos subconjuntos de acordo com a distribuição de classificação. Quanto a classificação caso/controle, tivemos 50% dos conjuntos com performances acima de 90% de acurácia. Na classificação diagnósticos, a maior acurácia foi de 85,74% e 67% dos subconjuntos explorados tiveram performances acima de 80%.

As Tabelas 11 e 12 apresentam os valores de test t dos subconjuntos de acordo com a distribuição de classificação. Analisando os grupos caso/controle obtivemos 5 dos 12 subconjuntos

Tabela 9 – *Wrapper*: Acurácia - classificação caso/controle

Classificador	Subconjunto <i>Wrapper</i>											
	1NN	3NN	5NN	10NN	RB	SVM-L	SVM-P	SVM-R	SVM-S	DT	RF	MLP
1NN	95,69	93,69	93,92	90,06	87,32	89,09	93,94	96,94	95,70	95,94	87,08	89,60
3NN	95,19	94,92	91,63	91,87	90,62	92,65	92,40	96,46	93,67	95,68	89,11	90,12
5NN	93,67	93,15	93,17	92,13	90,12	90,62	91,65	94,69	93,66	94,4	88,33	88,84
10NN	90,62	92,39	94,41	90,37	92,63	91,38	91,12	92,90	93,42	93,65	88,58	90,36
RB	95,42	95,67	95,16	92,63	95,69	98,23	96,70	97,72	94,41	91,35	95,94	95,18
SVM-L	98,47	97,46	97,46	61,38	97,46	97,21	97,45	97,96	97,47	95,42	98,73	95,93
SVM-P	93,40	93,39	92,37	51,01	94,38	98,22	97,22	92,13	92,38	96,44	94,65	91,36
SVM-R	98,47	72,35	70,81	51,27	91,61	97,97	98,22	99,24	95,42	95,92	94,67	72,09
SVM-S	96,97	49,23	49,23	49,23	49,23	48,47	53,81	96,97	95,17	79,66	49,23	49,23
DT	95,67	95,68	95,44	95,69	95,44	95,67	95,18	95,67	95,19	95,69	94,92	95,42
RF	98,22	98,47	98,21	97,21	98,21	98,47	98,22	97,20	97,47	96,95	98,73	98,98
MLP	97,20	96,69	96,44	95,68	96,95	96,17	96,18	97,20	96,96	96,18	95,93	95,95
Média	95,74	89,42	89,02	79,87	89,97	91,17	91,84	96,25	95,07	93,94	89,65	87,75

Tabela 10 – *Wrapper*: Acurácia - classificação diagnósticos

Classificador	Subconjunto <i>Wrapper</i>											
	1NN	3NN	5NN	10NN	RB	SVM-L	SVM-P	SVM-R	SVM-S	DT	RF	MLP
1NN	83,89	84,72	83,89	73,33	56,39	74,72	71,11	78,06	81,67	80,28	78,33	82,78
3NN	83,33	86,39	84,72	81,11	64,72	79,17	73,61	78,89	81,67	80,00	80,83	84,44
5NN	83,06	85,83	85,56	84,44	67,78	80,28	77,22	81,67	80,00	80,56	81,39	84,17
10NN	80,83	83,33	85,28	86,67	73,89	79,17	82,78	81,11	77,78	80,00	81,11	79,44
RB	88,61	88,61	87,50	88,06	78,89	87,22	87,22	89,44	87,78	88,89	88,61	88,89
SVM-L	89,17	88,33	82,50	81,11	75,83	85,28	86,39	82,78	84,72	86,67	80,28	87,50
SVM-P	72,78	86,67	80,00	80,00	71,11	81,11	90,00	85,00	67,78	82,22	85,56	71,39
SVM-R	86,39	83,89	68,06	66,11	53,33	70,56	85,00	88,61	87,78	84,72	85,56	87,50
SVM-S	80,28	76,11	24,72	26,11	25,56	28,33	44,72	73,33	86,39	59,44	34,17	82,78
DT	86,94	87,78	88,06	87,78	80,83	86,67	88,06	87,78	87,22	87,78	88,06	87,78
RF	88,33	89,44	88,61	90,56	81,94	90,56	89,72	90,56	88,33	89,72	89,17	89,17
MLP	86,67	87,78	85,83	85,56	78,89	88,06	86,11	88,89	85,28	88,89	86,94	87,50
Média	84,19	85,74	78,73	77,57	67,43	77,59	80,16	83,84	83,03	82,43	80,00	84,44

explorados com desempenhos iguais ou acima de 0,95; os subconjuntos 1NN e SVM-R tiveram maiores desempenhos ($AUC = 0,97$), apresentando melhora estatisticamente significativa em 67% dos classificadores. Em relação aos grupos diagnósticos, 8 dos 12 classificadores apresentaram performances acima de 0,90. A maior performance foi com o subconjunto 3NN ($AUC = 0,93$) que apresentou melhora estatisticamente significativa em 8 dos 12 classificadores estudados.

Para a classificação caso/controle, diante das avaliações, um novo subconjunto foi construído, o Match. Sua construção foi feita a partir das variáveis em comum dos subconjuntos que tiveram, em média, desempenhos acima do ponto de corte do nível de significância ($\alpha = 0,05$; desempenho médio superior a 95%). Assim, os subconjuntos 1NN, SMV-R e SVM-S foram selecionados e o conjunto Match é constituído por 9 atributos. A Tabela 13 apresenta o desempenho desse conjunto. O conjunto Match não foi construído para a classificação diagnósticos por não termos obtido performances satisfatórias considerando os mesmos critérios anteriores.

O conceito de “excelente” performance é controverso e depende da aplicação envolvida,

Tabela 11 – *Wrapper*: Test t pareado - classificação caso/controle

Classificador	Subconjunto <i>Wrapper</i>											
	1NN	3NN	5NN	10NN	RB	SVM-L	SVM-P	SVM-R	SVM-S	DT	RF	MLP
1NN	0,96●	0,94●	0,94●	0,90●	0,88●	0,89●	0,94●	0,96●	0,95●	0,96●	0,87●	0,90●
3NN	0,97●	0,98●	0,96●	0,94●	0,94●	0,97●	0,97●	0,98●	0,96●	0,97●	0,95●	0,94●
5NN	0,97●	0,98●	0,98●	0,96●	0,97●	0,98●	0,98●	0,98●	0,97●	0,97●	0,97●	0,97●
10NN	0,98●	0,99●	0,98●	0,98●	0,98●	0,99●	0,98●	0,98●	0,99●	0,98●	0,98●	0,98●
RB	0,99	0,99	0,98	0,96	0,99	0,99	0,99	1,00	0,97	0,97	0,99	0,99
SVM-L	0,98●	0,97●	0,97●	0,61	0,97●	0,97●	0,97●	0,98●	0,97●	0,95●	0,99●	0,96●
SVM-P	0,93●	0,93●	0,92●	0,51	0,94●	0,98●	0,97●	0,92●	0,92●	0,96●	0,95●	0,91●
SVM-R	0,98●	0,72●	0,71●	0,51	0,92●	0,98●	0,98●	0,99●	0,95●	0,96●	0,95●	0,72●
SVM-S	0,97●	0,50	0,50	0,50	0,50	0,48	0,54	0,97●	0,95●	0,80●	0,50	0,50
DT	0,96	0,96	0,97	0,96	0,97	0,97	0,94	0,95	0,95	0,97	0,96	0,96
RF	0,99	1,00	1,00	0,99	0,99	1,00	0,99	0,99	0,99	0,98	1,00	1,00
MLP	0,99	0,99	0,98	0,97	0,98	0,99	0,98	0,98	0,98	0,98	0,99	1,00
Média	0,97	0,91	0,90	0,82	0,92	0,93	0,93	0,97	0,96	0,95	0,92	0,90

● melhoria estatisticamente significativa em relação ao conjunto geral completo (com todas as variáveis).

Tabela 12 – *Wrapper*: Test t pareado - classificação diagnósticos

Classificador	Subconjunto <i>Wrapper</i>											
	1NN	3NN	5NN	10NN	RB	SVM-L	SVM-P	SVM-R	SVM-S	DT	RF	MLP
1NN	0,90●	0,91●	0,85	0,86	0,71	0,87●	0,86●	0,86●	0,91●	0,86●	0,87	0,91●
3NN	0,92	0,95●	0,91	0,91	0,86	0,93●	0,92	0,91●	0,93●	0,91	0,93	0,95●
5NN	0,93●	0,95●	0,94●	0,95●	0,90	0,94●	0,94●	0,94●	0,96●	0,93●	0,94●	0,96●
10NN	0,94	0,96●	0,95●	0,95●	0,89	0,95●	0,94	0,95●	0,95●	0,94	0,95	0,95
RB	0,97	0,97	0,97	0,97	0,93	0,97	0,96	0,96	0,97	0,96	0,96	0,96
SVM-L	0,91●	0,89●	0,89●	0,84●	0,85●	0,89●	0,88●	0,86●	0,88●	0,88●	0,87●	0,90●
SVM-P	0,84●	0,89●	0,88●	0,85●	0,85●	0,86●	0,92●	0,87●	0,79●	0,86●	0,90●	0,80●
SVM-R	0,91●	0,89●	0,79●	0,75●	0,67●	0,80●	0,88●	0,89●	0,91●	0,87●	0,91●	0,92●
SVM-S	0,86●	0,84●	0,53	0,51	0,50	0,51	0,66●	0,86●	0,90●	0,74●	0,61●	0,88●
DT	0,93	0,94	0,90	0,93	0,89	0,92	0,91	0,91	0,92	0,94	0,93	0,93
RF	0,96	0,97	0,97	0,96	0,94	0,96	0,96	0,97	0,97	0,97	0,97	0,97
MLP	0,93	0,94	0,94	0,94	0,90	0,94	0,92	0,93	0,93	0,92	0,92	0,92
Média	0,92	0,93	0,88	0,87	0,82	0,88	0,90	0,91	0,92	0,90	0,90	0,92

● melhoria estatisticamente significativa em relação ao conjunto geral completo (com todas as variáveis).

Tabela 13 – *Wrapper*: Performance do subconjunto Match - classificação caso/controle

Classificador	Acurácia	Test t
1NN	97,46	0,98●
3NN	96,69	0,99●
5NN	94,43	0,99●
10NN	93,92	0,99●
BN	97,21	0,99
SVM-L	97,72	0,98●
SVM-P	89,33	0,89●
SVM-R	98,23	0,98●
SVM-S	97,73	0,98●
DT	96,44	0,96
RF	97,46	0,99
MLP	97,21	0,99
Média	96,15	0,97

● melhoria estatisticamente significativa em relação ao conjunto geral completo (com todas as variáveis).

geralmente, no contexto de saúde mental, valores acima de 70% são considerados satisfatórios, acima de 80% são considerados bons desempenhos e acima de 90% excelentes (RICE; HARRIS, 2005).

Com essa atividade é observada também a diferença em se trabalhar com classificação binária (primeira análise: duas classes de exploração) e com um problema multi-classes (segunda análise: 3 classificações diagnósticas e classe controle). Usualmente um problema multi-classes é mais complexo que um problema binário e empiricamente observamos uma queda nas performances das análises. Durante as análises, o problema multi-classe foi adaptado em pequenos problemas binários de acordo com a estratégia “um-contra-todos” onde cada classe é comparada com todas as outras restantes (RIFKIN; KLAUTAU, 2004). Essa estratégia foi escolhida por resolver satisfatoriamente problemas com um grande número de recursos e número reduzido de amostras (SÁNCHEZ-MAROÑO *et al.*, 2010).

Por fim, com a abordagem *Wrapper*, foram analisados na etapa de extração de padrões de comportamento:

- Classificação caso/controle: Os subconjuntos *Wrapper* DT e *Wrapper* Match. Esses subconjuntos contêm menos atributos, tendo respectivamente 8 e 9 características e ambos mantiveram excelentes desempenhos (acima de 90%) em 11 dos 12 classificadores explorados.
- Classificação diagnósticos: Os subconjuntos *Wrapper* SVM-S e *Wrapper* MLP. Ambos obtiveram as melhores performances da análise, acima de 90% em 10 dos 12 classificadores explorados. Esses também contêm uma baixa quantidade de atributos (são o segundo e o terceiro menores conjuntos construídos). O conjunto *Wrapper* DT não foi selecionado pois apesar de ter a menor quantidade de atributos, obteve performance acima de 90% em apenas 7 dos classificadores explorados.

4.2 EXTRAÇÃO DE PADRÕES DE COMPORTAMENTO

4.2.1 CLASSIFICAÇÃO: CASO/CONTROLE

4.2.1.1 Avaliação dos Modelos

A Tabela 14 mostra a quantidade de atributos por conjunto.

Os conjuntos construídos por meio da seleção de atributos - método de filtragem tiveram, em média, 43,4% menos atributos que o conjunto completo. Já os conjuntos construídos por meio do método *Wrapper* diminuíram, em média, 97,5% a quantidade de atributos para análise.

A Tabela 15 apresenta, para cada conjunto de dados do estudo, os valores de acurácia dos modelos explorados.

Tabela 14 – Número de atributos por conjunto - classificação caso/controle

Conjunto de dados	# atributos
Completo	357
SA Correlação	195
SA GI	124
SA Qq	289
SA Match	93
Wrapper DT	8
Wrapper Match	9

SA: Seleção de Atributos; GI: Ganho de Informação; Qq: Qui-quadrado.

Tabela 15 – Modelos de extração de regras: Acurácia - classificação caso/controle

Conjunto de dados	Algoritmos							Média
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	OneR	PART	RIDOR	
Completo	94,92(3,4)	94,67(3,5)	95,94(2,1)	94,91(3,6)	89,36(4,2)	94,15(2,4)	92,62(3,3)	93,79
SA Correlação	94,16(3,2)	94,67(2,8)	95,94(2,1)	95,43(2,6)	89,36(4,2)	94,68(1,8)	91,87(4,5)	93,73
SA GI	94,92(2,9)	94,67(2,8)	95,94(2,1)	94,91(3,8)	89,36(4,2)	95,69(1,7)	93,63(3,3)	94,16
SA Qq	94,67(3,7)	94,67(3,5)	95,94(2,1)	95,17(2,8)	89,36(4,2)	94,16(2,4)	92,62(3,4)	93,80
SA Match	94,67(3,9)	94,67(3,5)	95,94(2,1)	94,65(3,5)	89,36 (4,2)	95,69(1,7)	91,61(3,6)	93,80
Wrapper DT	95,44(2,0)	95,69 (1,7)	95,19(2,5)	96,95(1,1)	89,36(4,2)	95,67(2,4)	94,66(3,7)	94,71
Wrapper Match	96,19(2,7)	96,44(2,7)	96,46(2,1)	97,47(2,0)	89,36(4,2)	96,46(2,1)	94,67(2,5)	95,29
Média	95,00	95,07	95,91	94,77	89,36	95,21	93,10	

Em relação aos algoritmos, 6 dos 7 explorados tiveram performances acima de 90% considerando todos os conjuntos. Os algoritmos C4.5 (com poda), Tabela de Decisão e PART tiveram taxas de acerto acima de 95%.

Em relação aos conjuntos explorados, os conjuntos derivados do método *Wrapper* de seleção de atributos apresentaram as melhores performances, considerando todos os algoritmos. O conjunto *Wrapper Match* que teve o maior desempenho, apresentou, em média, um ganho de 2% na acurácia em relação ao conjunto completo de atributos. Com exceção do SA Correlação, os conjuntos derivados da seleção de atributos ganham em performance em relação ao conjunto que explora todas as variáveis, validando empiricamente a importância da utilização de técnicas computacionais para se eleger conjuntos mais relevantes de características no contexto de transtornos psicóticos.

Na Tabela 16 temos, para cada conjunto, os resultados do teste estatístico teste t (métrica: área sob a curva ROC - AUC) em cada modelo.

