



UNIVERSIDADE FEDERAL DO CEARÁ
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

LUCAS DOS SANTOS FONSECA

**APRENDIZADO DE MÁQUINA PARA A PREDIÇÃO DA SAÚDE MENTAL E
QUALIDADE DE VIDA DE ESTUDANTES UNIVERSITÁRIOS**

SOBRAL
2024

LUCAS DOS SANTOS FONSECA

APRENDIZADO DE MÁQUINAS PARA A PREDIÇÃO DA SAÚDE MENTAL E
QUALIDADE DE VIDA DE ESTUDANTES UNIVERSITÁRIOS

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia Elétrica da
Universidade Federal do Ceará, como requisito
parcial à obtenção do grau de Bacharel em
Engenharia Elétrica.

Orientador: Prof. Dr. Carlos Alexandre Rolim
Fernandes.

SOBRAL

2024

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- F744a Fonseca, Lucas dos Santos.
Aprendizado de máquina para a predição da saúde mental e qualidade de vida de estudantes universitários / Lucas dos Santos Fonseca. – 2024.
67 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Sobral, Curso de Engenharia Elétrica, Sobral, 2024.
Orientação: Prof. Dr. Carlos Alexandre Rolim Fernandes.
1. Aprendizado de máquina. 2. Predição. 3. Saúde mental. 4. Qualidade de vida. I. Título.
CDD 621.3
-

LUCAS DOS SANTOS FONSECA

APRENDIZADO DE MÁQUINAS PARA A PREDIÇÃO DA SAÚDE MENTAL E
QUALIDADE DE VIDA DE ESTUDANTES UNIVERSITÁRIOS

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia Elétrica da
Universidade Federal do Ceará, como requisito
parcial à obtenção do grau de Bacharel em
Engenharia Elétrica.

Orientador: Prof. Dr. Carlos Alexandre Rolim
Fernandes.

Aprovada em 17/07/2024.

BANCA EXAMINADORA

Prof. Dr. Carlos Alexandre Rolim
Fernandes (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco Rafael Marques Lima
Universidade Federal do Ceará (UFC)

Prof. Dr. David Nascimento Coelho
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

À minha família, em especial aos meus pais, Carlos e Débora, pelos seus esforços em me prover uma boa educação e a possibilidade de cursar o ensino superior, sempre acreditando em mim e servindo de inspiração para que pudesse superar as adversidades.

À minha namorada, Gabriela, que me acompanhou de perto durante minha trajetória no curso, me incentivando e ajudando a superar os momentos difíceis, além de todo o carinho, atenção e palavras de apoio.

Ao casal de amigos, Keyvilânia e Douglas, com quem dividi moradia, horas de aulas e estudos, longas conversas, frustrações, aspirações ao futuro, e acompanhei de perto a ascensão de ambos à excelência profissional e à vida matrimonial. São exemplos de pessoas inteligentes, gentis e bondosas, das quais continuo sempre torcendo pelo sucesso.

Aos meus amigos da minha turma de 2017.2 que me acompanharam desde o início e aos que conheci durante o restante do curso.

Ao Prof. Dr. Carlos Alexandre Rolim Fernandes, por me orientar em meu trabalho de conclusão e durante todos os passos do desenvolvimento da pesquisa, e por ter despertado meu interesse pela área de Machine Learning e Inteligência Artificial.

Ao Prof. Dr. Francisco Rafael Marques Lima, por ter sido um divisor de águas durante minha formação, despertando meu interesse pela área de Telecomunicações e se tornando um exemplo de professor do qual pretendo me tornar um dia.

À Lycélia da Silva Oliveira e à Prof^a. Dra. Eliany Nazaré Oliveira por compartilharem os dados coletados no estudo que serviu de base para este trabalho.

À Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP), pelo apoio financeiro com a manutenção da minha bolsa do Programa de Bolsas de Produtividade em Pesquisa, Estímulo a Interiorização e Inovação Tecnológica (IC BPI), entre os anos de 2023 e 2024.

À Universidade Federal do Ceará – Campus Sobral, por proporcionar o ambiente da minha formação acadêmica e pela manutenção da minha bolsa de iniciação científica do Programa de Bolsas de Iniciação Científica (PIBIC), entre os anos de 2022 e 2023.

Aos professores participantes da banca examinadora Prof. Dr. Francisco Rafael Marques Lima e Prof. Dr. David Nascimento Coelho pelo tempo, pelas valiosas colaborações e sugestões.

Aos meus professores na Universidade Federal do Ceará (UFC), por me auxiliarem na aquisição de novos conhecimentos.

RESUMO

Nos últimos anos, observou-se um aumento significativo no número de pesquisas voltadas a Saúde Mental (SM) em todo o mundo. Estudantes, desde o ensino fundamental até a universidade, ganharam notoriedade devido ao aumento de índices relacionados a ansiedade e depressão. Na tarefa de identificar as causas desses números elevados, indicadores sociodemográficos e dados relacionados a SM e Qualidade de Vida (QV) são de suma importância. Diante disso, esse trabalho visa avaliar a eficácia do uso de técnicas de aprendizado de máquina na predição dos níveis de SM e QV de estudantes da Universidade do Vale do Acaraú (UVA), e identificar as principais causas de ansiedade e depressão experienciadas por eles. A base de dados utilizada é composta pelas respostas de 880 estudantes a três questionários: um referente a dados sociodemográficos, acadêmicos e clínicos, o Inventário de Saúde Mental (ISM) e o WHOQOL-Bref. O tratamento dos dados foi baseado nos conceitos e processos de *Data Mining* (DM) e *Knowledge Discovery in Databases* (KDD), e os algoritmos treinados foram: *Multilayer Perceptron* (MLP), *Support Vector Machine* (SVM), *Random Forest* (RF) e *Adaptive-Boost* (ADABOOST). Após o ajuste dos hiperparâmetros, feito por gridsearch, e seleção de atributos feita com os algoritmos *Sequential Forward Floating Selection* (SFFS) e *Sequential Backward Floating Selection* (SBFS), os resultados alcançaram uma acurácia de 78,44% para a predição da SM, e 77,40% para a predição da QV, ambos usando RF como modelo. Além disso, a importância dos atributos foi avaliada pelo cálculo do ganho de informação e por *stepwise regression*, sendo mais importante, para a SM, as pontuações dos domínios do WHOQOL-Bref, e, para a QV, as pontuações dos domínios do ISM.

Palavras-chave: saúde mental, qualidade de vida, aprendizado de máquina, predição.