Os algoritmos C4.5 (sem poda), Tabela de Decisão e PART tiveram, em média, performances excelentes (acima de 90%) ao explorar todos os conjuntos de dados. Já o algoritmo OneR teve performance não satisfatória e apresentou um decaimento estatisticamente significativo nos valores em relação aos demais algoritmos.

Os conjuntos SA Qq, *Wrapper DT* e *Wrapper Match* tiveram as maiores performances

Tabela 16 – Modelos de extração de regras: Teste t - classificação caso/controle

Conjunto de dados	Algoritmos							Média
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	OneR	PART	RIDOR	
Completo	0,97	0,96	0,97	0,94	0,89*	0,95	0,93*	0,94
SA Correlação	0,94	0,94	0,97	0,96	0,89*	0,96	0,92*	0,94
SA GI	0,95	0,95	0,97	0,94	0,89*	0,97	0,94	0,94
SA Qq	0,96	0,96	0,97	0,96	0,89*	0,95	0,93*	0,95
SA Match	0,95	0,94	0,97	0,95	0,89*	0,96	0,92*	0,94
Wrapper DT	0,97	0,97	0,96	0,97	0,89*	0,97	0,95	0,95
Wrapper Match	0,96	0,96	0,97	0,98	0,89*	0,97	0,95	0,95
Média	0,96	0,95	0,97	0,96	0,89	0,96	0,93	

* decaimento estatisticamente significativo em relação ao algoritmo de maior performance.

ao serem explorados por todos os algoritmos (AUC = 0,95).

A Tabela 17 mostra a quantidade de regras geradas em cada modelo, por conjunto. Para essa análise foi desconsiderado o algoritmo OneR por já ter apresentado performance não satisfatória na métrica anterior.

Tabela 17 – Número de regras por conjunto - classificação caso/controle

Conjunto de dados	Algoritmos						Média
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	PART	RIDOR	
Completo	18	15	16	9	7	6	12
SA Correlação	19	11	16	9	7	5	11
SA GI	24	11	16	2	6	5	11
SA Qq	18	15	16	2	7	4	10
SA Match	18	11	16	8	6	5	11
Wrapper DT	11	11	8	3	4	6	7
Wrapper Match	10	8	16	3	5	7	8
Média	17	12	15	5	6	5	

Em média, não houve grande variação na quantidade de regras geradas pelos conjuntos. Porém, para analisarmos as regras uma a uma, aplicamos uma pontuação nos modelos, apresentada na equação 4.1.

$$Score = P\#A + AUC + P\#R \quad (4.1)$$

Onde:

$P\#A$ = Quanto menor a quantidade de atributos, maior sua pontuação.

**Ponderação feita entre 0-1

AUC = Valor de performance - área sob a curva ROC

$P\#R$ = Quanto menor a quantidade de regras, maior sua pontuação.

**Ponderação feita entre 0-1

A pontuação máxima possível é 3. As regras analisadas individualmente foram as dos modelos que apresentaram pontuações maiores que 70%, ou seja, uma pontuação maior que 2,1. Esse corte foi adotado pois em psicologia/psiquiatria aplicada e na previsão de comportamento futuro (área de domínio da aplicação), valores de AUC superiores a 0,70 são considerados satisfatórios (RICE; HARRIS, 2005).

A Tabela 18 apresenta a pontuação de cada modelo, destacando (em negrito) quais tiveram suas regras analisadas individualmente.

Tabela 18 – Pontuação de performance - classificação caso/controle

Conjunto de dados	Algoritmos					
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	PART	RIDOR
Completo	1,10	1,12	1,12	1,18	1,26	1,29
SA Correlação	1,09	1,16	1,14	1,22	1,29	1,36
SA GI	1,06	1,16	1,12	1,97	1,33	1,37
SA Qq	1,14	1,16	1,16	2,02	1,30	1,49
SA Match	1,15	1,21	1,18	1,29	1,38	1,41
Wrapper DT	2,15	2,15	2,21	2,64	2,47	2,28
Wrapper Match	2,05	2,10	1,98	2,54	2,26	2,12

4.2.1.2 Avaliação das Regras

A seguir serão apresentadas, em fluxogramas, as regras geradas pelos modelos de maior performance, selecionados anteriormente. Cada caminho possível de se percorrer no fluxograma corresponde a uma regra. Em cada possível desfecho (caso ou controle) são indicados dois números, o primeiro representa quantos exemplos foram classificados de acordo com o rótulo indicado e o segundo quantos exemplos não foram classificados de acordo com o rótulo indicado.

Diversas métricas podem ser aplicadas para avaliar a qualidade de uma regra, muitas delas são complementares e a escolha é dependente do objetivo da avaliação. A força da regra deve expressar o quão bem suas relações descrevem o conjunto explorado e, neste trabalho, ela será analisada pelos valores de suporte e erro. O suporte é a medida de números relativos de exemplos cobertos corretamente pela regra, indicando a relevância da mesma, e foi calculado pela quantidade de exemplos identificados com o rótulo indicado menos a quantidade de exemplos que não obtiveram o rótulo indicado em relação ao total de exemplos disponíveis em cada classe. O erro expressa os exemplos não classificados corretamente e foi calculado pela quantidade de exemplos que não obtiveram o rótulo indicado em relação a quantidade de exemplos que obtiveram o rótulo indicado (MONARD; BARANAUSKAS, 2003; PRATI, 2006).

O conjunto *Wrapper DT* gerou o mesmo grupo de regras e relações (Figura 6) quando analisado pelo algoritmo C4.5, utilizando ou não a poda. Oito características foram necessárias para construir o modelo, três delas pertencentes ao grupo de variáveis do questionário OPCRIT

OPCRIT.

O grupo **controle** teve somente uma regra representada, quando não houve manifestações das características exploradas, apresentando 90% de suporte (178 exemplos classificados corretamente). Porém, houve um aumento de exemplos erroneamente classificados, 9% foram equivocados. Comparando com o modelo representado pela Figura 6, a regra de maior força referente ao grupo **controle**, teve apenas 3% de erro (5 de 158 exemplos).

Em relação ao grupo **caso**, esse modelo se distribuiu em 7 regras. A característica **relação sintomas psicóticos/afetivos** se comporta como mandatória, cuja presença de qualquer manifestação já acarretaria em uma classificação **caso**. Isso nos permite simplificar o modelo, porém nos apresenta pouca informação sobre a relação entre as características estudadas.

Figura 7 – Fluxograma de regras: *Wrapper DT* e Tabela de Decisão

Fonte: Elaborada pelo autor.

O fluxograma da Figura 8 apresenta o modelo com maior pontuação. Foram necessárias 5 características: três características são pertencentes ao questionário OPCRIT e duas ao questionário CAPE. Essas características já foram apresentadas pelo modelo da Figura 6, porém esse modelo simplifica suas relações em 3 regras.

Uma regra representa a classificação do grupo **caso** com valor de suporte de 96%. Qualquer manifestação da característica **relação sintomas psicóticos/afetivos** é decisiva.

A regra mandatória para o grupo **controle** é composta pela ausência de manifestação de três características, duas delas do questionário OPCRIT - **relação sintomas psicóticos/afetivos** e **delírios persecutórios** - e uma do questionário CAPE - a frequência em relação a situação “alguma vez, você ouviu vozes quando estava só?”. O suporte da regra é de 82% (163 de 197 total de exemplos controle) e o erro de 3%.

Na Figura 9 são apresentadas duas regras para cada classe. A regra da classe **caso**

Figura 8 – Fluxograma de regras: *Wrapper* DT e RIPPER

Fonte: Elaborada pelo autor.

de maior força mostra 62% de suporte e depende exclusivamente da manifestação de **delírios persecutórios**. Em contrapartida, a regra de maior força da classe **controle** tem um maior número de relações. Mostrando 77% de suporte, houve a necessidade de abranger a não manifestação de 4 características (2 pertencentes ao questionário OPCRIT e duas pertencentes ao questionário CAPE). Essa é a segunda vez que essa combinação de relações mostra a maior força para o conjunto **controle**, a mesma combinação foi apresentada pela análise da Figura 6.

A Figura 10 apresenta a mesma regra majoritária em relação à classe **caso** da Figura 9, porém, nesse modelo, o erro é de 50%, isso porque, a métrica utilizada construiu essa regra na aleatoriedade, como complemento de todas as demais regras, que focavam em contemplar a classe **controle**. Em relação à classe **controle**, a regra majoritária apresentou 49% de suporte, contemplando 4 características. A estrutura desse fluxograma utiliza características já exploradas nos demais fluxogramas e mostram um alto valor de erro na única regra do grupo **caso** e valor de suporte abaixo da aleatoriedade (menor que 50%) na classe majoritária da classe **controle**, não agregando informação relevante ao estudo.

No modelo apresentado pela Figura 11 são mostradas 3 relações e 5 características, 3 pertencentes ao questionário OPCRIT e 2 ao questionário CAPE. Duas características que não tinham sido exploradas nos modelos anteriores - **restrição do afeto** e **alucinações auditivas em terceira pessoa** - são base para a regra de maior força do grupo **controle**. A não manifestação

Figura 9 – Fluxograma de regras: *Wrapper* DT e PART

Fonte: Elaborada pelo autor.

dessas características refletiram um suporte de 91%. Nesse modelo, a manifestação de **relação sintomas psicóticos/afetivos** também é decisiva para identificação de indivíduos que apresentam transtornos psicóticos (classe **caso**), com suporte de 96%.

O modelo explorado na Figura 12 reflete a delicadeza da construção das relações desse trabalho. Isso se deve ao fato das regras que identificam o grupo **controle** ao final do fluxograma apresentam uma “margem maior” de possíveis valores de resposta, as últimas duas características exploradas por essas regras - a frequência em relação a situação “**alguma vez, você achou que os pensamentos em sua mente não fossem seus?**” e **alteração de libido** - mostram uma gama maior de possíveis valores de resposta com o mesmo desfecho, dificultando a representatividade clínica desses caminhos de decisão.

Em relação às regras apresentadas para o grupo **caso**, é reforçada a alta relevância da manifestação das características **delírios persecutórios** e **relação sintomas psicóticos/afetivos** em sua identificação.

Dos modelos melhores avaliados, a combinação do subconjunto *Wrapper* Match com o algoritmo RIDOR foi o único que construiu regras desconexas. Na Figura 13 visualizamos cada

Figura 10 – Fluxograma de regras: *Wrapper* DT e RIDOR

Fonte: Elaborada pelo autor.

Figura 11 – Fluxograma de regras: *Wrapper* Match e RIPPER

Fonte: Elaborada pelo autor.

Figura 12 – Fluxograma de regras: *Wrapper Match* e *PART*

Fonte: Elaborada pelo autor.

regra que, na verdade, apresenta algumas variáveis de maior relevância para definir o grupo **caso**.

Nesse modelo, as variáveis **delírios persecutórios** e **relações sintomas psicóticos/afetivos** também foram decisivas ao classificar indivíduos do grupo **caso** e tiveram o maior número de suporte. Elas identificaram aproximadamente 34% dos indivíduos.

Uma regra não aparece no fluxograma pois trata-se da exceção às demais, ou seja, caso nenhuma regra seja contemplada, o modelo classificará o indivíduo como grupo **controle** (394/197). Essa regra especificamente não contribui na identificação dos grupos, sua construção reflete um teste aleatório, com erro de 50%.

Apesar de ter apresentado pontuação satisfatória, a representação desse modelo não se mostrou adequada para análise do estudo. A desconexão mostra relevância de cada uma das características na identificação dos grupos porém, não nos ajuda no estudo de um conjunto mínimo em tamanho, representatividade e relações.

Os fluxogramas construídos nos guiam para um conjunto mínimo de características relevantes em relação a identificação de transtornos psicóticos em primeiro episódio:

- **Questionário OPCRIT:** delírios persecutórios, relação sintomas psicóticos/afetivos, diminuição do apetite, restrição do afeto, alucinações auditivas na terceira pessoa e alteração da libido.
- **Questionário CAPE:**
 - Alguma vez, você achou que os pensamentos em sua mente não fossem seus?

Figura 13 – Fluxograma de regras: *Wrapper Match* e RIDOR

Fonte: Elaborada pelo autor.

- Alguma vez, você ouviu vozes quando estava só?
- Alguma vez, você achou que um sócio tivesse tomado o lugar de um membro da família, de um amigo ou de algum conhecido?
- Alguma vez, você sentiu que sua mente estava vazia?

A manifestação ou não dessas características são pontos cruciais para decisão, independentemente do nível de manifestação. Na Tabela 19 estão apresentadas as regras majoritárias de cada modelo para cada classe, sua força de decisão e inclusão ou exclusão no modelo final. Foram excluídas do modelo final as regras com valores de suporte abaixo de 70% (valor de performance satisfatório mínimo) ou regras com decisão aleatória que apresentavam valor de erro igual a 50%.

Na Tabela 20 podemos visualizar o modelo final construído. A força da regra, caso houvesse sobreposição, está de acordo com o maior valor de suporte. É importante ressaltar que o objetivo não é definir características suficientes para o diagnóstico de transtornos psicóticos e sim apontar características e relações que merecem maior atenção durante o processo.

Com exceção da característica **relação sintomas psicóticos/afetivos**, as demais são intuitivas à população e podem fomentar sinais de alerta. A ideia é poder divulgar a relevância desses sinais nos indivíduos e, caso haja percepção persistente dos mesmos, aconselhar que o médico seja procurado imediatamente. Podemos assim, além de utilizar o modelo como apoio ao diagnóstico clínico, utilizar seus achados em programas de prevenção, informativos à população.

A construção do modelo apresenta também que, apesar da incorporação de outras

Tabela 19 – Avaliação das Regras - classificação caso/controle

Modelo	Classe	Regra	Suporte	Erro	Inclusão no modelo final
Wrapper DT e C4.5	CASO	SE Delírios persecutórios = presente	62%	0%	Não
Wrapper DT e C4.5	CONTROLE	SE Delírios persecutórios = ausente E Relação sintomas psicóticos/afetivos = ausente E a frequência das situações “Alguma vez, você achou que os pensamentos em sua mente não fossem seus?” = ausente E “Alguma vez, você ouviu vozes quando estava só?” = ausente	77%	3%	Sim
Wrapper DT e Tabela de Decisão	CASO	SE Relação sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Delírios persecutórios = presente	27%	0%	Não
Wrapper DT e Tabela de Decisão	CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente	90%	9%	Sim
Wrapper DT e RIPPER	CASO	SE Relação sintomas psicóticos/afetivos = presente	96%	0%	Sim
Wrapper DT e RIPPER	CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente E a frequência da situação “Alguma vez, você ouviu vozes quando estava só?” = ausente	82%	3%	Sim
Wrapper DT e PART	CASO	SE Delírios persecutórios = presente	62%	0%	Não
Wrapper DT e PART	CONTROLE	SE Delírios persecutórios = ausente E Relação sintomas psicóticos/afetivos = ausente E a frequência das situações “Alguma vez, você achou que os pensamentos em sua mente não fossem seus?” = ausente E “Alguma vez, você ouviu vozes quando estava só?” = ausente	77%	3%	Sim
Wrapper DT e RIDOR	CASO	SE Delírios persecutórios = presente	100%	50%	Não
Wrapper DT e RIDOR	CONTROLE	SE Delírios persecutórios = ausente E Diminuição do apetite = ausente E a frequência das situações “Alguma vez, você ouviu vozes quando estava só?” = ausente E “Alguma vez, você sentiu que sua mente estava vazia?” = ausente	49%	10%	Não
Wrapper Match e RIPPER	CASO	SE Relação sintomas psicóticos/afetivos = presente	96%	0,5%	Sim
Wrapper Match e RIPPER	CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente E a frequência da situação “Alguma vez, você achou que os pensamentos em sua mente não fossem seus?” = ausente E Restrição do afeto = ausente E Alucinações auditivas na terceira pessoa = ausente	91%	1%	Sim
Wrapper Match e PART	CASO	SE Delírios persecutórios = presente	62%	0%	Não
Wrapper Match e PART	CONTROLE	SE Delírios persecutórios = ausente E Relação sintomas psicóticos/afetivos = ausente E a frequência da situação “Alguma vez, você achou que os pensamentos em sua mente não fossem seus?” = ausente E Alteração da libido = ausente	89%	3%	Sim
Wrapper DT e RIDOR	CASO	SE Delírios persecutórios = presente	19%	0%	Não
Wrapper DT e RIDOR	CONTROLE	Exceção as demais regras do modelo	100%	50%	Não

variáveis no contexto de classificação, características relacionadas aos sinais e sintomas dos pacientes são decisivas e de alta relevância.