ABSTRACT

In recent years, there has been a significant increase in the number of studies focused on Mental Health (MH) worldwide. Students, from elementary school to university, have gained notoriety due to the rise in anxiety and depression rates. In the task of identifying the causes of these elevated numbers, sociodemographic indicators and data related to mental health and quality of life are of utmost importance. Therefore, this study aims to evaluate the effectiveness of using machine learning techniques to predict the levels of MH and Quality of Life (QoL) of students at the University of Vale do Acaraú (UVA) and to identify the main causes of anxiety and depression experienced by them. The dataset used consists of responses from 880 students to three questionnaires: one related to sociodemographic, academic, and clinical data, the Mental Health Inventory (MHI), and the WHOQOL-Bref. Data processing was based on the concepts and processes of Data Mining (DM) and Knowledge Discovery in Databases (KDD), and the trained algorithms were: Multilayer Perceptron (MLP), Support Vector Machine (SVM), Random Forest (RF), and Adaptive Boosting (AdaBoost). After hyperparameter tuning, done via grid search, and feature selection performed with the Sequential Forward Floating Selection (SFFS) and Sequential Backward Floating Selection (SBFS) algorithms, the results achieved an accuracy of 78.44% for the prediction of MH and 77.40% for the prediction of QoL, both using RF as the model. Additionally, the importance of the attributes was evaluated by calculating information gain and stepwise regression, with the most important attributes for MH being the scores of the WHOQOL-Bref domains, and for QoL, the scores of the MHI domains.

Index Terms: mental health, quality of life, machine learning, prediction model.

LISTA DE FIGURAS

Figura 1 - Etapas do KDD	22
Figura 2 - Exemplo genérico de árvore de decisão	25
Figura 3 - Estrutura de uma MLP	27
Figura 4 – Exemplo de binarização de uma variável.....	33
Figura 5 - Matriz de confusão do modelo de RF para a predição da QV	42
Figura 6 - Matriz de confusão do modelo de RF para a predição da SM	43

LISTA DE TABELAS

Tabela 1 - Domínios do ISM	19
Tabela 2 - Domínios do WHOQOL-Bref	21
Tabela 3 - Cenários considerados para avaliação	32
Tabela 4 - Atributos extraídos do FSAC	34
Tabela 5 - Acurácias dos modelos de predição sem <i>undersampling</i> ($N = 872$ Amostras)	39
Tabela 6 - Hiperparâmetros dos casos sem <i>undersampling</i>	40
Tabela 7 - Acurácias dos modelos de predição com <i>undersampling</i>	40
Tabela 8 - Hiperparâmetros dos casos com <i>undersampling</i>	41
Tabela 9 - Métricas de avaliação do modelo de RF para a predição da QV	42
Tabela 10 - Métricas de avaliação do modelo de RF para a predição da SM	44
Tabela 11 - Resultados da seleção de atributos utilizando SFFS	44
Tabela 12 - Resultados da seleção de atributos utilizando SBFS	46
Tabela 13 – 10 maiores ganhos de informação dos atributos para a predição da SM	48
Tabela 14 - 10 maiores ganhos de informação dos atributos para a predição da QV	49
Tabela 15 - Acurácias obtidas nas predições por domínio	50
Tabela 16 - Seleção de atributos por <i>stepwise regression</i> para predição da QV	51
Tabela 17 - Seleção de atributos por <i>stepwise regression</i> para predição da SM	52

SUMÁRIO

1	Introdução	11
1.1	Motivação e contexto	11
1.2	Objetivos Gerais e Específicos	13
1.3	Estrutura do Documento	13
2	Trabalhos Relacionados	15
3	Fundamentação Teórica	18
3.1	Saúde Mental	18
3.1.1	Inventário de Saúde Mental (ISM)	18
3.2	Qualidade de Vida	20
3.2.1	Formulário WHOQOL-Bref	21
3.3	<i>Knowledge Discovery in Databases</i> (KDD)	22
3.4	<i>Machine Learning</i> (ML)	23
3.5	Classificadores.....	24
3.5.1	<i>Random Forest</i>	24
3.5.2	<i>Support Vector Machine</i>	26
3.5.3	<i>Multilayer Perceptron</i>	26
3.5.4	<i>Adaptive Boost</i> (AdaBoost)	27
3.5.5	Métricas de Avaliação	28
3.6	Métodos de Seleção de Atributos	28
3.7	Regressão Linear	29
3.7.1	Métricas de Performance	30
3.7.2	<i>Stepwise Regression</i>	30
4	Metodologia	31
4.1	Base de Dados	31
4.2	Aplicação do método KDD	31
4.2.1	Seleção e Pré-processamento	32
4.2.2	Transformação	32

4.2.3	Mineração	36
4.2.4	Avaliação	37
5	Resultados e Discussão	39
5.1	Modelos de Predição	39
5.2	Seleção e Importância dos Atributos	44
5.3	Regressão Linear	50
6	Conclusão e Trabalhos Futuros	53

1 INTRODUÇÃO

A Seção 1.1 contém a motivação e o contexto do estudo apresentado; na Seção 1.2, os objetivos gerais e específicos são abordados; a Seção 1.3 descreve a estrutura do documento.

1.1 Motivação e contexto

Estudos voltados à Saúde Mental (SM) cresceram exponencialmente na última década ao redor do mundo. Devido a pandemia de COVID-19, houve um aumento de 25%, no primeiro ano, dos casos de depressão e ansiedade, sendo jovens e mulheres os mais afetados (Organização Pan-Americana da Saúde, 2022). A situação dos jovens e adolescentes merece destaque. No Brasil, uma pesquisa realizada pelo DataFolha, publicada em julho de 2022, realizada com 1308 responsáveis e 1869 alunos de instituições públicas em todo o território nacional, revelou que, na visão dos pais, 34% tinham dificuldades para controlar as emoções, 24% se sentem sobrecarregados e 18% estão tristes ou deprimidos (Instituto Unibanco, 2022). Segundo a Organização Mundial da Saúde (OMS), em 2019, 14% dos adolescentes do mundo viviam com algum transtorno mental (Organização Pan-Americana da Saúde, 2022).

Atualmente, a SM é vista como um dos principais fatores que impactam a vida das pessoas em vários âmbitos (VAN LENTE et al., 2012). A OMS define SM como “estado de bem-estar mental, que possibilita as pessoas a lidarem com o estresse da vida, perceber suas habilidades, aprender bem, trabalhar bem e contribuir com sua comunidade”. Durante a vida de uma pessoa, sua SM é determinada por fatores individuais, sociais e estruturais da sociedade. Fatores psicológicos e biológicos, como habilidades emocionais e o uso de drogas ou remédios, bem como a situação social, econômica e política do ambiente em que se vive, são fatores determinantes para a SM com poder de proteger ou expor as pessoas à problemas mentais (WHO, 2022).

Um instrumento importante para o estudo e manutenção da SM é o Inventário de Saúde Mental (ISM), criado a partir de um estudo realizado pelo *United States Department of Health, Education and Welfare*, com início em 1971 e duração de 15 anos, com o intuito de “identificar aspectos negativos e positivos da SM, identificar indivíduos com mais ou menos SM entre a população em geral e fornecer indicações para o rastreio de doença mental” (Ribeiro, 2011). O ISM foi desenvolvido para ser aplicado na população geral, e seu manual fornece instruções para a aplicação de um questionário, a interpretação dos resultados e manipulação dos dados.

Além da SM, a Qualidade de Vida (QV) é outro fator que apresenta, atualmente, extrema relevância na área da saúde, tanto em âmbito prático quanto de pesquisa, possuindo um poder de análise multidimensional. Segundo o manual WHOQOL-Bref, versão abreviada do WHOQOL-100, ferramenta criada pelo grupo WHOQOL (*World Health Organization Quality of Life*) para a avaliação da QV das pessoas com aplicação multicultural, QV é definida como “as percepções de um indivíduo sobre sua posição, em vida, no contexto da cultura e do sistema de valores em que vive, e em relação as suas metas, expectativas, padrões e preocupações”. Apesar do caráter subjetivo dessa definição, englobando questões culturais, sociais e ambientais, o manual contém instruções para a aplicação de um questionário acerca dessas questões, bem como a interpretação dos resultados de forma objetiva e numérica.

De acordo com (OLIVEIRA, 2020), em uma pesquisa realizada com os estudantes da Universidade Federal do Vale do Acaraú (UVA), dados sociodemográficos, tais como sexo, idade, situação conjugal, religião e raça, em conjunto com dados referentes aos cursos de graduação e estrutura da instituição de ensino e dados clínicos, quando relacionados aos questionários ISM e WHOQOL-Bref, revelam, no âmbito da QV, fatores como insatisfação com o sono, pouca energia para o dia-a-dia, dificuldade de concentração, pensamentos negativos com frequência, insegurança no local onde vive, falta de dinheiro para necessidades, poucas oportunidades de lazer e insatisfação com o acesso aos serviços de saúde. Em relação à SM, foram observados altos níveis de ansiedade, irritação, preocupação, inquietação, nervosismo e depressão. Além disso, observou-se maior disposição do sexo feminino ao adoecimento mental, e uma média de 16,7% dos estudantes de cada área (Humanas, Exatas, Biológicas e Saúde) apresentaram baixos níveis de SM.

Diante do crescimento da aplicação de Mineração de Dados (*Data Mining* – DM) e técnicas de Aprendizado de Máquina (*Machine Learning* – ML) em estudos voltados ao âmbito da saúde, este trabalho propõe a investigação de dois problemas: o uso de modelos de ML para a predição dos níveis de SM e de QV de estudantes universitários, com base nos dados obtidos em (OLIVEIRA, 2020). Foram aplicados os conceitos e etapas de Descoberta de Conhecimento em Base de Dados (*Knowledge Discovery in Databases* – KDD) para o tratamento dos dados do Formulário Sociodemográfico, Acadêmico e Clínico (FSAC), como remoção tanto de informações irrelevantes para os algoritmos, como de amostras com dados faltosos, e binarização de variáveis. Os algoritmos treinados foram os classificadores Floresta Aleatória (*Random Forest* – RF), Máquina de Vetores de Suporte (*Support Vector Machine* - SVM), *Multilayer Perceptron* (MLP) e *Adaptive-Boost* (ADABOOST), sendo seus respectivos hiperparâmetros otimizados por *gridsearch*. O desempenho dos algoritmos foi avaliado por

validação cruzada e o melhor resultado obtido foi de 77,40% de acurácia para a predição da QV, e 78,44% para a predição da SM, ambos com o modelo de RF.

Além disso, algoritmos de seleção de atributos, *Sequential Forward Floating Selection* (SFFS) e *Sequential Backward Floating Selection* (SBFS), e análise de regressão feita por *Stepwise Regression*, foram utilizados para reduzir a dimensionalidade da base de dados e otimizar a performance da predição, além de servir como comparativo para os resultados da análise da importância dos atributos por meio do cálculo do ganho de informação baseado na entropia dos dados. Os resultados revelaram que, tanto para a classificação da SM, quanto para a QV, as pontuações dos domínios dos dois instrumentos de avaliação, WHOQOL-Bref e ISM, figuraram entre os atributos com os maiores ganhos de informação, e estiveram também presentes nos atributos selecionados pelo SFFS, SBFS e pela análise de regressão linear.

1.2 Objetivos Gerais e Específicos

Este trabalho tem como objetivo geral a análise do desempenho de técnicas de aprendizado de máquina para a predição dos níveis de SM e QV de estudantes universitários, baseada em dados sociodemográficos, acadêmicos e clínicos e métricas de SM e QV disponíveis na literatura. Outro objetivo é identificar quais atributos apresentam maior relevância para esse estudo.

O estudo apresentado também contou com os seguintes objetivos específicos:

- Analisar e tratar os dados do FSAC, com base nos conceitos e processos de DM e KDD, para melhor desempenho dos modelos preditivos testados.
- Interpretar e tratar os dados dos questionários WHOQOL-Bref e MHI nos conformes de seus respectivos manuais.
- Observar os principais fatores para as predições identificados pelos algoritmos e traçar paralelos com estudos relacionados ao tema disponíveis na literatura.
- Avaliar o desempenho dos algoritmos a partir de técnicas de validação cruzada.

1.3 Estrutura do Documento

O documento segue a seguinte estrutura: Na seção 2, estudos relacionados são apresentados, expondo o que já existe sobre o tema na literatura. Na seção 3, é apresentada a fundamentação teórica do estudo. Na seção 4, a metodologia utilizada é apresentada. A seção

5 contém os resultados e discussão do estudo. Por fim, a seção 6 apresenta as conclusões e considerações finais sobre o trabalho.

2 TRABALHOS RELACIONADOS

Esta seção apresenta uma revisão na literatura sobre trabalhos relacionados SM e QV e a aplicação de ML nesses contextos.