Os dados do OPCRIT avaliam a presença de sintomas dos pacientes, prática comum no processo de diagnóstico clínico em psiquiatria. As questões de alta relevância selecionadas do OPCRIT estão de acordo com o Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM-5), a classificação padrão de transtornos mentais, e, geralmente, são apontadas como critérios sintomáticos importantes para a definição do diagnóstico. Essa importância se deve ao fato desses sintomas poderem causar danos sociais e/ou funcionais ao indivíduo ([AMERICAN PSYCHIATRIC ASSOCIATION, 2013](#); [PHALEN *et al.*, 2017](#)).

No entanto, este questionário contém 90 perguntas, o que torna sua aplicação demorada e exaustiva, favorecendo um viés nas informações obtidas. Com os resultados explorados acima, as características de análise deste questionário seriam reduzidas em 93%, ajudando assim a agilidade, confiabilidade e validade do processo diagnóstico.

Também foram apresentadas características do questionário CAPE - características que não são comumente exploradas, como as questões descritas no CAPE, no processo diagnóstico de transtornos psicóticos. Este questionário apresenta informações sobre sentimentos, pensamentos e experiências mentais. No entanto, considerando as variáveis estudadas no conjunto CAPE (84 características), a aplicação de técnicas de mineração de dados permitiu um foco inicial (4 características mais relevantes) para estudar a incorporação e relevância dessas variáveis no processo diagnóstico de primeiro episódio psicótico.

Recentemente, essas informações são apontadas como sinais preliminares de alerta para um possível episódio psicótico e a literatura reforça a importância de identificar essas variáveis clínicas para construir uma visão abrangente das evidências atuais sobre os caminhos dos cuidados nos estágios iniciais dos transtornos psicóticos em grupos de risco ([GRONHOLM *et al.*, 2017](#); [RAGAZZI *et al.*, 2020](#)).

Em relação aos algoritmos explorados, o algoritmo de indução de regras RIPPER se destacou dos demais, tendo maior desempenho geral e regras majoritárias com alto valor de suporte (acima de 80%). Diante disso, ele pode ser considerado um candidato promissor na extração de regras para área da psiquiatria, em especial no estudo de transtornos psicóticos.

Tabela 20 – Modelo Final - classificação caso/controle

Classe	Regra	Suporte	Erro
CASO	SE Relação sintomas psicóticos/afetivos = presente	96%	0%
CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente	90%	9%
CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Restrição do afeto = ausente E Delírios persecutórios = ausente E a frequência da situação “Alguma vez, você achou que os pensamentos em sua mente não fossem seus?” = ausente E Alucinações auditivas na terceira pessoa = ausente	91%	1%
CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Alteração da libido = ausente Delírios persecutórios = ausente E a frequência da situação “Alguma vez, você achou que os pensamentos em sua mente não fossem seus?” = ausente	89%	3%
CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente E a frequência da situação “Alguma vez, você ouviu vozes quando estava só?” = ausente	82%	3%
CONTROLE	SE Relação sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente E a frequência das situações “Alguma vez, você achou que os pensamentos em sua mente não fossem seus?” = ausente E “Alguma vez, você ouviu vozes quando estava só?” = ausente	77%	3%

4.2.2 CLASSIFICAÇÃO: DIAGNÓSTICOS

4.2.2.1 Avaliação dos Modelos

A Tabela 21 mostra a quantidade de atributos por conjunto.

Tabela 21 – Número de atributos por conjunto - classificação diagnósticos

Conjunto de dados	# atributos
Completo	357
SA Correlação	171
SA GI	124
SA Qq	230
SA Match	62
Wrapper SVM-S	34
Wrapper MLP	31

Tivemos, em média, uma diminuição de 59% na quantidade de atributos com a filtragem e 91% com o wrapper.

Para cada conjunto, a Tabela 22 apresenta os valores de acurácia dos modelos.

Tabela 22 – Modelos de extração de regras: Acurácia - classificação diagnósticos

Conjunto de dados	Algoritmos							Média
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	OneR	PART	RIDOR	
Completo	84,72(5,8)	85,28(6,1)	83,89(9,2)	81,11(7,8)	65,00(5,4)	83,06(6,0)	81,11(7,1)	80,60
SA Correlação	84,72(7,0)	85,83(7,8)	83,61(9,8)	84,17(5,5)	65,00(5,4)	83,06(7,4)	80,56(6,9)	80,99
SA GI	85,28(6,8)	85,56(6,5)	83,89(9,6)	84,44(6,3)	65,00(5,4)	84,44(5,8)	79,72(6,6)	81,19
SA Qq	84,72(6,1)	85,56(6,7)	83,33(9,2)	80,28(5,4)	65,00(5,4)	82,50(4,9)	79,72(6,4)	80,16
SA Match	86,67(7,1)	86,67(7,7)	83,89(10,2)	82,22(6,5)	65,00(5,4)	84,17(6,8)	78,61(7,8)	81,03
Wrapper SVM-S	84,72(5,1)	87,22(5,5)	83,89(10,1)	83,33(4,9)	65,00(5,4)	85,56(4,3)	81,39(6,1)	81,59
Wrapper MLP	87,50(6,1)	87,78(6,5)	83,33(9,9)	86,94(5,4)	65,00(5,4)	83,89(6,1)	84,44(6,4)	82,70
Média	85,48	86,27	83,69	83,21	65,00	83,81	80,79	

Seis dos sete algoritmos estudados obtiveram, em média, boas performances, acima de 80%. Houve um ganho de 21,27% entre a melhor performance - C4.5 (com poda): 86,27% - e a pior performance - OneR: 65%.

Em relação aos conjuntos, 5 de 6 ganharam, em média, em performance do conjunto completo de atributos. O maior ganho foi de 2,1% com a exploração do conjunto *Wrapper* MLP.

A Tabela 23 apresenta os valores do test t.

Tabela 23 – Modelos de extração de regras: Test t - classificação diagnósticos

Conjunto de dados	Algoritmos							Média
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	OneR	PART	RIDOR	
Completo	0,92	0,92	0,91	0,86	0,54*	0,90	0,86	0,84
SA Correlação	0,92	0,91	0,91	0,87	0,54*	0,88	0,83*	0,84
SA GI	0,92	0,90	0,91	0,91	0,54*	0,90	0,83*	0,84
SA Qq	0,91	0,90	0,90	0,87	0,54*	0,89	0,83*	0,83
SA Match	0,93	0,91	0,91	0,86	0,54*	0,90	0,82*	0,84
<i>Wrapper</i> SVM-S	0,91	0,92	0,90	0,89	0,54*	0,89	0,86	0,84
<i>Wrapper</i> MLP	0,92	0,93	0,90	0,91	0,54*	0,92	0,87	0,86
Média	0,92	0,91	0,91	0,88	0,54*	0,90	0,84	

Com essa métrica, 4 algoritmos apresentaram performances excelentes (acima de 90%). O algoritmo OneR apresentou valores não relevantes para análise. Alguns conjuntos estudados pelo algoritmo RIDOR também obtiveram performances inferiores as demais explorações.

O conjunto *Wrapper* MLP, em média com maior valor em performance, ao ser analisado por todos os algoritmos, apresentou 2% de ganho de desempenho em relação a exploração do conjunto total de dados.

A Tabela 24 mostra a quantidade de regras geradas. Nessa abordagem, o algoritmo OneR não foi considerado por já ter apresentado performance não satisfatória na métrica anterior.

Tabela 24 – Número de regras por conjunto - classificação diagnósticos

Conjunto de dados	Algoritmos						Média
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	PART	RIDOR	
Completo	35	25	29	8	19	18	22
SA Correlação	35	24	27	6	17	18	21
SA GI	26	22	27	11	19	20	21
SA Qq	36	26	27	6	17	18	22
SA Match	29	22	27	8	17	20	21
<i>Wrapper</i> SVM-S	42	17	26	9	12	18	21
<i>Wrapper</i> MLP	34	13	26	8	20	20	20
Média	34	21	27	8	17	19	

Tivemos o menor número de regras geradas com o algoritmo RIPPER e os conjuntos SA Correlação e SA Qq, gerando 6 regras. Ao se comparar com o maior número de regras geradas (conjunto *Wrapper* SVM-S e algoritmo C4.5 (sem poda); 42 regras), tivemos 86% de redução na

quantidade de regras para análise. Porém, para analisarmos as regras detalhadamente, a Tabela 25 apresenta as pontuações de performances. Em negrito estão destacados os conjuntos que tiveram as regras avaliadas individualmente (acima de 70% de desempenho; pontuação maior que 2,1).

Tabela 25 – Pontuação de performance - classificação diagnósticos

Conjunto de dados	Algoritmos					
	C4.5 (sem poda)	C4.5 (com poda)	Tabela de Decisão	RIPPER	PART	RIDOR
Completo	1,18	1,25	1,20	1,38	1,30	1,28
SA Correlação	1,27	1,34	1,31	1,72	1,41	1,34
SA GI	1,40	1,42	1,38	1,34	1,47	1,38
SA Qq	1,08	1,27	1,26	1,67	1,38	1,30
SA Match	1,64	1,68	1,63	1,79	1,75	1,62
Wrapper SVM-S	2,05	2,27	2,13	2,56	2,39	2,19
Wrapper MLP	2,10	2,39	2,13	2,66	2,22	2,17

4.2.2.2 Avaliação das Regras

A complexidade e a sutileza das relações entre os diagnósticos estudados estão refletidos nos fluxogramas das regras geradas pelos modelos selecionados na seção anterior, apresentados a seguir. Houve uma quantidade maior de características e relações apontadas nesse conjunto de análise (identificação de diagnósticos) para a construção das regras.

O modelo da Figura 14 apresentou 14 características para a identificação dos diagnósticos, pertencentes a três questionários: 11 do OPCRIT, 2 do CAPE e 1 do CTQ. É a primeira vez que uma característica sobre **traumas na infância (questionário CTQ)** aparece com alta relevância nos modelos - **“Eu apanhei tanto que um professor, vizinho ou médico chegou a notar”**. No total, 17 regras são mostradas e em relação a cada grupo, tivemos:

Transtorno Bipolar: 7 regras e 14 características. Regra majoritária: 63% de suporte e 2 características base: **relações sintomas psicóticos/afetivos** e **aumento da autoestima**. Para identificação do transtorno bipolar, pode-se destacar a manifestação, em qualquer nível, da característica **aumento da autoestima**.

Esquizofrenia: 5 regras e 9 características. Regra majoritária: 64% de suporte e 1 característica base: **relações sintomas psicóticos/afetivos**.

Transtorno Depressivo: 3 regras e 7 características. Regra majoritária: 93% de suporte e 4 características base: **relações sintomas psicóticos/afetivos**, **aumento da autoestima**, **pensamentos acelerados** e **atividade excessiva**. Pode-se destacar que a ausência da manifestação das últimas 3 características visam a identificação do transtorno depressivo ao invés do transtorno bipolar - que sempre se caracterizou pela manifestação das mesmas. Com isso, temos alta relevância para essas características na diferenciação, especialmente, entre os diagnósticos de transtornos depressivo e bipolar.

Controle: 2 regras e 8 características. Regra majoritária: 96% de suporte e 6 características base: **relações sintomas psicóticos/afetivos, delírios persecutórios, delírios e alucinações que duram 1 semana, distúrbio formal do pensamento negativo, embotamento afetivo** e a frequência em relação a situação “**Eu apanhei tanto que um professor, vizinho ou médico chegou a notar**”. Para esse grupo, a não manifestação das características selecionadas foi o valor de decisão da regra, assim, em contrapartida, a manifestação de qualquer uma delas visa um diagnóstico de transtorno psicótico ao indivíduo.

Figura 14 – Fluxograma de regras: *Wrapper SVM-S* e *C4.5* (com poda)

Fonte: Elaborada pelo autor.

O algoritmo Tabela de Decisão mostrou a mesma quantidade de relações e características para os conjuntos *Wrapper SVM-S* e *Wrapper MLP*, descritas na Figura 15. Foram apresentadas 26 regras a partir da combinação dos valores de 4 características do questionário OPCRIT. Nesse modelo, para qualquer desfecho, as 4 características foram selecionadas. Para cada grupo, observou-se:

Transtorno Bipolar: 13 regras. Regra majoritária: 16% de suporte.

Esquizofrenia: 8 regras. Regra majoritária: 38% de suporte.

Transtorno Depressivo: 4 regras. Regra majoritária: 18% de suporte.

Controle: 1 regra. Regra majoritária: 78% de suporte. Assim como no modelo anterior, a não manifestação das características selecionadas foi o valor de decisão da regra para o grupo controle.

Devido ao alto número de regras e sua distribuição contar apenas com as combinações de 4 características, houve um decaimento nos valores de suporte das regras majoritárias de cada grupo. Uma maior dissipação das regras pelo fluxograma traduz com menos exatidão a força da regra para análise.

O modelo da Figura 16 apresentou 3 fluxogramas desconexos, 9 regras em torno de 11 características de 3 questionários - 9 do OPCRIT, 1 do CAPE e 1 do DFAR. É a primeira vez que “**o reconhecimento de emoções faciais**” é apresentado com alta relevância para identificação dos diagnósticos. O **grupo de dados DFAR** é obtido pelo reconhecimento de uma emoção por meio de uma imagem mostrada ao paciente. Então, o caminho mostrado no fluxograma se refere a resposta dada e não necessariamente ao acerto da emoção, isso significa que estamos explorando a percepção de mundo do indivíduo. Quando essa característica fizer parte de alguma regra majoritária iremos apontar a resposta dada pelo indivíduo e também a taxa de acerto para essa emoção nessa regra. Em cada grupo, tivemos:

Transtorno Bipolar: 4 regras e 6 características. Regra majoritária: 55% de suporte e 2 características base: **relações sintomas psicóticos/afetivos** e **atividade excessiva**. Assim como no modelo da Figura 14, a característica **relações sintomas psicóticos/afetivos** quando avaliada com os **sintomas afetivos predominantes** também mostrou-se decisiva para esse grupo diagnóstico.

Esquizofrenia: 1 regra e 1 característica. Regra majoritária: 85% de suporte e 1 característica base: **relações sintomas psicóticos/afetivos**. A caracterização desse grupo também alinhou-se com o achado do modelo da Figura 14.

Transtorno Depressivo: 3 regras e 7 características. Regra majoritária: 44% de suporte e 5 características base: **relações sintomas psicóticos/afetivos**, **atividade excessiva**, **aumento da autoestima**, **perda de energia/cansaço** e **reconhecimento de emoções faciais**. Em relação a característica **reconhecimento de emoções faciais**, 65% dos indivíduos reconheceram corretamente a emoção (face mostrada = medo; rótulo dado = medo), os demais rotularam como medo faces originalmente neutras ou que expressavam raiva ou alegria.