Danowitz e Beddoes (2020) realizaram uma pesquisa em 5 universidades dos Estados Unidos em busca de quais problemas de SM mais afetavam os estudantes de engenharia. Foram aplicados diferentes instrumentos de avaliação e questionários para análise de taxas de sintomas graves e moderados de desordem mental, medição das taxas de depressão, ansiedade e distúrbios alimentares e análise de distúrbios por estresse pós-traumático, além de uma análise de dados sociodemográficos. Os resultados mostraram que 28,4% dos estudantes potencialmente sofriam de uma condição de SM diagnosticável, e que 55,2% dos estudantes apresentaram sintomas moderados de desordem mental. Além disso, foi observado que mulheres, principalmente de grupos étnicos com histórico de exclusão, apresentaram taxas elevadas de pânico e transtornos por estresse pós-traumático em relação aos homens.

Liang et al. (2015) examinaram de forma semântica e ontológica o nível de energia emocional presente no conteúdo de aproximadamente 60 mil universitários chineses em um microblog, com base em palavras-chaves e termos específicos, visando classificar as emoções dos estudantes em: positiva, negativa e neutra. Os resultados mostraram que 46,8% dos dados do microblog refletiam condições psicológicas positivas, 19,77% eram neutras e 33,85% eram negativas. Para a porcentagem negativa, as possíveis influências consideradas foram: barreiras psicológicas devido à má adaptação ao ambiente universitário, pressão nos estudos, problemas nos relacionamentos interpessoais e relações íntimas, pressão econômica e ansiedade devido a planos futuros.

Em (MEDVEDEV; LANDHUIS, 2018), buscou-se examinar as relações existentes entre os conceitos de felicidade, bem-estar subjetivo e QV, visando um melhor entendimento e discernimento entre eles. O estudo foi conduzido em 180 universitários, sendo 80% mulheres e com média de idade de 25 anos. Foram analisadas métricas de bem-estar obtidas pela aplicação dos instrumentos de avaliação: *Oxford Happiness Questionnaire* (OHQ), *WHOQOL-Bref*, *Satisfaction of Life Scale* (SL) e *Positive and Negative Affect Scale* (PANAS). Os dados foram analisados por correlação, regressão linear e análise explanatória de fatores. Os resultados mostraram alta correlação positiva entre felicidade, medida pelo OHQ, os domínios “Psicológico” e “Saúde Física” do WHOQOL-Bref, satisfação com a vida, medida pelo SL, e afetos positivos do PANAS. Os domínios “Relações Sociais” e “Fatores

Ambientais” do WHOQOL-Bref foram preditores pobres para felicidade e bem-estar. Regressão linear múltipla foi aplicada para a análise da importância dos domínios do WHOQOL na predição de felicidade e bem-estar. O domínio psicológico se mostrou o fator de maior importância em ambas.

Em (AY-WOAN et al., 2006), foram examinados fatores preditivos da QV de pacientes internados com desordens depressivas. O estudo foi conduzido com 83 pacientes de ala psiquiátrica, sendo 73% mulheres e com média de idade de 44 anos. Os modelos preditivos propostos foram modelados a partir de 3 vertentes: variáveis clínicas, dados demográficos e competências percebidas, sendo essa última interpretada como a capacidade do indivíduo em engajar em atividades e se satisfazer com a própria performance. As variáveis de saída foram as pontuações do caso geral e de cada domínio do WHOQOL-Bref. Foi aplicado *stepwise regression* para identificar fatores significantes em relação às variáveis de saída. Diversos questionários e instrumentos de avaliação fizeram parte dos dados de entrada. No fim, foi gerado um modelo para cada variável de saída, sendo os fatores preditivos mais significativos de cada um uma combinação entre os instrumentos de avaliação e variáveis sociodemográficas. As significâncias das variáveis da vertente de competências percebidas refletiram a importância dela como indicativo da necessidade de intervenção com terapia ocupacional.

(SRIVIDYA; MOHANAVALLI; BHALAJI, 2018) usaram modelos preditivos baseados em ML para identificar indivíduos mentalmente abalados em diferentes grupos, com o intuito de os direcionar atenção especial, visando a manutenção da SM dos grupos. Os dados utilizados foram extraídos a partir de um questionário modelado por um psicólogo, aplicado a dois grupos, um composto por 300 estudantes, e outro composto por 356 profissionais com menos de 5 anos de carreira. De acordo com a pontuação obtida no questionário, uma pessoa pode ser classificada como mentalmente abalada, pouco satisfeito com a vida ou otimista. Os classificadores utilizados foram: Regressão Logística (*Logistic Regression – LR*), *Naive Bayes* (NB), SVM, Árvore de Decisão (*Decision Tree – DT*) e *K-Nearest Neighbours* (KNN). Além disso, métodos de *ensemble* também foram implementados, apresentando os melhores resultados, atingindo 90% de acurácia.

Em uma abordagem mais preventiva, (PRISCILLA DOOSHIMA, 2018) elaborou um modelo de predição de doenças mentais com base em fatores de risco. Três classes de fatores de risco foram associadas com doenças mentais: fatores biológicos, fatores psicológicos e fatores ambientais. A base de dados foi coletada a partir de 30 pacientes com uma distribuição balanceada entre as classes: sem risco, baixo risco, risco moderado e alto

risco de doenças mentais. Foram utilizados os classificadores NB e DT, atingindo 76,7% e 83,3% de acurácia, respectivamente. Além disso, o modelo com DT revelou as principais variáveis para identificar os riscos de doenças mentais, como por exemplo “ter perdido alguém próximo”.

Em (ERDOĞAN; NAMLI, 2019), foi testado o desempenho de técnicas de ML e Aprendizado de Máquina Conjunto (*Ensemble Machine Learning* – EML) para a predição do melhor ambiente de vida para as pessoas, baseada em dados colhidos a partir de um questionário direcionado a identificar os índices de QV preferíveis por cada um. Dessa forma, os índices observados em cada indivíduo eram comparados aos índices de QV de diferentes cidades, a fim de se encontrar qual proporcionava o melhor ambiente de vida, se encaixando nas necessidades e expectativas de cada. As metodologias utilizadas, baseadas em ML, foram as Redes Neurais Artificiais (Artificial Neural Network – ANN) e SVM; e, baseadas em EML, foram *stacking* e *voting*. O melhor resultado foi obtido com um modelo de *ensemble* utilizando *Logistic Model Tree* e *Sequential Minimal Optimization* baseado em *stacking*, utilizando Kfold com K=10 e 20% dos dados para validação, atingindo 84% de acurácia. Foi observado que o nível de satisfação com o ambiente de vida aumenta com o acesso a serviços de saúde, serviços sociais do estado, senso de segurança, entre outros fatores relacionados.