Controle: 1 regra e 2 características. Regra majoritária: 100% de suporte e 2 características base: **relações sintomas psicóticos/afetivos**, **delírios persecutórios**. A não manifestação dessas características já apareceu como relevante em modelos anteriores, porém é a primeira vez que temos a taxa máxima de suporte. Isso sugere que qualquer manifestação

Figura 15 – Fluxograma de regras: *Wrapper SVM-S/MLP* e Tabela de Decisão

Fonte: Elaborada pelo autor.

dessas características é um alto sinal de alerta para transtornos psicóticos, corroborando com o modelo final encontrado no grupo de análise anterior (Tabela 20, classificação caso/controle).

Figura 16 – Fluxograma de regras: *Wrapper SVM-S* e *RIPPER*

Fonte: Elaborada pelo autor.

Na Figura 17 tivemos 12 regras e 19 características em torno de 4 grupos de dados - 16 do OPCRIT, 1 do DFAR, 1 do CAPE e 1 do CEQ. Os modelos de identificação diagnóstica estão explorando características não apresentadas na análise caso/controle. É a primeira vez que questões sobre **experiências com maconha (questionário CEQ)** são apresentadas com alta relevância. Em cada diagnóstico, tivemos:

Transtorno Bipolar: 5 regras e 4 características. Regra majoritária: 74% de suporte e 4 características base: **reconhecimento de emoções faciais**, **insônia intermediária (sono fragmentado)**, **relações sintomas psicóticos/afetivos** e **perda de prazer**. Todas as regras majoritárias desse modelo foram construídas a partir da característica **reconhecimento de emoções faciais**, rotulada como raiva, onde 72% dos indivíduos reconheceram corretamente a emoção raiva.

Esquizofrenia: 3 regras e 8 características. Regra majoritária: 57% de suporte e 4 características base: **reconhecimento de emoções faciais**, **insônia intermediária (sono fragmentado)**, **relações sintomas psicóticos/afetivos** e **discurso difícil de entender**. Nesse caminho do

modelo, a identificação de esquizofrenia acontece independente da rotulação da característica **discurso difícil de entender**, apontando posteriormente a regra majoritária e também apresentando a característica **rastreamento para dependência de maconha**, informação inédita em nossas explorações.

Transtorno Depressivo: 3 regras e 10 características. Regra majoritária: 83% de suporte e 8 características base: **reconhecimento de emoções faciais, insônia intermediária (sono fragmentado), relações sintomas psicóticos/afetivos, perda de prazer, aumento da autoestima, pensamentos acelerados, atividades excessivas** e a frequência da situação **“alguma vez, você ouviu vozes conversando entre si quando estava só?”**. De 8 características exploradas pela regra majoritária desse grupo, 50% delas são compartilhadas com a identificação de Transtorno Bipolar. Como apresentado também por outros modelos, é comum esses diagnósticos compartilharem mais características entre si do que com os demais grupos. O ponto chave, nesse caso, é a manifestação da característica **perda de prazer** e na frequência da situação **“alguma vez, você ouviu vozes conversando entre si quando estava só?”**.

Controle: 1 regra e 8 características. Regra majoritária: 100% de suporte e 8 características base: **reconhecimento de emoções faciais, insônia intermediária (sono fragmentado), relações sintomas psicóticos/afetivos, delírios persecutórios, ideação suicida, distúrbio formal do pensamento negativo, vozes comentando as atividades e embotamento afetivo**. Nesse grupo, como no modelo da Figura 16 tivemos 100% de suporte, porém, houve 9% de erro, em comparação com 16% apresentado pelo modelo da Figura 16.

No modelo apresentado pela Figura 18 tivemos 18 regras e 15 características, contemplando 3 questionários - 12 do OPCRIT, 1 do DFAR e 2 do CAPE. Para cada grupo diagnóstico foi apresentado:

Transtorno Bipolar: 7 regras e 13 características. Regra majoritária: 25% de suporte e 7 características base: **relações sintomas psicóticos/afetivos, delírios persecutórios, pensamentos acelerados, ideação suicida, delírio de grandeza, perda de energia/cansaço e disforia**.

Esquizofrenia: 7 regras e 12 características. Regra majoritária: 7% de suporte e 5 características base: **relações sintomas psicóticos/afetivos, delírios persecutórios, restrição do afeto, embotamento afetivo e perda de energia/cansaço**.

Transtorno Depressivo: 3 regras e 10 características. Regra majoritária: 68% de suporte e 6 características base: **relações sintomas psicóticos/afetivos, delírios persecutórios, pensamentos acelerados, ideação suicida, perda de prazer e insônia intermediária (sono fragmentado)**.

Figura 17 – Fluxograma de regras: *Wrapper* SVM-S e PART

Fonte: Elaborada pelo autor.

Controle: 1 regra e 1 características. Regra majoritária: 100% de suporte e 1 característica base: **relações sintomas psicóticos/afetivos**.

O modelo do conjunto *Wrapper SVM-S* e algoritmo RIDOR não apresentou novos achados, todas as características já foram exploradas por modelos anteriores, com relações mais representativas por terem maiores valores de suporte. Inclusive, a regra gerada para identificação do grupo controle, apesar de termos 100% de suporte, foi construída na aleatoriedade, com erro de 75%.

Na Figura 19 foram apresentadas 13 regras e 9 características de 2 questionários - 12 do OPCRIT e 1 do CTQ. Em cada grupo diagnóstico, tivemos:

Transtorno Bipolar: 5 regras e 9 características. Regra majoritária: 63% de suporte e 2 características base: **relações sintomas psicóticos/afetivos** e **aumento da autoestima**.

Esquizofrenia: 5 regras e 5 características. Regra majoritária: 64% de suporte e 1 característica base: **relações sintomas psicóticos/afetivos**.

Transtorno Depressivo: 2 regras e 5 características. Regra majoritária: 88% de suporte e 4 características base: **relações sintomas psicóticos/afetivos** e **aumento da autoestima**, **pensamentos acelerados** e **atividade excessiva**. O mesmo “caminho” leva, nesse modelo, para as regras majoritárias do grupo Transtorno Bipolar e Transtorno Depressivo. Embora apresentando uma maior quantidade de características para descrever o Transtorno Depressivo, a diferenciação é baseada na manifestação da característica **aumento da autoestima**, em qualquer nível, para o reconhecimento de indivíduos do grupo de Transtorno Bipolar.

Controle: 1 regra e 5 características. Regra majoritária: 100% de suporte e 5 característica base: **relações sintomas psicóticos/afetivos**, **delírios e alucinações que duram 1 semana**, a frequência da situação “**antes dos 17 anos alguém me molestou**” e **distúrbio formal do pensamento negativo**. Outra situação relacionada a traumas na infância é apresentada nessa análise (a frequência da situação: “**antes dos 17 anos alguém me molestou**”), sua não manifestação, junto com demais características, representa o grupo controle com apenas 8% de erro. Isso sugere que a manifestação dessa característica é um alerta para o diagnóstico de transtornos psicóticos.

O modelo da Figura 20 apresentou 6 características para a identificação dos diagnósticos, pertencentes a dois questionários: 5 do OPCRIT e 1 do CEQ. No total, 8 regras são mostradas e em relação a cada grupo, tivemos:

Transtorno Bipolar: 2 regras e 5 características. Regra majoritária: 73% de suporte e 5 características base: **delírios persecutórios**, **delírios e alucinações que duram 1 semana**,

Figura 18 – Fluxograma de regras: *Wrapper* SVM-S e RIDOR

Fonte: Elaborada pelo autor.

Figura 19 – Fluxograma de regras: *Wrapper* MLP e C4.5 (com poda)

Fonte: Elaborada pelo autor.

rastreamento para dependência de maconha, relações sintomas psicóticos/afetivos e perda de prazer.

Esquizofrenia: 4 regras e 4 características. Regra majoritária: 75% de suporte e 1 característica base: **delírios persecutórios**. Apesar de não se apresentarem na regra majoritária, as manifestações das características **delírios e alucinações que duram 1 semana** e **rastreamento para dependência de maconha** também apresentaram desfechos relacionados a identificação de esquizofrenia, apontando relevância na exploração das mesmas para esse grupo diagnóstico.

Transtorno Depressivo: 1 regra e 5 características. Regra majoritária: 84% de suporte e 5 características base: **delírios persecutórios**, **delírios e alucinações que duram 1 semana**, **rastreamento para dependência de maconha**, **relações sintomas psicóticos/afetivos**, **perda de prazer** e **aumento da autoestima**. Esse modelo alinha-se a achados anteriores com relação ao compartilhamento de diversas características entre a identificação do Transtorno Bipolar e Transtorno Depressivo, mostrando a sutileza na diferenciação desses diagnósticos.

Controle: 1 regra e 4 características. Regra majoritária: 98% de suporte e 4 características base: **delírios persecutórios**, **delírios e alucinações que duram 1 semana**, **rastreamento para dependência de maconha** e **relações sintomas psicóticos/afetivos**.

O modelo do conjunto *Wrapper* MLP e o algoritmo PART é representado por dois fluxogramas desconexos, Figuras 21 e 22. Vinte regras são apontadas, explorando 18 características,

Figura 20 – Fluxograma de regras: *Wrapper* MLP e RIPPER

Fonte: Elaborada pelo autor.

pertencentes a 4 questionários: 15 do OPCRIT, 1 do DFAR, 1 do CTQ e 1 do CEQ. Para cada identificação diagnóstica, tivemos:

Transtorno Bipolar: 5 regras e 4 características. Regra majoritária: 63% de suporte e 3 características base: **relações sintomas psicóticos/afetivos, perda de energia/cansaço e aumento da autoestima.**

Esquizofrenia: 6 regras e 14 características. Regra majoritária: 41% de suporte e 6 características base: **relações sintomas psicóticos/afetivos, alucinações auditivas na terceira pessoa, perda de prazer, ideação suicida, distúrbio formal do pensamento negativo e delírios persecutórios.**

Transtorno Depressivo: 5 regras e 9 características. Regra majoritária: 58% de suporte e 7 características base: **relações sintomas psicóticos/afetivos, perda de energia/cansaço, aumento da autoestima, pensamentos acelerados, atividade excessiva, rastreamento para dependência de maconha e reconhecimento de emoções faciais.** Em relação a característica **reconhecimento de emoções faciais**, 71% dos indivíduos reconheceram corretamente a emoção (face mostrada = medo; rótulo dado = medo).

Controle: 4 regras e 12 características. Regra majoritária: 91% de suporte e 10 características

base: **relações sintomas psicóticos/afetivos, perda de energia/cansaço, embotamento afetivo, disforia, delírios persecutórios, delírios e alucinações que duram 1 semana**, a frequência em relação a situação “antes dos 17 alguém me molestou”, **distúrbio formal do pensamento negativo, elevação do humor e perda do prazer**.

O modelo explorado pelo algoritmo PART apresentou regras com baixos valores de suporte, não adicionando achados relevantes para as análises. A regra com maior valor, que pertence ao grupo de identificação controle, reforça a importância de características já apontadas por modelos anteriores.

No último modelo de análise, mostrado pela Figura 23, tivemos 20 regras e 13 características em torno de 4 grupo de dados - 10 do OPCRIT, 1 do DFAR, 1 do CAPE e 1 do CTQ. Em cada diagnóstico foi apresentado:

Transtorno Bipolar: 7 regras e 11 características. Regra majoritária: 26% de suporte e 8 características base: a frequência em relação a situação “**ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual**”, **relações sintomas psicóticos/afetivos, delírios persecutórios, perda de energia/cansaço, pensamento acelerados, delírios e alucinações que duram uma semana, disforia e elevação do humor**.

Esquizofrenia: 4 regras e 7 características. Regra majoritária: 68% de suporte e 4 características base: a frequência em relação a situação “**ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual**”, **relações sintomas psicóticos/afetivos, distúrbio formal do pensamento negativo e delírios persecutórios**.

Transtorno Depressivo: 8 regras e 11 características. Regra majoritária: 41% de suporte e 6 características base: a frequência em relação a situação “**ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual**”, **relações sintomas psicóticos/afetivos, delírios persecutórios, perda de energia/cansaço, perda de prazer e disforia**.

Controle: 1 regra e 1 característica. Regra majoritária: 100% de suporte e 2 características base: a frequência em relação a situação “**ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual**” e **relações sintomas psicóticos/afetivos**.

Apesar de termos algumas características inéditas exploradas por esse modelo, assim como no modelo das Figuras 15, 21 e 22, a grande quantidade de regras geradas proveu alta disseminação nas relações e classificações dos exemplos, agregando pouco em nossas análises, pois foram construídas regras com baixos valores de suporte. A única regra com alto valor de suporte, pertencente ao grupo controle, como no modelo do conjunto *Wrapper* SVM-S também com o algoritmo RIDOR (Figura 18), foi construída na aleatoriedade, apresentando 75% de erro.

Figura 21 – Fluxograma de regras: *Wrapper* MLP e PART (1/2)

Figura 22 – Fluxograma de regras: *Wrapper* MLP e PART (2/2)

Fonte: Elaborada pelo autor.

Após a investigação das regras individualmente dos modelos com maiores performances, tivemos, no total, um conjunto mínimo de 31 características apresentadas com alta relevância, englobando 5 grupos diferentes de dados.

- **Questionário OPCRIT:** relações sintomas psicóticos/afetivos, aumento da autoestima, pensamentos acelerados, atividade excessiva, delírios persecutórios, delírios e alucinações que duram 1 semana, distúrbio formal do pensamento negativo, embotamento afetivo, humor irritável, perda de energia/cansaço, excessiva autoculpabilização, incoerência, insônia intermediária (sono fragmentado), discurso difícil de entender, ideação suicida, vozes comentando as atividades, disforia, delírio de grandeza, perda de prazer, restrição do afeto, alucinações auditivas na terceira pessoa, elevação do humor.
- **Questionário CAPE:**
 - Alguma vez, você achou que seus sentimentos não tinham intensidade?
 - Alguma vez, você ouviu vozes conversando entre si quando estava só?
 - Alguma vez, você ouviu seus próprios pensamentos retornarem a você como um eco?
- **Questionário CTQ:**
 - Eu apanhei tanto que um professor, vizinho ou médico chegou a notar.
 - Antes dos 17 anos alguém me molestou.
 - Ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual.

Figura 23 – Fluxograma de regras: *Wrapper* MLP e RIDOR

Fonte: Elaborada pelo autor.

- **Questionário CEQ:**

- Alguma vez você, nos últimos 12 meses, teve necessidade de aumento significativo da quantidade da substância para ficar intoxicado ou obter os efeitos desejados?
- Alguma vez você teve uso continuado da substância, apesar do conhecimento da existência de problemas físicos ou psicológicos persistentes ou recorrentes que sejam provavelmente causados ou exacerbados pelo uso da substância?

- **Questionários DFAR:** reconhecimento de emoções faciais.

Diante disso, as Tabelas 26, 27, 28 e 29 apresentam as regras majoritárias para cada identificação diagnóstica, sua força de decisão e inclusão ou exclusão no modelo final, apresentado pela Tabela 30. Foram excluídas do modelo final as regras com valores de suporte abaixo de 70% (valor de performance satisfatório mínimo) ou regras com decisão aleatória que apresentavam valores de erro igual a 75%.

Empiricamente conseguimos apontar como é desafiador a diferenciação dos diagnósticos de transtornos psicóticos. Principalmente, há uma maior confusão e compartilhamento de características entre os diagnósticos de Transtornos Bipolar e Transtorno Depressivo. Para análise dos diagnósticos, características não pertencentes ao grupo de sinais e sintomas foram selecionadas em maior quantidade como informações cruciais na identificação, apoiando a hipótese de ampliarmos os estudos e técnicas de explorações de variáveis no apoio ao reconhecimento de padrões diagnósticos em psiquiatria.