Modelos de predição de SM utilizando DT, RF e NB foram implementados em (LAIJAWALA et al., 2020) utilizando uma base de dados disponível online pela *Open Sourcing Mental Illness* (OSMI), sendo composta principalmente por dados de indivíduos da classe trabalhadora, totalizando 315 amostras. O modelo de melhor desempenho, com base em acurácia e tempo de execução, foi o de DT, atingindo 82% de acurácia. Ele foi implementado em uma página *online*, onde os usuários do *site* obtêm conhecimento acerca de problemas de SM e recebem, como resposta do algoritmo após fornecerem seus dados, a probabilidade de terem algum problema de SM, além de recomendações de tratamento e paliativos.

Diante do exposto, o presente trabalho investiga a eficiência de diversas técnicas de ML para a predição dos níveis de QV e SM de estudantes universitários baseada em dados sociodemográficos, acadêmicos, clínicos e pontuações obtidas pelo WHOQOL-Bref e ISM. Também foi estudado a correlação existente entre o WHOQOL-Bref e o ISM, e evidenciada uma maior eficiência do primeiro para a análise da SM. Além disso, a importância dos atributos foi analisada pelas métricas de ganho de informação *ep-value*, consolidando os domínios do WHOQOL-Bref e do ISM como os mais importantes para as predições, acompanhados por dados relacionados a raça, religião, situação civil e atividades de lazer.

3 FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta os aspectos teóricos dos conceitos e instrumentos que fundamentaram o estudo realizado, sendo eles: SM e o instrumento de medição utilizado no trabalho, o ISM; QV e o formulário WHOQOL-Bref; KDD, ML e os classificadores utilizados no trabalho; métodos de seleção de atributos, ganho de informação e entropia da base de dados e, por fim, regressão linear.

3.1 Saúde Mental

Saúde e SM são conceitos complexos e historicamente influenciados por contextos sócio-políticos e pela evolução das práticas de saúde. Nos dois últimos séculos, têm-se visto a ascensão da definição desses termos como específicos do campo da medicina. Entretanto, com a consolidação de um cuidado em saúde multidisciplinar, diferentes áreas de conhecimento têm incorporado tais conceitos (GAINO et al., 2018). Segundo a OMS, SM é definida como “estado de bem-estar mental, que possibilita as pessoas a lidarem com o estresse da vida, perceber suas habilidades, aprender bem, trabalhar bem e contribuir com sua comunidade” (WHO,2022).

De maneira geral, SM é compreendida como ausência de doença, saúde mental positiva e estado de equilíbrio. Diante da necessidade de propor uma definição que integrasse esses três paradigmas, (CORONEL-SANTOS; RODRÍGUEZ-MACÍAS, 2022) propôs um modelo explanatório que define SM como o processo interno de autocuidado, centrado em autoconhecimento e auto regulação do ser humano, onde cada pessoa busca equilibrar seus sentimentos, pensamentos e comportamentos, intrapessoais e interpessoais, abordando um estado ótimo de bem estar e ausência de desordens mentais, de acordo com valores universais, e fatores biológicos, sociais, psicológicos e ambientais.

3.1.1 Inventário de Saúde Mental (ISM)

O ISM é um instrumento de medição dos níveis de SM de aplicação à população geral, desenvolvido pelo Departamento de Saúde, Educação e Bem-Estar dos Estados Unidos (*United States Department of Health, Education and Welfare*). Ele foi desenvolvido no âmbito do Rand Health Insurance Experiment (HIE), uma investigação acerca da satisfação dos doentes com os serviços de saúde da época, tendo início em 1971 e fim após 15 anos, com uma série de estudos realizados em 6 cidades dos Estados Unidos da América (EUA), liderados por Veit e Ware, e contabilizando 5089 participantes entre 13 e 69 anos de idade. O

objetivo do ISM era funcionar como uma medida de distresse psicológico e bem estar da população em geral, e não somente em pessoas com doenças mentais. Ele é composto por 38 itens que se distribuem por dois grandes fatores de segunda ordem de correlação, “Distresse Psicológico” e “Bem-Estar Psicológico”, e em 5 fatores de primeira ordem de correlação, “Ansiedade”, “Depressão”, “Laços Emocionais”, “Afeto Geral Positivo” e “Perda de Controle Emocional/Comportamental”. A Tabela 1 apresenta um resumo dos itens que compõem cada domínio. O preenchimento do formulário está associado com uma pontuação obtida para medir os níveis de SM. O formulário completo pode ser visto no Anexo A.

Tabela 1 - Domínios do ISM

Domínios	Itens
1. Ansiedade	3- Nervoso ou apreensivo por coisas que aconteceram 11- Pessoa muito nervosa (MHI-5) 13- Tenso e irritado 15- As mãos a tremer quando fazia algo 22- Relaxar sem dificuldade a 25- Incomodado devido ao nervoso 29- Cansado inquieto e impaciente 32- Confuso ou perturbado 33- Ansioso ou preocupado 35- Dificuldade em se manter calmo
2. Depressão	9- Deprimido 27- Triste e em baixo (MHI-5) 30- Rabugento e de mau humor 36- Espiritualmente em baixo 38- Debaixo de grande pressão ou stress
3. Perda de Controle Emocional	8- Preocupado por perder a cabeça 14- Controlo de comportamento, pensamentos, sentimentos 16- Sem futuro 18- Sentiu emocionalmente estável 19- Triste e em baixo (MHI-5) 20- Sentiu como se fosse chorar 21- Seria melhor que não existisse 24- Tudo acontece ao contrário do desejado 28- Pensar em acabar com a vida
4. Afeto Positivo	1- Feliz e satisfeito

	4- Futuro promissor 5- Dia a dia interessante 6- Relaxado e sem tensão 7- Prazer no que faz 12- Esperar ter um dia interessante 17- Calmo e em paz (MHI-5) 26- Vida é uma aventura maravilhosa 31- Alegre, animado e bem disposto 34- Pessoa feliz (MHI-5) 37- Acordou fresco e repousado
5. Laços Emocionais	2- Sentiu-se só 10- Sentiu-se amado e querido 23- Relações amorosas satisfatórias

Fonte: Adaptado de Inventário de Saúde Mental (Ribeiro, 2011).

3.2 Qualidade de Vida

O conceito de QV é utilizado em duas vertentes: na linguagem cotidiana e no contexto da pesquisa científica. Na área da saúde, o conceito de QV é relativamente recente e decorre, em parte, de novos paradigmas que influenciam as políticas e práticas do setor nas últimas décadas (SEIDL; ZANNON, 2004).

QV tem emergido como o ideal da medicina moderna do ponto de vista biopsicossocial, sendo um conceito frequentemente usado como atributo importante na assistência ao paciente e estudos clínicos (AWAD; VORUGANTI, 2000).