Nas questões do grupo CTQ, temos a investigação de cinco componentes traumáticos da infância do indivíduo: abuso físico, abuso emocional, abuso sexual, negligência física e negligência emocional. Na literatura, há evidências que uma história de trauma na infância está associada a um risco aumentado de desenvolver um distúrbio psicótico (PAN *et al.*, 2019). Além da predição diagnóstica, há recentes evidências que os traumas na infância estão associados com piores desfechos clínicos, é apontada uma associação da alta prevalência de situações traumáticas com suicídio e auto-mutilação, fomentando a importância de questões sobre traumas na infância serem incorporadas durante a avaliação clínica (VOS *et al.*, 2019).

O grupo de dados CEQ descreve sobre a experiência do indivíduo em relação ao uso da maconha. Corroborando com a literatura atual, em estudos clínicos e epidemiológicos feitos também com dados da colaboração EU-GEI, existem evidências de que a frequência e quantidade do uso de maconha podem contribuir na variação de incidência de transtornos psicóticos (EU-GEI WP2 GROUP COLLABORATORS, 2019; QUATTRONE *et al.*, 2020).

Em relação as características do questionário DFAR - que mede o reconhecimento de expressões faciais emocionais - é apresentado na literatura clínica uma correlação na dificuldade de regulação emocional como contribuinte para a formação e manutenção de sintomas de delírios persecutórios. O achado do trabalho dessa característica como relevante para identificação

Tabela 26 – Avaliação das Regras - classificação diagnósticos - Transtorno Bipolar

Modelo	Regra	Suporte	Erro	Inclusão no modelo final
<i>Wrapper</i> SVM-S e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Aumento da autoestima = presente	63%	0%	Não
<i>Wrapper</i> SVM-S/MLP e Tabela de Decisão	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Pensamentos acelerados = presente E Delírios persecutórios = ausente E Aumento da autoestima = presente	16%	0%	Não
<i>Wrapper</i> SVM-S e RIPPER	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Atividade excessiva = presente	55%	0%	Não
<i>Wrapper</i> SVM-S e PART	Se Reconhecimento de emoções faciais = raiva E Insônia intermediária (sono fragmentado) = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de prazer = ausente ou presente por pelo menos 1 ou 2 semanas	74%	0%	Sim
<i>Wrapper</i> SVM-S e RIDOR	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Delírios persecutórios = presente E Pensamentos acelerados = ausente ou presente por pelo menos 4 dias E Ideação suicida = ausente E Delírio de grandeza = ausente E Perda de energia/cansaço = presente por pelo menos 1 semana E Disforia = ausente ou presente por pelo menos 1 semana	25%	8%	Não
<i>Wrapper</i> MLP e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Aumento da autoestima = presente	63%	0%	Não
<i>Wrapper</i> MLP e RIPPER	Se Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E Rastreamento para dependência de maconha = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de prazer = ausente	73%	4%	Sim
<i>Wrapper</i> MLP e PART	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de energia/cansaço = presente por pelo menos 1 mês E Aumento da autoestima = presente	63%	0%	Não
<i>Wrapper</i> MLP e RIDOR	Se a frequência em relação a situação “Ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual” = nunca ou poucas vezes E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Delírios persecutórios = presente E Perda de energia/cansaço = presente por pelo menos 2 semanas ou 1 mês E Pensamento acelerados = presente E Delírios e alucinações que duram uma semana = presente E Disforia = ausente ou presente por pelo menos 1 semana E Elevação do humor = presente	26%	0%	Não

Tabela 27 – Avaliação das Regras - classificação diagnósticos - Esquizofrenia

Modelo	Regra	Suporte	Erro	Inclusão no modelo final
Wrapper SVM-S e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional	64%	12%	Não
Wrapper SVM-S/MLP e Tabela de Decisão	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional E Pensamentos acelerados = ausente E Delírios persecutórios = presente E Aumento da autoestima = ausente	38%	10%	Não
Wrapper SVM-S e RIPPER	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional	85%	17%	Sim
Wrapper SVM-S e PART	Se Reconhecimento de emoções faciais = raiva E Insônia intermediária (sono fragmentado) = ausente E Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional E Discurso difícil de entender = ausente	57%	7%	Não
Wrapper SVM-S e RIDOR	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos e afetivos estão equilibrados E Delírios persecutórios = ausente E Restrição do afeto = presente E Embotamento afetivo = presente E Perda de energia/cansaço = presente por pelo menos 1 mês	7%	8%	Não
Wrapper MLP e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional	64%	12%	Não
Wrapper MLP e RIPPER	Se Delírios persecutórios = presente	75%	12%	Sim
Wrapper MLP e PART	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional E Alucinações auditivas na terceira pessoa = presente por uma porção significativa de tempo no período de 1 mês E Perda de prazer = ausente ou presente por pelo menos 1 semana E Ideação suicida = ausente E Distúrbio formal do pensamento negativo = ausente ou presente por menos de 1 mês ou duração inespecífica E Delírios persecutórios = ausente	41%	2%	Não
Wrapper MLP e RIDOR	Se a frequência da situação “Ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual” = nunca ou poucas vezes E Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional E Distúrbio formal do pensamento negativo = presente por uma porção significativa de tempo no período de 1 mês E Delírios persecutórios = presente	68%	0%	Não

Tabela 28 – Avaliação das Regras - classificação diagnósticos - Transtorno Depressivo

Modelo	Regra	Suporte	Erro	Inclusão no modelo final
Wrapper SVM-S e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Aumento da autoestima = ausente E Pensamentos acelerados = ausente E Atividade excessiva = ausente	88%	6%	Sim
Wrapper SVM-S/MLP e Tabela de Decisão	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Pensamentos acelerados = ausente E Delírios persecutórios = ausente E Aumento da autoestima = ausente	18%	26%	Não
Wrapper SVM-S e RIPPER	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Atividade excessiva = ausente E Aumento da autoestima = ausente E Perda de energia/cansaço = ausente E Reconhecimento de emoções faciais = medo	44%	0%	Não
Wrapper SVM-S e PART	Se Reconhecimento de emoções faciais = raiva E Insônia intermediária (sono fragmentado) = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de prazer = presente por pelo menos 1 mês E Aumento da autoestima = ausente E Pensamentos acelerados = ausente E Atividades excessivas = ausente E a frequência da situação “Alguma vez, você ouviu vozes conversando entre si quando estava só?” = nunca ou algumas vezes ou frequentemente	83%	1%	Sim
Wrapper SVM-S e RIDOR	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos e afetivos estão equilibrados E Delírios persecutórios = presente E Pensamentos acelerados = ausente ou presente por pelo menos 4 dias E Ideação suicida = presente E Perda de prazer = ausente E insônia intermediária (sono fragmentado) = presente	68%	0%	Não
Wrapper MLP e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Aumento da autoestima = ausente E Pensamentos acelerados = ausente E Atividade excessiva = ausente	88%	6%	Sim
Wrapper MLP e RIPPER	Se Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E Rastreamento para dependência de maconha = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de prazer = presente E Aumento da autoestima = ausente	84%	9%	Sim
Wrapper MLP e PART	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de energia/cansaço = presente por pelo menos 1 mês E Aumento da autoestima = ausente E Pensamentos acelerados = ausente E Atividade excessiva = ausente E Rastreamento para dependência de maconha = sim E Reconhecimento de emoções faciais = medo	58%	2%	Não
Wrapper MLP e RIDOR	Se a frequência da situação “Ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual” = nunca ou poucas vezes E Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional E Delírios persecutórios = presente E Perda de energia/cansaço = ausente ou presente por pelo menos 1 semana E Perda de prazer = ausente E Disforia = presente por pelo menos 2 semanas ou 1 mês	41%	0%	Não

Tabela 29 – Avaliação das Regras - classificação diagnósticos - Controle

Modelo	Regra	Suporte	Erro	Inclusão no modelo final
Wrapper SVM-S e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E Distúrbio formal do pensamento negativo = ausente E Embotamento afetivo = ausente E a frequência da situação “Eu apanhei tanto que um professor, vizinho ou médico chegou a notar” = nunca	96%	6%	Sim
Wrapper SVM-S/MLP e Tabela de Decisão	Se Relações sintomas psicóticos/afetivos = ausente E Pensamentos acelerados = ausente E Delírios persecutórios = ausente E Aumento da autoestima = ausente	78%	21%	Sim
Wrapper SVM-S e RIPPER	Se Relações sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente	100%	16%	Sim
Wrapper SVM-S e PART	Se Reconhecimento de emoções faciais = raiva E Insônia intermediária (sono fragmentado) = ausente E Relações sintomas psicóticos/afetivos = ausente Delírios persecutórios = ausente E Ideação suicida = ausente ou presente pelo menos uma semana E Distúrbio formal do pensamento negativo = ausente E Vozes comentando as atividades = ausente ou presente por pelo menos 1 mês E Embotamento afetivo = ausente	100%	9%	Sim
Wrapper SVM-S e RIDOR	Se Relações sintomas psicóticos/afetivos = ausente	100%	75%	Não
Wrapper MLP e C4.5 (com poda)	Se Relações sintomas psicóticos/afetivos = ausente E Delírios e alucinações que duram 1 semana = ausente a frequência em relação a situação: “Antes dos 17 anos alguém me molestou” = nunca E Distúrbio formal do pensamento negativo = ausente	100%	8%	Sim
Wrapper MLP e RIPPER	Se Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E Rastreamento para dependência de maconha = ausente E Relações sintomas psicóticos/afetivos = ausente	98%	11%	Sim
Wrapper MLP e PART	Se Relações sintomas psicóticos/afetivos = ausente E Perda de energia/cansaço = presente por pelo menos 1 mês E Embotamento afetivo = presente E Elevação do humor = ausente Disforia = ausente E Delírios persecutórios = ausente Delírios e alucinações que duram 1 semana = ausente E a frequência da situação “Antes dos 17 alguém me molestou” = nunca E Distúrbio formal do pensamento negativo = ausente E Perda do prazer = ausente ou presente por pelo menos 1 semana	91%	4%	Sim
Wrapper MLP e RIDOR	A frequência da situação “ameaçaram me machucar ou contar mentiras sobre mim se eu não fizesse algo sexual” = nunca ou poucas vezes E Relações sintomas psicóticos/afetivos = ausente	100%	75%	Não

diagnóstica, reforça que o direcionamento da instabilidade do humor pode levar a tratamentos inovadores para psicose (WESTERMANN; LINCOLN, 2011; MARWAHA *et al.*, 2014).

Assim como na análise de caso/controle, as variáveis expostas também poderão ser utilizadas como alertas a população. Os achados poderão apoiar as decisões em saúde de profissionais da saúde mental e também em ações da saúde básica, como campanhas de autocuidado e conhecimento.

Nos modelos explorados, as técnicas de pré-processamento, sobretudo a seleção de atributos, foram essencialmente importantes para obtenção da melhor performance possível de cada modelo. Quanto aos algoritmos, os algoritmos PART e RIPPER mostraram-se bons candidatos para exploração desse tipo de conjunto de dados, em sua maioria, obtiveram performances satisfatórias (acima de 70%) e apresentaram apontamentos de variáveis e relações relevantes.

Tabela 30 – Modelo final - classificação diagnósticos

Classe	Regra	Suporte	Erro
TRANSTORNO BIPOLAR	Se Reconhecimento de emoções faciais = raiva E Insônia intermediária (sono fragmentado) = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de prazer = ausente ou presente por pelo menos 1 ou 2 semanas	74%	0%
TRANSTORNO BIPOLAR	Se Delírios persecutórios = ausente E Perda de prazer = ausente E Delírios e alucinações que duram 1 semana = ausente E Rastreamento para dependência de maconha = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos	73%	4%
ESQUIZOFRENIA	Se Relações sintomas psicóticos/afetivos = os sintomas psicóticos predominam, embora possam também ocorrer perturbação afetiva ocasional	85%	17%
ESQUIZOFRENIA	Se Delírios persecutórios = presente	75%	12%
TRANSTORNO DEPRESSIVO	Se Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Aumento da autoestima = ausente E Pensamentos acelerados = ausente E Atividade excessiva = ausente	93%	6%
TRANSTORNO DEPRESSIVO	Se Reconhecimento de emoções faciais = raiva E Insônia intermediária (sono fragmentado) = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de prazer = presente por pelo menos 1 mês E Aumento da autoestima = ausente E Pensamentos acelerados = ausente E Atividades excessivas = ausente E a frequência da situação “Alguma vez, você ouviu vozes conversando entre si quando estava só?” = nunca ou algumas vezes ou frequentemente	83%	1%
TRANSTORNO DEPRESSIVO	Se Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E Rastreamento para dependência de maconha = ausente E Relações sintomas psicóticos/afetivos = os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos E Perda de prazer = presente E Aumento da autoestima = ausente	84%	9%
CONTROLE	Se Relações sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E Distúrbio formal do pensamento negativo = ausente E Embotamento afetivo = ausente E a frequência em relação a situação “Eu apanhei tanto que um professor, vizinho ou médico chegou a notar” = nunca	96%	6%
CONTROLE	Se Relações sintomas psicóticos/afetivos = ausente E Pensamentos acelerados = ausente E Delírios persecutórios = ausente E Aumento da autoestima = ausente	78%	21%
CONTROLE	Se Relações sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente	100%	16%
CONTROLE	Se Reconhecimento de emoções faciais = raiva E Insônia intermediária (sono fragmentado) = ausente E Relações sintomas psicóticos/afetivos = ausente E Delírios persecutórios = ausente E Ideação suicida = ausente ou presente pelo menos uma semana E Distúrbio formal do pensamento negativo = ausente E Vozes comentando as atividades = ausente ou presente por pelo menos 1 mês E Embotamento afetivo = ausente	100%	9%
CONTROLE	Se Relações sintomas psicóticos/afetivos = ausente E Delírios e alucinações que duram 1 semana = ausente a frequência da situação: “Antes dos 17 anos alguém me molestou” = nunca E Distúrbio formal do pensamento negativo = ausente	100%	8%
CONTROLE	Se Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E Rastreamento para dependência de maconha = ausente E Relações sintomas psicóticos/afetivos = ausente	98%	11%
CONTROLE	Se Relações sintomas psicóticos/afetivos = ausente E Perda de energia/cansaço = presente por pelo menos 1 mês E Embotamento afetivo = presente E Elevação do humor = ausente E Disforia = ausente E Delírios persecutórios = ausente E Delírios e alucinações que duram 1 semana = ausente E a frequência da situação “Antes dos 17 alguém me molestou” = nunca E Distúrbio formal do pensamento negativo = ausente E Perda do prazer = ausente ou presente por pelo menos 1 semana	91%	4%

4.3 A FERRAMENTA PEP HELP

A Figura 24 apresenta a página inicial da ferramenta PEP HELP que visa automatizar os modelos encontrados nas sessões anteriores e servir de apoio ao diagnóstico aos profissionais de saúde mental. A ferramenta está alocada em <http://bcibiocom.icmc.usp.br/pephelp/>. Para não promover o autodiagnóstico é necessário que haja controle de acesso, cujos principais usuários seriam profissionais e pesquisadores em saúde mental. As Figuras 25 e 26 mostram as telas referentes a essa função.

A imagem mostra a interface de login da ferramenta PEP HELP. No topo à esquerda, há um ícone de uma rede neural com pontos azuis e pretos conectados por linhas. Abaixo dele, o texto "PEP HELP" em uma fonte grande e negrito. Logo abaixo, em uma fonte menor, o texto: "FERRAMENTA WEB PARA APOIO À DECISÃO CLÍNICA NO DIAGNÓSTICO DE ESQUIZOFRENIA, TRANSTORNO DEPRESSIVO E TRANSTORNO BIPOLAR EM PRIMEIRO EPISÓDIO PSICÓTICO". À direita, há campos de entrada para "Login" e "Senha", um botão "Entrar" em um retângulo arredondado de cor verde, e uma opção "Lembrar de mim" com uma caixa de seleção desmarcada. Abaixo do botão "Entrar", há dois links: "Esqueceu a senha?" e "Solicitar acesso".

Figura 24 – Ferramenta PEP HELP: Tela inicial.