Segundo a OMS, QV é definida como “as percepções de um indivíduo sobre sua posição, em vida, no contexto da cultura e do sistema de valores em que vive, e em relação as suas metas, expectativas, padrões e preocupações” (“The World Health Organization quality of life assessment (WHOQOL)”, 1995).

Diversos instrumentos genéricos de avaliação da QV, para fins de pesquisa ou aplicação clínica direta, estão disponíveis na literatura, como o Medical Outcomes Study SF-36 Health Survey (Ware; Kosinski; Keller, 1993), o Sickness Impact Profile (“Quality of life assessment: an annotated bibliography”, 1994), além do próprio WHOQOL-100, desenvolvido pela OMS.

3.2.1 Formulário WHOQOL-Bref

O formulário WHOQOL-Bref é uma versão abreviada do WHOQOL-100, uma medida de avaliação da QV, criada a partir de necessidade de se incluir medidas de saúde de caráter diferente dos indicadores tradicionais de mortalidade e morbidade, e promover uma perspectiva mais humanista na medicina, para além da urgência de apenas erradicar doenças e sintomas.

Dado que a QV é uma medida subjetiva e de caráter multidimensional, o WHOQOL-100 é composto por 100 itens que avaliam 24 facetas da QV, que, por sua vez, são agrupadas em 6 domínios. Contudo, após uma análise de dados, e devido também à grande extensão do questionário, foi observado que uma abordagem com 4 domínios seria mais apropriada, dando origem ao WHOQOL-Bref, composto por 26 itens que se desdobram em 24 facetas e nos domínios “Saúde física”, “Psicológico”, “Relacionamentos Sociais”, “Ambiente”. A Tabela 2 apresenta quais facetas compõem cada domínio. Similarmente ao ISM, o preenchimento deste formulário retorna uma pontuação obtida que é utilizada para medir os níveis de QV. O formulário completo está disponível no Anexo B.

Tabela 2 - Domínios do WHOQOL-Bref

Domínios	Facetas incorporadas
1. Saúde Física	Atividades diárias Dependência de substâncias medicinais e aparatos médicos Energia e fadiga Mobilidade Dor e desconforto Sono e descanso Capacidade de trabalhar
2. Psicológico	Imagem corporal e aparência Sentimentos negativos Sentimentos positivos Autoestima Espiritualidade/ Religião/ Crenças pessoais Pensamento, aprendizagem, memória e concentração
3. Relacionamentos Sociais	Relacionamentos pessoais Suporte social Atividade sexual
4. Ambiente	Recursos financeiros

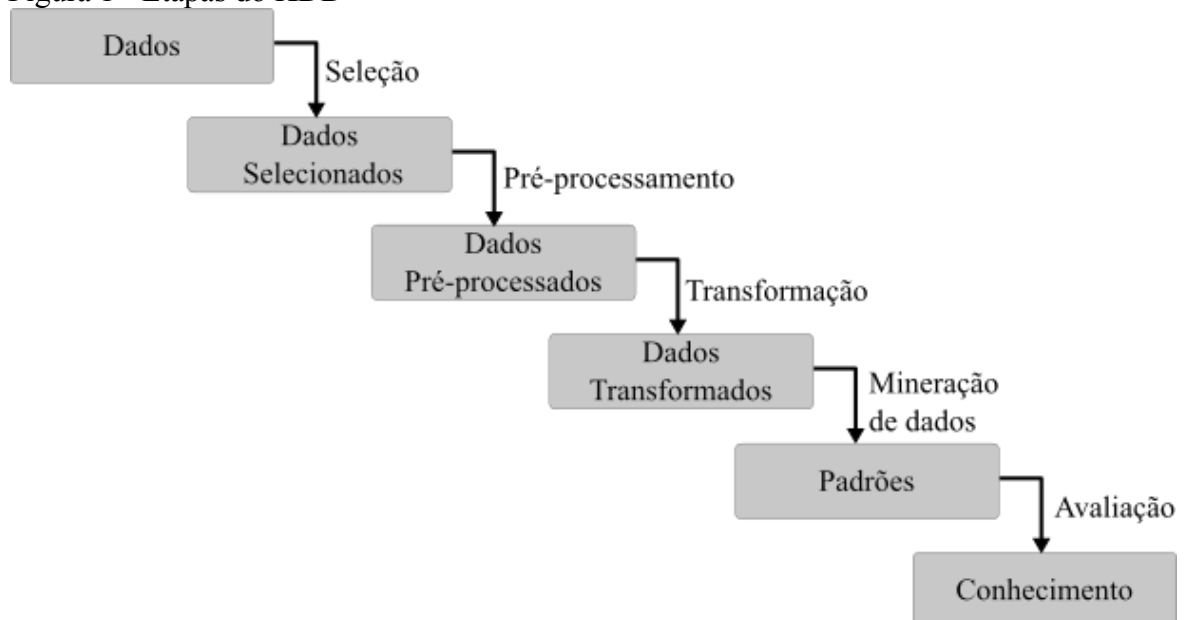
	Liberdade, segurança física e proteção Saúde e cuidados sociais: acessibilidade e qualidade Ambiente doméstico Oportunidades para adquirir novas informações e habilidades Participação e oportunidades de recreação / atividades de lazer Ambiente físico (poluição, barulho, tráfego e clima) Transporte
--	--

Fonte: Adaptado de WHOQOL-BREF Field Trial Version (1996).

3.3 Knowledge Discovery in Databases (KDD)

De acordo com (Fayyad et al, 1996), o campo de KDD se preocupa com o desenvolvimento de técnicas e métodos voltados para a extração de significado de bases de dados. O problema básico abordado pelo processo de KDD é o de transformar dados volumosos e dispersos em formas mais compactas, compreensíveis e úteis/aplicáveis. No centro desse processo, encontram-se aplicações específicas de DM para o descobrimento de padrões e extração de informações. A Figura 1 esboça as etapas que constituem o processo de KDD.

Figura 1 - Etapas do KDD



Fonte: Autoria própria.

Apesar do processo de KDD depender de decisões tomadas pelo usuário, o fluxo básico de fases segue as etapas expostas na Figura 1, sendo elas:

- Seleção: agrupamento e seleção dos dados a serem analisados.

- Pré-processamento: limpeza de dados, remoção de ruído, definição de estratégias para lidar com dados omissos.
- Transformação: binarização e seleção de atributos úteis para o objetivo principal de análise, passível de aplicações de técnicas de redução de dimensionalidade.
- Mineração de dados: aplicação de técnicas para extração de informações ou detecção de padrões, tais como algoritmos de ML baseados em tarefas de classificação, regressão, entre outros.
- Avaliação/Interpretação: análise exploratória dos padrões minerados visando a verificação do conhecimento descoberto. Para consolidação dos resultados, pode-se considerar um retorno às etapas anteriores.

3.4 *Machine Learning* (ML)

De acordo com (MITCHELL, 1997), o campo de Aprendizagem de Máquina (ML) se preocupa com a questão de como construir programas de computador capazes de evoluir a partir de experiências. Dentro do contexto de DM, existem tarefas encarregadas de extrair informações de conjuntos de dados, sendo elas divididas em duas grandes categorias: preditivas e descritivas (TAN; STEINBACH; KUMAR, 2014). A aplicação de ML se faz presente na categoria de tarefas preditivas, uma vez que os algoritmos são treinados, com conjuntos de dados, para realizarem previsões em novos dados. Desse treinamento se abstrai a ideia de aprendizado e evolução.

Os métodos de ML são baseados, principalmente, em 3 abordagens de aprendizado: supervisionado, onde o algoritmo observa pares de entrada-saída das amostras, a fim de aprender uma função generalista que mapeia os dados de entrada aos de saída; não-supervisionado, onde padrões são observados nos dados de entrada, ainda que não sejam fornecidos dados de saída; por reforço, onde o algoritmo aprende a partir de punições e recompensas às suas ações (RUSSELL; NORVIG; DAVIS, 2010).

As tarefas realizadas pelos algoritmos de ML são divididas em:

- Classificação: realiza a previsão de classe ou categoria de uma observação.
- Regressão: estima um valor numérico de saída à uma observação.
- Agrupamento: agrupa diferentes observações em “clusters”.

O estudo realizado nesse trabalho se baseou em modelos preditivos de classificação e regressão.

3.5 Classificadores

Classificadores são algoritmos que realizam a tarefa de classificar/categorizar amostras, baseado na semelhança e proximidade das características ou atributos (dados de entrada) que as compõem, com as do conjunto de dados usado para treinamento. A seguir serão apresentados os modelos utilizados no presente estudo.

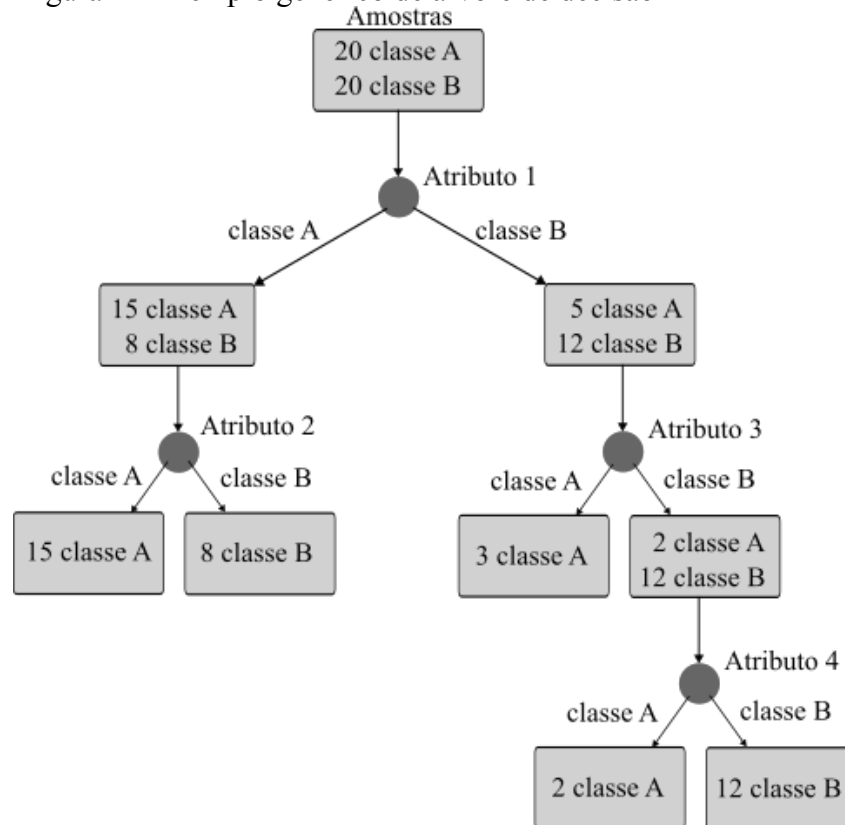
3.5.1 *Random Forest*

O algoritmo de RF é comumente usado tanto para tarefas de classificação, quanto de regressão. Ele é baseado na técnica de *ensemble learning* para árvores de decisão. O método de *ensemble*, em ML, consiste na combinação dos resultados de um conjunto de modelos de predição para balancear a predição final, visando evitar problemas de *overfitting*, que consiste no sobreajuste de um modelo aos dados de treinamento, tornando-o não genérico e, portanto, ineficiente à entrada de novos dados. Além disso, o algoritmo de RF, também realiza, intrinsecamente, análise da importância dos atributos, é pouco sensível ao ajuste de hiperparâmetros (COURONNÉ; PROBST; BOULESTEIX, 2018) e apresenta robustez contra dados heterogêneos (MARTON et al., 2023).

Os hiperparâmetros são métricas de ajuste dos algoritmos. Para se obter melhor desempenho diante do conjunto de dados de treinamento, normalmente se opta por otimizar os hiperparâmetros. Cada algoritmo tem seu conjunto de hiperparâmetros, por exemplo, os de RF são: o número de árvores utilizadas, o número de atributos testados em cada árvore, o tamanho mínimo dos nós de resposta, entre outros.

O algoritmo de árvore de decisão funciona selecionando, a cada nó, que são pontos de decisão da árvore, o atributo que melhor separa o conjunto de dados nas classes de interesse, e repete o processo a partir dos nós gerados, até que todas as amostras estejam separadas em conjuntos de mesma classe. A Figura 2 exemplifica esse processo.

Figura 2 - Exemplo genérico de árvore de decisão



Fonte: Autoria própria.

Para escolher os atributos de cada nó, o índice de Gini e o ganho de informação são métricas comumente utilizadas. Elas calculam a impureza dos conjuntos, ou seja, o quão misturadas as amostras de um conjunto estão, em relação às suas classes. Essas métricas também são usadas para calcular a importância dos atributos. Pelo índice de Gini, esse cálculo é baseado na probabilidade de ocorrência ou não de um evento, no caso, pertencer ou não a uma classe, com base em um atributo observado; já o ganho de informação se baseia no quanto um atributo, utilizado como medida única para a classificação, diminui a entropia dos dados.