Fonte: Elaborada pelo autor.

A imagem mostra a interface de recuperação de senha da ferramenta PEP HELP. À esquerda, há um ícone de uma mão azul segurando um cartão amarelo com um retângulo vermelho no topo, rodeado por quatro pontos de interrogação. À direita, o título "Esqueceu a senha?" está em negrito. Abaixo dele, o texto: "Basta digitar seu endereço de email abaixo e nós lhe enviaremos um link para redefinir sua senha!". Há um campo de entrada para "Email" e um botão "Redefinir Senha" em um retângulo arredondado de cor verde. Abaixo do botão, há dois links: "Solicitar acesso" e "Já tem acesso? Entre".

Figura 25 – Ferramenta PEP HELP: Recuperação de senha.

Fonte: Elaborada pelo autor.

Figura 26 – Ferramenta PEP HELP: Solicitação de acesso.

Fonte: Elaborada pelo autor.

Ao acessar a ferramenta, temos o painel principal, apresentado pelas Figuras 27 e 28. À esquerda visualizamos as opções: [i] ícone **HELP Diagnóstico**: visa aplicação do modelo de apoio à decisão; [ii] ícone **Sobre**: uma breve apresentação da ferramenta e [iii] ícone **Links úteis**: algumas informações externas à ferramenta. À direita temos o início da aplicação **HELP Diagnóstico**, onde são apresentadas as questões selecionadas do questionário OPCRIT, o primeiro grupo de questões dos modelos de decisão. Ao final da página encontramos o botão de ação para o próximo conjunto de questões - o grupo CAPE. O acesso aos grupos de questões pode também ser feito por meio de abas (visualizadas na parte superior da figura).

As Figuras 29, 30, 31 e 32 apresentam, respectivamente, as questões dos grupos CAPE, CTQ, CEQ e DFAR. Ao final, temos o botão de ação de consulta que nos apresenta, de acordo com as regras construídas anteriormente, a possibilidade do indivíduo ser do grupo caso ou controle e, se houver alta possibilidade de ser do grupo caso, sua possibilidade em ser um diagnóstico de esquizofrenia, transtorno bipolar ou transtorno depressivo.

Assim, após o preenchimento das informações, temos a tela de saída de consulta da função de apoio ao diagnóstico, um exemplo é apresentado pela Figura 33. A partir dessa página, podemos obter um relatório com as respostas da consulta, como o mostrado pela Figura 34, ou fazer uma nova requisição. Por fim, as Figuras 35 e 36 apresentam as páginas Sobre e Links úteis.

PEP HELP

HELP Diagnóstico

Sobre

Links úteis

Psiquiatra | CRM: 0001

HELP Diagnóstico: Formulário do Paciente

OPCRIT CAPE CTQ CEQ DFAR

OPCRIT: AVALIA A PRESENÇA DE SINTOMAS PSICÓTICOS

ATIVIDADE EXCESSIVA
O paciente está marcadamente hiperativo. Isso inclui atividade motora, social e sexual.

☒ Não
☐ Pelo menos 4 dias
☐ Pelo menos 1 semana
☐ Pelo menos 2 semanas

PERDA DE ENERGIA/CANSAÇO
Queixa subjetiva de se sentir excessivamente cansado e sem energia.

☒ Não
☐ Pelo menos 1 semana
☐ Pelo menos 2 semanas
☐ Pelo menos 1 mês

DISCURSO DIFÍCIL DE ENTENDER
Discurso que torna a comunicação difícil por causa da falta de organização lógica ou organização compreensível. Não inclui disartria ou dificuldade em falar.

☒ Não
☐ Sim

INCOERÊNCIA
A construção gramatical normal das frases se rompeu. Inclui "salada de palavras" e deve ser cotada somente conservadoramente para formas extremas de distúrbio formal do pensamento.

☒ Não
☐ Presente por menos de 1 mês ou duração inespecífica
☐ Presente durante uma porção significativa de tempo no período de 1 mês

DISTÚRPIO FORMAL DO PENSAMENTO NEGATIVO
Inclui pobreza do pensamento, freqüente bloqueio do pensamento, pobreza do discurso ou pobreza do conteúdo do discurso.

☒ Não
☐ Presente por menos de 1 mês ou duração inespecífica
☐ Presente durante uma porção significativa de tempo no período de 1 mês

PENSAMENTOS ACCELERADOS
O paciente vivencia os pensamentos acelerados que ocorrem em sua cabeça, ou os outros observam fuga de ideias e acham difícil seguir o que o paciente está dizendo, ou o interrompem por causa da rapidez e quantidade do discurso.

☒ Não
☐ Pelo menos 4 dias
☐ Pelo menos 1 semana
☐ Pelo menos 2 semanas

RESTRIÇÃO DO AFETO
As respostas emocionais do paciente são limitadas em amplitude, e na entrevista há uma impressão de indiferença maliciosa ou de "falta de contato".

☒ Não
☐ Presente por menos de 1 mês ou duração inespecífica
☐ Presente durante uma porção significativa de tempo no período de 1 mês

EMBOTAMENTO AFETIVO
As respostas emocionais do paciente são persistentemente sem grande profundidade e mostram uma completa falência em ressoar a mudança exterior. Diferenças entre restrição e embotamento do afeto devem ser consideradas de grau, com embotamento sendo somente cotado em casos extremos.

☒ Não
☐ Presente por menos de 1 mês ou duração inespecífica
☐ Presente durante uma porção significativa de tempo no período de 1 mês

ELEVAÇÃO DO HUMOR
O humor predominante do paciente é de elevação.

☒ Não
☐ Pelo menos 4 dias
☐ Pelo menos 1 semana
☐ Pelo menos 2 semanas

HUMOR IRRITÁVEL
O humor do paciente é predominantemente irritável.

☒ Não
☐ Pelo menos 4 dias
☐ Pelo menos 1 semana
☐ Pelo menos 2 semanas

DISFORIA
Humor persistentemente deprimido ou "pra baixo", humor irritável e triste ou perda difusa do interesse.

☒ Não
☐ Pelo menos 1 semana
☐ Pelo menos 2 semanas
☐ Pelo menos 1 mês

PERDA DE PRAZER
Incapacidade difusa de ter prazer em qualquer atividade. Inclui marcada perda de interesse ou perda da libido.

☒ Não
☐ Pelo menos 1 semana
☐ Pelo menos 2 semanas
☐ Pelo menos 1 mês

Figura 27 – Ferramenta PEP HELP: Painel principal e HELP Diagnóstico - questões OPCRIT (1/2).

Fonte: Elaborada pelo autor.

ALTERAÇÃO DA LIBIDO
Alteração clara e persistente do interesse ou impulso sexual em comparação com o nível antes do início da doença.

☒ Não ☐ Perda da libido por pelo menos 1 semana ☐ Aumento da libido por pelo menos 1 semana

EXCESSIVA AUTOCULPABILIZAÇÃO
Sentimentos extremos de culpa e desvalorização. Pode ser de intensidade delirante ("a pior pessoa do mundo").

☒ Não ☐ Pelo menos 1 semana ☐ Pelo menos 2 semanas ☐ Pelo menos 1 mês

IDEAÇÃO SUICIDA
Preocupação com pensamentos de morte (não necessariamente a própria). Pensa em suicídio, desejaria estar morto, tentativas de suicídio.

☒ Não ☐ Pelo menos 1 semana ☐ Pelo menos 2 semanas ☐ Pelo menos 1 mês

INSÔNIA INTERMEDIÁRIA (SONO FRAGMENTADO)
Na maioria das noites, o sono está perturbado, o paciente acorda no meio do sono e tem dificuldade em voltar a adormecer.

☒ Não ☐ Sim

DIMINUIÇÃO DO APETITE
O paciente tem queixas subjetivas de diminuição do apetite (não necessariamente se observa comer menos).

☒ Não ☐ Pelo menos 1 semana ☐ Pelo menos 2 semanas ☐ Pelo menos 1 mês

RELAÇÃO SINTOMAS PSICÓTICOS/AFETIVOS

☒ Sem coocorrência
☐ Os sintomas psicóticos dominam o quadro clínico, embora possa ocorrer também perturbação afetiva ocasional
☐ Os sintomas psicóticos e afetivos estão equilibrados, mas delírios e alucinações ocorreram por pelo menos 2 semanas na ausência de sintomas de humor proeminentes
☐ Os sintomas afetivos predominam, embora possam também ocorrer sintomas psicóticos

DELÍRIOS PERSECUTÓRIOS
Incluem todos os delírios com ideação persecutória.

☒ Não ☐ Presente por menos de 1 mês ou duração inespecífica ☐ Presente durante uma porção significativa de tempo no período de 1 mês

AUMENTO DA AUTOESTIMA
O paciente acredita que é uma pessoa excepcional, com poderes, planos, talentos ou capacidades especiais. Cotar positivamente aqui se ideia sobrevalorizada, mas se a qualidade é delirante, cotar também o item (delírios de grandeza).

☒ Não ☐ Pelo menos 4 dias ☐ Pelo menos 1 semana ☐ Pelo menos 2 semanas

DELÍRIO DE GRANDEZA
O paciente tem um exagerado e irredutível sentimento da sua importância, tem poderes ou capacidades excepcionais ou acredita erroneamente que é rico ou famoso, nobre ou divino, ou parente de pessoas importantes. Inclui também delírios de identificação com Deus, anjos, o Messias, etc.

☒ Não ☐ Pelo menos 4 dias ☐ Pelo menos 1 semana ☐ Pelo menos 2 semanas

DELÍRIOS E ALUCINAÇÕES QUE DURAM 1 SEMANA
Qualquer tipo de delírio acompanhado por qualquer tipo de alucinação com duração de pelo menos 1 semana.

☒ Não ☐ Presente por menos de 1 mês ou duração inespecífica ☐ Presente durante uma porção significativa de tempo no período de 1 mês

ALUCINAÇÕES AUDITIVAS NA TERCEIRA PESSOA
Duas ou mais vozes dialogando sobre o paciente na terceira pessoa. Cotar se "verdadeiras" ou "pseudo-alucinações", isto é, a diferenciação da origem das vozes não é importante.

☒ Não ☐ Presente por menos de 1 mês ou duração inespecífica ☐ Presente durante uma porção significativa de tempo no período de 1 mês

VOZES COMENTANDO AS ATIVIDADES
O paciente ouve vozes que descrevem as suas ações, sensações ou emoções à medida que ocorrem.

☒ Não ☐ Presente por menos de 1 mês ou duração inespecífica ☐ Presente durante uma porção significativa de tempo no período de 1 mês

[→ PRÓXIMO](#)

Copyright © USP-São Carlos || PEP HELP 2020

Figura 28 – Ferramenta PEP HELP: Painel principal e HELP Diagnóstico - questões OPCRIT (2/2).

Fonte: Elaborada pelo autor.

PEP HELP

Psiquiatra | CRM: 0001

HELP Diagnóstico: Formulário do Paciente

OPCRIT CAPE CTQ CEQ DFAR

CAPE: AVALIA SENTIMENTOS, PENSAMENTOS E EXPERIÊNCIAS MENTAIS

DURANTE SUA VIDA, COM QUE FREQUÊNCIA VOCÊ EXPERIMENTOU CERTOS SENTIMENTOS, PENSAMENTOS OU EXPERIÊNCIAS MENTAIS?

ALGUMA VEZ, VOCÊ SENTIU QUE SUA MENTE ESTAVA VAZIA?

☒ Nunca ☐ Algumas vezes ☐ Frequentemente ☐ Quase sempre

ALGUMA VEZ, VOCÊ ACHOU QUE OS PENSAMENTOS EM SUA MENTE NÃO FOSSEM SEUS?

☒ Nunca ☐ Algumas vezes ☐ Frequentemente ☐ Quase sempre

ALGUMA VEZ, VOCÊ ACHOU QUE SEUS SENTIMENTOS NÃO TINHAM INTENSIDADE?

☒ Nunca ☐ Algumas vezes ☐ Frequentemente ☐ Quase sempre

ALGUMA VEZ, VOCÊ OUVIU SEUS PRÓPRIOS PENSAMENTOS RETORNAREM A VOCÊ, COMO UM ECO?

☒ Nunca ☐ Algumas vezes ☐ Frequentemente ☐ Quase sempre

ALGUMA VEZ, VOCÊ OUVIU VOZES QUANDO ESTAVA SÓ?

☒ Nunca ☐ Algumas vezes ☐ Frequentemente ☐ Quase sempre

ALGUMA VEZ, VOCÊ OUVIU VOZES CONVERSANDO ENTRE SI QUANDO ESTAVA SÓ?

☒ Nunca ☐ Algumas vezes ☐ Frequentemente ☐ Quase sempre

ALGUMA VEZ, VOCÊ ACHOU QUE UM SÓZIA TIVESSE TOMADO O LUGAR DE UM MEMBRO DA FAMÍLIA, DE UM AMIGO OU DE ALGUM CONHECIDO?

☒ Nunca ☐ Algumas vezes ☐ Frequentemente ☐ Quase sempre

→ PRÓXIMO

Copyright © USP-São Carlos || PEP HELP 2020

Figura 29 – Ferramenta PEP HELP: HELP Diagnóstico - questões CAPE.

Fonte: Elaborada pelo autor.

PEP HELP

Psiquiatra | CRM: 0001

HELP Diagnóstico: Formulário do Paciente

OPCRIT CAPE CTQ CEQ DFAR

CTQ: TRAUMAS NA INFÂNCIA

ANTES DOS 17 ANOS, EU APANHEI TANTO QUE UM PROFESSOR, VIZINHO OU MÉDICO CHEGOU A NOTAR

☒ Nunca ☐ Poucas vezes ☐ Às vezes ☐ Muitas vezes ☐ Sempre

ANTES DOS 17 ANOS, AMEAÇARAM ME MACHUCAR OU CONTAR MENTIRAS SOBRE MIM SE EU NÃO FIZESSE ALGO SEXUAL

☒ Nunca ☐ Poucas vezes ☐ Às vezes ☐ Muitas vezes ☐ Sempre

ANTES DOS 17 ANOS, ALGUÉM ME MOLESTOU

☒ Nunca ☐ Poucas vezes ☐ Às vezes ☐ Muitas vezes ☐ Sempre

→ PRÓXIMO

Copyright © USP-São Carlos || PEP HELP 2020

Figura 30 – Ferramenta PEP HELP: HELP Diagnóstico - questões CTQ.

Fonte: Elaborada pelo autor.

The screenshot displays the 'HELP Diagnóstico: Formulário do Paciente' interface. On the left is a purple sidebar with 'PEP HELP' at the top, followed by 'HELP Diagnóstico', 'Sobre', and 'Links úteis'. The main area has a header with the title and a user profile 'Psiquiatra | CRM: 0001'. Below the header is a tabbed interface with 'OPCRIT', 'CAPE', 'CTQ', 'CEQ', and 'DFAR'. The 'CEQ' tab is active, showing the title 'CEQ: EXPERIÊNCIAS COM MACONHA' in red. It contains two questions with radio button options for 'Não' and 'Sim'. The first question asks about the need for increased substance quantity in the last 12 months. The second question asks about continued use despite physical or psychological problems. A red 'PRÓXIMO' button is at the bottom. The footer reads 'Copyright © USP-São Carlos || PEP HELP 2020'.

Figura 31 – Ferramenta PEP HELP: HELP Diagnóstico - questões CEQ.

Fonte: Elaborada pelo autor.

The screenshot displays the 'HELP Diagnóstico: Formulário do Paciente' interface. On the left is a purple sidebar with 'PEP HELP' at the top, followed by 'HELP Diagnóstico', 'Sobre', and 'Links úteis'. The main area has a header with the title and a user profile 'Psiquiatra | CRM: 0001'. Below the header is a tabbed interface with 'OPCRIT', 'CAPE', 'CTQ', 'CEQ', and 'DFAR'. The 'DFAR' tab is active, showing the title 'DFAR: RECONHECIMENTO FACIAL DE EMOÇÕES ATENUADAS' in blue. It contains four questions with radio button options for 'Neutra', 'Alegria', 'Medo', and 'Raiva'. The questions ask for the majority response when presented with neutral, happy, fearful, and angry faces. A green 'CONSULTAR' button is at the bottom. The footer reads 'Copyright © USP-São Carlos || PEP HELP 2020'.

Figura 32 – Ferramenta PEP HELP: HELP Diagnóstico - questões DFAR.

Fonte: Elaborada pelo autor.

Figura 33 – Ferramenta PEP HELP: HELP Diagnóstico - página de consulta.

Fonte: Elaborada pelo autor.

Figura 34 – Ferramenta PEP HELP: HELP Diagnóstico - relatório da consulta.

Fonte: Elaborada pelo autor.

Figura 35 – Ferramenta PEP HELP: Página Sobre - breve apresentação da ferramenta.

Fonte: Elaborada pelo autor.

Figura 36 – Ferramenta PEP HELP: Página Links úteis.

Fonte: Elaborada pelo autor.

4.3.1 CONSULTA AOS ESPECIALISTAS DE DOMÍNIO

Para análise dos achados de acordo com a experiência da rotina clínica foram consultados 10 especialistas em saúde mental da Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo (2 médicos psiquiatras, 2 enfermeiras e 6 psicólogos). As regras de decisão e a ferramenta PEP HELP foram apresentadas. Todo conteúdo da tese foi discutido e aprimorado por críticas e sugestões. Em opinião geral, o trabalho foi considerado relevante pelos especialistas de domínio, mostrando o grande potencial colaborativo da exploração das ferramentas de mineração de dados para as questões clínicas do processo diagnóstico em transtornos psicóticos, inclusive em prover desdobramentos a outros estudos na área.

CONSIDERAÇÕES FINAIS

Este trabalho explorou uma área interdisciplinar entre computação e medicina, investigando técnicas computacionais que permitem um “novo olhar” aos dados que temos disponíveis na rotina clínica e, assim, contribuindo com o processo diagnóstico em saúde mental.

O estudo do modelo diagnóstico em psiquiatria afeta diretamente: [i] a qualidade de vida dos pacientes, que têm seus prognósticos cada vez mais eficazes e poderão ser submetidos a tratamentos mais efetivos e personalizados, e [ii] ao sistema de saúde, propondo políticas públicas baseadas em melhores decisões para apoiar esses pacientes e famílias.

Para promover discussão, avanço científico e troca de experiências no assunto, tivemos:

- Apresentação de trabalho no 4th BRAINN Congress - 2017, congresso internacional que aconteceu em Março/2017 na Universidade Estadual de Campinas - Unicamp ([CARVALHO *et al.*, 2017](#));
- Coorientação de um projeto de iniciação científica com duração de um ano e contemplado pelo Programa Institucional de Bolsas de Iniciação Científica (PIBIC-CNPq), gerando apresentação de trabalho no Simpósio Internacional de Iniciação Científica e Tecnológica da USP - SIICUSP, 2018 ([SALOMAO; ROSA; CARVALHO, 2018](#));
- Apresentação de trabalho no HCist - HCist - International Conference on Health and Social Care Information Systems and Technologies, conferência internacional que aconteceu em Novembro/2018 em Lisboa, Portugal. Esse trabalho gerou uma publicação na revista *Procedia Computer Science* ([CARVALHO *et al.*, 2018](#));
- Um artigo submetido para publicação: “Rule-based classification algorithms in the diagnosis of schizophrenia, bipolar disorder, and depressive disorder, with occurrence of psychotic episodes” - *Health Information Science and Systems*.

Os algoritmos de extração de regras se mostraram ferramentas promissoras para exploração de variáveis clínicas no contexto de transtornos psicóticos. Foram obtidas características e relações relevantes, com boa acurácia e com alinhamento na literatura clínica da área. Como trabalho futuro é possível incorporar a ferramenta PEP HELP à rotina clínica, capturar novos dados e aperfeiçoar os modelos de decisão.

5.1 Nota: colaboração - Portal COVID-19 BRASIL

Este trabalho de doutorado foi desenvolvido entre 2016 e 2020. Em 2020, estamos em uma situação crítica mundial, a pandemia do coronavírus. Juntamente com outros cientistas, colaboro com uma iniciativa provendo ferramentas de monitoramento e análises, em tempo real, dos dados fornecidos por fontes oficiais, sobre a propagação do vírus no país. Estão sendo utilizadas ferramentas de análise cientificamente embasadas auxiliando diretamente gestores federais, estaduais e municipais quanto às decisões de ações de enfrentamento. Todas as informações estão disponíveis em <http://ciis.fmrp.usp.br/covid19>.

Apesar da colaboração não estar diretamente ligada a tese descrita, foram compartilhadas técnicas entre os trabalhos, principalmente questões envolvendo o processo de descoberta de conhecimento em base de dados, desenvolvimento web e predição com base em modelos matemáticos.

REFERÊNCIAS

- ACHOUR, M.; BETZ, F.; DOVGAL, A.; LOPES, N. **PHP manual**. [S.l.]: The PHP Documentation Group, 2006. Citado na página 42.
- ALGHAMDI, W.; STAMATE, D.; VANG, K.; STAHL, D.; COLIZZI, M.; TRIPOLI, G.; QUATRONE, D.; AJNAKINA, O.; MURRAY, R. M.; FORTI, M. D. A prediction modelling and pattern detection approach for the first-episode psychosis associated to cannabis use. **2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA)**, IEEE, p. 825–830, 2016. Citado nas páginas 28 e 29.
- AMATO, F.; LÓPEZ, A.; PEÑA-MÉNDEZ, E. M.; VAÑHARA, P.; HAMPL, A.; HAVEL, J. Artificial neural networks in medical diagnosis. **Journal of Applied Biomedicine**, Elsevier, v. 11, n. 2, p. 47–58, 2013. Citado na página 22.
- AMERICAN PSYCHIATRIC ASSOCIATION. **Diagnostic and statistical manual of mental disorders (DSM-5®)**. [S.l.]: American Psychiatric Pub, 2013. Citado nas páginas 21 e 63.
- BARKUS, E. J.; STIRLING, J.; HOPKINS, R. S.; LEWIS, S. Cannabis-induced psychosis-like experiences are associated with high schizotypy. **Psychopathology**, Karger Publishers, v. 39, n. 4, p. 175–178, 2006. Citado na página 35.
- BATINI, C.; CAPPIELLO, C.; FRANCALANCI, C.; MAURINO, A. Methodologies for data quality assessment and improvement. **ACM computing surveys (CSUR)**, ACM, v. 41, n. 3, p. 16, 2009. Citado na página 45.
- BATISTA, G. E. d. A. P. *et al.* **Pré-processamento de dados em aprendizado de máquina supervisionado**. Tese (Doutorado) — Universidade de São Paulo, 2003. Citado na página 37.
- BERNSTEIN, D. P.; STEIN, J. A.; NEWCOMB, M. D.; WALKER, E.; POGGE, D.; AHLUVALIA, T.; STOKES, J.; HANDELSMAN, L.; MEDRANO, M.; DESMOND, D.; ZULE, W. Development and validation of a brief screening version of the Childhood Trauma Questionnaire. **Child abuse & neglect**, Elsevier, v. 27, n. 2, p. 169–190, 2003. Citado na página 35.
- BIFULCO, A.; BROWN, G. W.; HARRIS, T. O. Childhood experience of care and abuse (CECA): a retrospective interview measure. **Journal of Child Psychology and Psychiatry**, Wiley Online Library, v. 35, n. 8, p. 1419–1435, 1994. Citado na página 35.
- BRAVEMAN, P.; GOTTLIEB, L. The social determinants of health: it's time to consider the causes of the causes. **Public health reports**, SAGE Publications Sage CA: Los Angeles, CA, v. 129, n. 1_suppl2, p. 19–31, 2014. Citado na página 31.
- BUDDHINATH, G.; DERRY, D. A simple enhancement to one rule classification. **Department of Computer Science & Software Engineering. University of Melbourne, Australia**, 2006. Citado na página 40.
- BZDOK, D.; MEYER-LINDENBERG, A. Machine learning for precision psychiatry: opportunities and challenges. **Biological Psychiatry: Cognitive Neuroscience and Neuroimaging**, Elsevier, v. 3, n. 3, p. 223–230, 2018. Citado nas páginas 27 e 28.

- CÂMARA, F. P. A construção do diagnóstico psiquiátrico. **Revista Latinoamericana de Psicopatologia Fundamental**, v. 10, n. 4, p. 677–684, 2007. Citado na página 27.
- CAMILO, C. O.; SILVA, J. C. d. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. **Relatório Técnico, Universidade Federal de Goiás (UFG)**, 2009. Citado na página 25.
- CAO, H.; SCHWARZ, E. Opportunities and challenges of machine learning approaches for biomarker signature identification in psychiatry. In: **Personalized Psychiatry**. [S.l.]: Elsevier, 2020. p. 117–126. Citado na página 31.
- CARVALHO, I.; ROSA, J. L. G.; DEL-BEN, C. M.; SHUHAMA, R.; LOUREIRO, C. M.; MENEZES, P. R. A model for diagnostic decision support in mental health through the analysis of variables of different kinds. **4th BRAINN Congress**, 2017. Citado na página 95.
- CARVALHO, I.; ROSA, J. L. G.; SANTOS, K. F. dos; ALVES, D. Rule induction algorithms for classification of psychotic disorders involving social vulnerability features. **Procedia Computer Science**, Elsevier, v. 138, p. 49–55, 2018. Citado na página 95.
- CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. Smote: synthetic minority over-sampling technique. **Journal of artificial intelligence research**, v. 16, p. 321–357, 2002. Citado na página 38.
- CRADDOCK, N.; MYNORS-WALLIS, L. Psychiatric diagnosis: impersonal, imperfect and important. **The British Journal of Psychiatry**, RCP, v. 204, n. 2, p. 93–95, 2014. Citado na página 27.
- CUTHBERT, B. N. The RDoC framework: facilitating transition from icd/dsm to dimensional approaches that integrate neuroscience and psychopathology. **World Psychiatry**, Wiley Online Library, v. 13, n. 1, p. 28–35, 2014. Citado na página 23.
- CUTHBERT, B. N.; INSEL, T. R. Toward the future of psychiatric diagnosis: the seven pillars of rdoc. **BMC medicine**, BioMed Central, v. 11, n. 1, p. 126, 2013. Citado na página 23.
- DAS, S. Filters, wrappers and a boosting-based hybrid for feature selection. **ICML**, Citeseer, v. 1, p. 74–81, 2001. Citado na página 38.
- DAUD, N. R.; CORNE, D. W. Human readable rule induction in medical data mining. In: SPRINGER. **Proceedings of the European Computing Conference**. [S.l.], 2009. p. 787–798. Citado na página 39.
- EU-GEI WP2 GROUP COLLABORATORS. The contribution of cannabis use to variation in the incidence of psychotic disorder across europe (EU-GEI): a multicentre case-control study. **The Lancet Psychiatry**, Elsevier, v. 6, n. 5, p. 427–436, 2019. Citado na página 81.
- FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, v. 2, 2011. Citado nas páginas 38 e 39.
- FARMER, A. E.; JONES, I.; WILLIAMS, J.; MCGUFFIN, P. Defining schizophrenia: Operational criteria. **Journal of Mental Health**, Routledge, v. 2, n. 3, p. 209–222, 1993. Citado na página 34.
- FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI magazine**, v. 17, n. 3, p. 37, 1996. Citado na página 25.

- FLANAGAN, D. **JavaScript: the definitive guide**. [S.l.]: "O'Reilly Media, Inc.", 2006. Citado na página [42](#).
- FORTI, M. D.; MORGAN, C.; DAZZAN, P.; PARIANTE, C.; MONDELLI, V.; MARQUES, T. R.; HANDLEY, R.; LUZI, S.; RUSSO, M.; PAPARELLI, A.; BUTT, A.; STILO, S. A.; WIFFEN, B.; POWELL, J.; MURRAY, R. M. High-potency cannabis and the risk of psychosis. **The British Journal of Psychiatry**, RCP, v. 195, n. 6, p. 488–491, 2009. Citado na página [35](#).
- FRACCARO, P.; CASTELEIRO, M. A.; AINSWORTH, J.; BUCHAN, I. Adoption of clinical decision support in multimorbidity: A systematic review. **JMIR Medical Informatics**, JMIR Publications Inc., Toronto, Canada, v. 3, n. 1, p. e4, 2015. Citado na página [22](#).
- FRANK, E.; WITTEN, I. H. Generating accurate rule sets without global optimization. University of Waikato, Department of Computer Science, 1998. Citado na página [40](#).
- FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. **Machine learning**, Springer, v. 29, n. 2-3, p. 131–163, 1997. Citado na página [39](#).
- GAINES, B. R.; COMPTON, P. Induction of ripple-down rules applied to modeling large databases. **Journal of Intelligent Information Systems**, Springer, v. 5, n. 3, p. 211–228, 1995. Citado na página [40](#).
- GRASSI-OLIVEIRA, R.; STEIN, L. M.; PEZZI, J. C. Translation and content validation of the childhood trauma questionnaire into portuguese language. **Revista de saude publica**, SciELO Brasil, v. 40, n. 2, p. 249–255, 2006. Citado na página [35](#).
- GRONHOLM, P.; THORNICROFT, G.; LAURENS, K.; EVANS-LACKO, S. Mental health-related stigma and pathways to care for people at risk of psychotic disorders or experiencing first-episode psychosis: a systematic review. **Psychological Medicine**, Cambridge University Press, p. 1–13, 2017. Citado na página [63](#).
- GUPTA, M. K.; CHANDRA, P. A comprehensive survey of data mining. **International Journal of Information Technology**, Springer, p. 1–15, 2020. Citado na página [25](#).
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, ACM, v. 11, n. 1, p. 10–18, 2009. Citado na página [41](#).
- HAN, J.; PEI, J.; KAMBER, M. **Data mining: concepts and techniques**. Elsevier, 2011. Citado na página [25](#).
- HAYKIN, S. S. **Neural networks and learning machines**. Pearson Upper Saddle River, v. 3, 2009. Citado na página [39](#).
- HESLIN, M.; LOMAS, B.; LAPPIN, J.; DONOGHUE, K.; REININGHAUS, U.; ONYEJIKA, A.; CROUDACE, T.; JONES, P.; MURRAY, R.; FEARON, P. *et al.* Diagnostic change 10 years after a first episode of psychosis. **Psychological Medicine**, Cambridge University Press, v. 45, n. 13, p. 2757–2769, 2015. Citado na página [27](#).
- HUYS, Q. J.; MAIA, T. V.; FRANK, M. J. Computational psychiatry as a bridge from neuroscience to clinical applications. **Nature Neuroscience**, Nature Research, v. 19, n. 3, p. 404–413, 2016. Citado na página [22](#).

- JABLENSKY, A. Psychiatric classifications: validity and utility. **World Psychiatry**, Wiley Online Library, v. 15, n. 1, p. 26–31, 2016. Citado nas páginas 21 e 22.
- JAMES, S. L.; ABATE, D.; ABATE, K. H.; ABAY, S. M.; ABBAFATI, C.; ABBASI, N.; ABBASTABAR, H.; ABD-ALLAH, F.; ABDELA, J.; ABDELALIM, A. *et al.* Global, regional, and national incidence, prevalence, and years lived with disability for 354 diseases and injuries for 195 countries and territories, 1990–2017: a systematic analysis for the global burden of disease study 2017. **The Lancet**, Elsevier, v. 392, n. 10159, p. 1789–1858, 2018. Citado na página 21.
- JANE-LLOPIS, E.; JANÉ-LLOPIS, E.; MATYTSINA, I.; JANÉ-LLOPIS, E.; MATYTSINA, I. Mental health and alcohol, drugs and tobacco: a review of the comorbidity between mental disorders and the use of alcohol, tobacco and illicit drugs. **Drug and alcohol review**, Taylor & Francis, v. 25, n. 6, p. 515–536, 2006. Citado na página 35.
- JAUHAR, S.; KRISHNADAS, R.; NOUR, M.; CUNNINGHAM-OWENS, D.; JOHNSTONE, E.; LAWRIE, S. Is there a symptomatic distinction between the affective psychoses and schizophrenia? a machine learning approach. **Schizophrenia research**, Elsevier, v. 202, p. 241–247, 2018. Citado nas páginas 29 e 30.
- JONGSMA, H. E.; GAYER-ANDERSON, C.; LASALVIA, A.; QUATTRONE, D.; MULè, A.; SZöKE, A.; SELTEN, J.-P.; TURNER, C.; ARANGO, C.; TARRICONE, I.; BERARDI, D.; TORTELLI, A.; LLORCA, P.-M.; HAAN, L. de; BOBES, J.; BERNARDO, M.; SANJUÁN, J.; SANTOS, J. L.; ARROJO, M.; DEL-BEN, C. M.; MENEZES, P. R.; VELTHORST, E.; MURRAY, R. M.; RUTTEN, B. P.; JONES, P. B.; OS, J. v.; MORGAN, C.; KIRKBRIDE, J. B. Treated incidence of psychotic disorders in the multinational EU-GEI study. **JAMA psychiatry**, American Medical Association, v. 75, n. 1, p. 36–46, 2018. Citado nas páginas 21, 34 e 36.
- KOHAVI, R. The power of decision tables. In: SPRINGER. **European conference on machine learning**. [S.l.], 1995. p. 174–189. Citado na página 40.
- KONINGS, M.; BAK, M.; HANSEN, M.; OS, J. V.; KRABBENDAM, L. Validity and reliability of the CAPE: a self-report instrument for the measurement of psychotic experiences in the general population. **Acta Psychiatrica Scandinavica**, Wiley Online Library, v. 114, n. 1, p. 55–61, 2006. Citado na página 34.
- KONONENKO, I. Machine learning for medical diagnosis: history, state of the art and perspective. **Artificial Intelligence in Medicine**, Elsevier, v. 23, n. 1, p. 89–109, 2001. Citado nas páginas 22, 23 e 26.
- KOPROWSKI, R.; FOSTER, K. R. **Machine learning and medicine: book review and commentary**. [S.l.]: BioMed Central, 2018. Citado na página 22.
- LI, J.; CHENG, K.; WANG, S.; MORSTATTER, F.; TREVINO, R. P.; TANG, J.; LIU, H. Feature selection: A data perspective. **ACM Computing Surveys (CSUR)**, ACM, v. 50, n. 6, p. 94, 2017. Citado na página 38.
- LIMA, C. R. d. A.; SCHRAMM, J. M. d. A.; COELI, C. M.; SILVA, M. E. M. d. Revisão das dimensões de qualidade dos dados e métodos aplicados na avaliação dos sistemas de informação em saúde. **Cadernos de saúde pública**, SciELO Public Health, v. 25, p. 2095–2109, 2009. Citado na página 45.

LOUREIRO, C.; SHUHAMA, R.; FACHIM, H.; MENEZES, P.; DEL-BEN, C.; LOUZADA-JUNIOR, P. Low plasma concentrations of n-methyl-d-aspartate receptor subunits as a possible biomarker for psychosis. **Schizophrenia Research**, Elsevier, 2018. Citado na página 35.

MALLET, R. Sociodemographic schedule. **Section of Social Psychiatry, Institute of Psychiatry**, v. 183, 1997. Citado na página 35.

MARTÍNEZ, S.; ROBERTO, G.; BERMÚDEZ, Y. V. C. Modelo híbrido para el diagnóstico de enfermedades cardiovasculares basado en inteligencia artificial. **Tecnura**, v. 16, n. 33, p. 35–52, 2012. Citado na página 22.

MARWAHA, S.; BROOME, M. R.; BEBBINGTON, P. E.; KUIPERS, E.; FREEMAN, D. Mood instability and psychosis: analyses of british national survey data. **Schizophrenia bulletin**, Oxford University Press US, v. 40, n. 2, p. 269–277, 2014. Citado na página 85.

MATOS, G.; GUARNIERO, F. B.; HALLAK, J. E.; BRESSAN, R. A. Schizophrenia, the forgotten disorder: the scenario in Brazil. **Revista Brasileira de Psiquiatria**, SciELO Brasil, v. 37, n. 4, p. 269–270, 2015. Citado na página 21.

MCCUE, C. **Data mining and predictive analysis: Intelligence gathering and crime analysis**. Butterworth-Heinemann, 2014. Citado na página 26.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. In: **Sistemas inteligentes: fundamentos e aplicações**. [S.l.]: Editora Manole Ltda, 2003. Citado na página 54.

MÜLLER-STAU, M.; GRAAF-WAAR, H. de; PAANS, W. An internationally consented standard for nursing process-clinical decision support systems in electronic health records. **Computers, informatics, nursing: CIN**, Comput Inform Nurs, 2016. Citado na página 22.

MUSEN, M. A.; MIDDLETON, B.; GREENES, R. A. Clinical decision-support systems. **Bio-medical Informatics**, Springer, p. 643–674, 2014. Citado nas páginas 22 e 23.

MYSQL, A. **MySQL reference manual**. 2001. Citado na página 45.

NADEAU, C.; BENGIO, Y. Inference for the generalization error. In: **Advances in neural information processing systems**. [S.l.: s.n.], 2000. p. 307–313. Citado na página 41.

PAN, P. M.; GADELHA, A.; ARGOLO, F. C.; HOFFMANN, M. S.; ARCADEPANI, F. B.; MIGUEL, E. C.; ROHDE, L. A.; MCGUIRE, P.; SALUM, G. A.; BRESSAN, R. A. Childhood trauma and adolescent psychotic experiences in a community-based cohort: The potential role of positive attributes as a protective factor. **Schizophrenia research**, Elsevier, v. 205, p. 23–29, 2019. Citado na página 81.

PERUZZO, D.; CASTELLANI, U.; PERLINI, C.; BELLANI, M.; MARINELLI, V.; RAMBALDELLI, G.; LASALVIA, A.; TOSATO, S.; SANTI, K. D.; MURINO, V. *et al.* Classification of first-episode psychosis: a multi-modal multi-feature approach integrating structural and diffusion imaging. **Journal of Neural Transmission**, Springer, v. 122, n. 6, p. 897–905, 2015. Citado na página 36.

PETTERSSON-YEO, W.; BENETTI, S.; MARQUAND, A.; DELL'ACQUA, F.; WILLIAMS, S.; ALLEN, P.; PRATA, D.; MCGUIRE, P.; MECHELLI, A. Using genetic, cognitive and multi-modal neuroimaging data to identify ultra-high-risk and first-episode psychosis at the

individual level. **Psychological Medicine**, Cambridge Univ Press, v. 43, n. 12, p. 2547–2562, 2013. Citado na página 36.

PHALEN, P. L.; DIMAGGIO, G.; POPOLO, R.; LYSAKER, P. H. Aspects of theory of mind that attenuate the relationship between persecutory delusions and social functioning in schizophrenia spectrum disorders. **Journal of behavior therapy and experimental psychiatry**, Elsevier, v. 56, p. 65–70, 2017. Citado na página 63.

PINA-CAMACHO, L.; GARCIA-PRIETO, J.; PARELLADA, M.; CASTRO-FORNIELES, J.; GONZALEZ-PINTO, A. M.; BOMBIN, I.; GRAELL, M.; PAYA, B.; RAPADO-CASTRO, M.; JANSSEN, J. *et al.* Predictors of schizophrenia spectrum disorders in early-onset first episodes of psychosis: a support vector machine model. **European Child & Adolescent Psychiatry**, Springer, v. 24, n. 4, p. 427–440, 2015. Citado nas páginas 22 e 28.

PODGORELEC, V.; KOKOL, P.; STIGLIC, B.; ROZMAN, I. Decision trees: an overview and their use in medicine. **Journal of medical systems**, Springer, v. 26, n. 5, p. 445–463, 2002. Citado na página 39.

POWELL, T. A. **HTML & CSS.: The Complete Reference**. [S.l.]: The McGraw-Hill Companies., 2010. Citado na página 42.

PRATI, R. C. **Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos**. Tese (Doutorado) — Universidade de São Paulo, 2006. Citado na página 54.

QUATTRONE, D.; FERRARO, L.; TRIPOLI, G.; CASCIA, C. L.; QUIGLEY, H.; QUATTRONE, A.; JONGSMA, H. E.; PESCHIO, S. D.; GATTO, G.; GAYER-ANDERSON, C. *et al.* Daily use of high-potency cannabis is associated with more positive symptoms in first-episode psychosis patients: the EU-GEI case-control study. **Psychological medicine**, Cambridge University Press, p. 1–9, 2020. Citado na página 81.

RAGAZZI, T. C.; SHUHAMA, R.; SINVAL, J.; MARÔCO, J.; CORSI-ZUELLI, F.; ROZA, D. L. d.; OS, J. V.; MENEZES, P. R.; DEL-BEN, C. M. Validation of the portuguese version of the community assessment of psychic experiences and characterization of psychotic experiences in a brazilian sample. **Brazilian Journal of Psychiatry**, SciELO Brasil, n. AHEAD, 2020. Citado na página 63.

RAZZOUK, D.; MARI, J. d. J.; SHIRAKAWA, I.; WAINER, J.; SIGULEM, D. Decision support system for the diagnosis of schizophrenia disorders. **Brazilian Journal of Medical and Biological Research**, SciELO Brasil, v. 39, n. 1, p. 119–128, 2006. Citado nas páginas 22 e 28.

REIS, L. P.; FARIA, B. M.; GONCALVES, J.; CARVALHO, V. *et al.* Qvida+: Quality of life continuous estimation for clinical decision support. **2016 11th Iberian Conference on Information Systems and Technologies (CISTI)**, p. 1–7, 2016. Citado na página 22.

RICE, M. E.; HARRIS, G. T. Comparing effect sizes in follow-up studies: ROC Area, Cohen's d, and r. **Law and human behavior**, Springer, v. 29, n. 5, p. 615–620, 2005. Citado nas páginas 51 e 54.

RIFKIN, R.; KLAUTAU, A. In defense of one-vs-all classification. **Journal of machine learning research**, v. 5, n. Jan, p. 101–141, 2004. Citado na página 51.

- ROSSUM, G. Python reference manual. CWI (Centre for Mathematics and Computer Science), 1995. Citado na página 42.
- SALOMAO, M.; ROSA, J. L. G.; CARVALHO, I. Técnicas de aprendizado de máquina para análise de manifestações clínicas no apoio ao diagnóstico de transtornos psicóticos. **26 Simpósio Internacional de Iniciação Científica e Tecnológica da USP - SIICUSP**, 2018. Citado na página 95.
- SÁNCHEZ-MAROÑO, N.; ALONSO-BETANZOS, A.; GARCÍA-GONZÁLEZ, P.; BOLÓN-CANEDO, V. Multiclass classifiers vs multiple binary classifiers using filters for feature selection. In: IEEE. **The 2010 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2010. p. 1–8. Citado na página 51.
- SANISLOW, C. A.; MORRIS, S. E.; PACHECO, J.; CUTHBERT, B. N. Research domain criteria. **New Oxford Textbook of Psychiatry**, Oxford University Press, USA, p. 62, 2020. Citado na página 27.
- SATO, R. C.; SATO, G. T. K. Probabilistic graphic models applied to identification of diseases. **Einstein (São Paulo)**, SciELO Brasil, v. 13, n. 2, p. 330–333, 2015. Citado na página 22.
- SCHADT, E. E.; BJÖRKEGREN, J. L. New: network-enabled wisdom in biology, medicine, and health care. **Science Translational Medicine**, American Association for the Advancement of Science, v. 4, n. 115, 2012. Citado na página 22.
- SCHOLKOPF, B.; SMOLA, A. J. **Learning with kernels: support vector machines, regularization, optimization, and beyond**. Cambridge: MIT press, 2001. Citado na página 39.
- SIMMONS, J. M.; QUINN, K. J. The NIMH research domain criteria (RDoc) project: implications for genetics research. **Mammalian Genome**, Springer, v. 25, n. 1-2, p. 23–31, 2014. Citado na página 23.
- SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation. **Australian Conference on Artificial Intelligence**, p. 1015–1021, 2006. Citado na página 41.
- STAMATE, D.; KATRINECZ, A.; STAHL, D.; VERHAGEN, S. J.; DELESPAUL, P. A.; OS, J. van; GULOKSUZ, S. Identifying psychosis spectrum disorder from experience sampling data using machine learning approaches. **Schizophrenia research**, Elsevier, v. 209, p. 156–163, 2019. Citado na página 30.
- STEPHAN, K. E.; BACH, D. R.; FLETCHER, P. C.; FLINT, J.; FRANK, M. J.; FRISTON, K. J.; HEINZ, A.; HUYS, Q. J.; OWEN, M. J.; BINDER, E. B. *et al.* Charting the landscape of priority problems in psychiatry, part 1: classification and diagnosis. **The Lancet Psychiatry**, Elsevier, v. 3, n. 1, p. 77–83, 2016. Citado na página 21.
- TALAMONE, R. S.; CAINELLI, P. **FMRP e FMUSP integram pesquisa mundial sobre esquizofrenia**. 2012. [USP. Notícias em Pesquisa. Online; acessado em 02-Junho-2020]. Disponível em: <<https://www6.usp.br/7881/usp-integra-pesquisa-mundial-sobre-esquizofrenia/>>. Citado nas páginas 34 e 36.
- TENÓRIO, J. M.; HUMMEL, A. D.; SDEPANIAN, V. L.; PISA, I. T.; MARIN, H. de F. Experiências internacionais da aplicação de sistemas de apoio à decisão clínica em gastroenterologia. **Journal of Health Informatics**, NIH Public Access, v. 3, n. 1, p. 27, 2011. Citado na página 22.

VIJAYARANI, S.; DIVYA, M. An efficient algorithm for generating classification rules. **International Journal of Computer Science and Technology**, v. 2, n. 4, p. 512–515, 2011. Citado na página 40.

VOS, C. de; THOMPSON, A.; AMMINGER, P.; BENDALL, S.; HAAN, L. de; HARTMANN, J.; LAVOIE, S.; MARKULEV, C.; MCGORRY, P.; NIEMAN, D. *et al.* The relationship between childhood trauma and clinical characteristics in ultra-high risk for psychosis youth. **Psychosis**, Taylor & Francis, v. 11, n. 1, p. 28–41, 2019. Citado na página 81.

WESTERMANN, S.; LINCOLN, T. M. Emotion regulation difficulties are relevant to persecutory ideation. **Psychology and Psychotherapy: Theory, Research and Practice**, Wiley Online Library, v. 84, n. 3, p. 273–287, 2011. Citado na página 85.

WINSLOW, R. L.; TRAYANOVA, N.; GEMAN, D.; MILLER, M. I. Computational medicine: translating models to clinical care. **Science Translational Medicine**, American Association for the Advancement of Science, v. 4, n. 158, 2012. Citado nas páginas 27 e 31.

WITTEN, I. H.; FRANK, E.; HALL, M. A.; PAL, C. J. **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann, 2016. Citado nas páginas 38, 39, 40 e 47.

WOUT, M. van't; ALEMAN, A.; KESSELS, R. P.; LARØI, F.; KAHN, R. S. Emotional processing in a non-clinical psychosis-prone sample. **Schizophrenia research**, Elsevier, v. 68, n. 2-3, p. 271–281, 2004. Citado na página 34.