A entropia (H), de uma base de dados (B), composta por C classes, e o ganho de informação (I), obtido por um atributo m , onde $m = \{1, \dots, M\}$, sendo M a quantidade de atributos que compõem as amostras de B , podem ser expressos matematicamente de acordo com as equações a seguir.

$$H(B) = \sum_{i=1}^C p_i \ln(p_i) \quad (1)$$

$$I(B, m) = H(B) - H(B, m) \quad (2)$$

onde, $H(B, m)$ é a média das entropias nos novos conjuntos de dados separados por m , e p_i é a probabilidade associada a escolha de cada classe.

Dessa forma, o algoritmo de RF gera várias árvores de decisão, cada uma treinada com um subconjunto aleatório das amostras e atributos formados pela técnica de *bagging* (*bootstrap aggregation*), que consiste em criar subconjuntos de treinamento a partir dos dados originais, contendo o mesmo tamanho, e se diferenciam pela repetição e exclusão aleatória de amostras. Esse método visa diminuir a variância dos dados e os problemas de *overfitting*. Ao final, a decisão do modelo de RF, é tido, mais comumente, como a decisão obtida pela maioria das árvores do modelo, método de *ensemble* conhecido como *voting*.

3.5.2 Support Vector Machine

O SVM é um algoritmo que também têm versões tanto de classificação, como de regressão. Ele tem raízes em teorias de aprendizado estatístico e apresenta bons resultados em vários tipos de aplicações e em dados com um grande número de dimensões (TAN; STEINBACH; KUMAR, 2014). Três propriedades principais o compõem: 1. Busca por uma região de decisão com a maior distância possível entre as amostras, o que ajuda na generalização do modelo; 2. A classificação das amostras é feita por um hiperplano de separação que consegue atuar em espaços vetoriais de múltiplas dimensões, o que concede uma vantagem sobre métodos de classificação que atuam apenas em representações lineares dos dados; 3. É um método não-paramétrico, o que significa que ele é flexível e se ajusta bem à distribuição do conjunto de dados de treinamento (RUSSELL; NORVIG; DAVIS, 2010).


3.5.3 Multilayer Perceptron

Redes neurais artificiais fornecem um método prático e genérico para aprendizagem de funções de valores reais, discretos e vetoriais com base em treinamento supervisionado, sendo robusta contra erros nos dados de treinamento (MITCHELL, 1997). O estudo de redes neurais artificiais foi incentivado pela tentativa de simular os sistemas neurais biológicos, sendo assim, de forma análoga à estrutura do cérebro humano, compostas por conjuntos interconectados de nós e *links* diretos (TAN; STEINBACH; KUMAR, 2014).

Uma rede MLP é composta por vários neurônios divididos em camadas: a primeira camada, alimentada pelos valores de entrada (atributos), uma camada de saída, com o resultado das interações entre os neurônios, e camadas intermediárias, chamadas de camadas ocultas. Os *links* servem para propagar a ativação entre os neurônios e estão também associados a um peso, que é ajustado durante o treinamento, conforme mais amostras são inseridas.

Uma rede de apenas uma camada é capaz de lidar apenas com problemas linearmente separáveis. A adição de camadas intermediárias possibilita a resolução de problemas mais complexos e não linearmente separáveis. Na verdade, uma única camada oculta, suficientemente grande, é possível representar qualquer função contínua aos dados de entrada com acurácia arbitrária e, com duas camadas, até funções descontínuas podem ser representadas (RUSSELL; NORVIG; DAVIS, 2010). A Figura 3 exemplifica a estrutura de uma MLP.

Figura 3 - Estrutura de uma MLP



Fonte: Autoria própria.

3.5.4 Adaptive Boost (AdaBoost)

O AdaBoost é um algoritmo de *ensemble learning* que utiliza o método de *boosting*. Assim como explicado para o RF, ele combina os resultados de um conjunto de modelos e utiliza a técnica de *bagging*. Porém, acrescenta a técnica de *boosting*, que consiste em atribuir pesos às amostras, de forma que as classificadas erroneamente recebem um incremento no valor desse peso, e as classificadas corretamente, recebem um decremento. Isso faz com que o próximo modelo treinado tenha mais ênfase nas amostras mais difíceis de classificar (TAN; STEINBACH; KUMAR, 2014).

Mesmo que o modelo de entrada seja um classificador fraco, com acurácia próxima de um palpite aleatório (50%), o AdaBoost retorna um modelo de *ensemble* capaz de classificar de forma eficiente o conjunto de treino para uma quantidade suficientemente grande de modelos treinados com *boosting*, não importa o quão complexa seja a função a ser aprendida (RUSSELL; NORVIG; DAVIS, 2010).

3.5.5 Métricas de Avaliação

Métricas comumente utilizadas para avaliar o desempenho de classificadores são acurácia, precisão, sensibilidade, especificidade e F1-score. Essas métricas são calculadas baseado nas quantidades de casos Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN). A denominação “Positivo” se refere à classe que está sob observação, e “Negativo” se refere às demais classes presentes no problema. Dessa forma, VP são as amostras que foram corretamente classificadas em relação à classe observada, VN são as amostras corretamente classificadas em relação às demais classes, FP são as amostras erroneamente classificadas pertencentes a classe de observação, e FN são amostras erroneamente classificadas pertencentes às demais classes.

Diante disso, as métricas citadas são calculadas de acordo com as seguintes equações:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}, \quad (3)$$

$$Precisão = \frac{VP}{VP + FP}, \quad (4)$$

$$Especificidade = \frac{VN}{VN + FP}, \quad (5)$$

$$Sensibilidade = \frac{VP}{VP + FN}, \quad (6)$$

$$F1\ score = 2 \left(\frac{Precisão \cdot Sensibilidade}{Precisão + Sensibilidade} \right). \quad (7)$$

A acurácia é uma medida geral de acertos do modelo; a precisão se refere à capacidade do modelo de acertar as instâncias positivas; a especificidade mede a capacidade do modelo de identificar as instâncias negativas, e a sensibilidade, as instâncias positivas; o F1 score condensa a precisão e a sensibilidade em uma única métrica.

3.6 Métodos de Seleção de Atributos

Seleção de atributos é um tema relevante e recorrente em problemas de agrupamento (*clustering*) e classificação. Escolher um subconjunto de atributos mais adequado leva à redução da dimensionalidade dos dados, o que aumenta a performance dos algoritmos por diminuir a complexidade do problema e evitar dados redundantes ou irrelevantes (DE LA HOZ et al., 2014).

Algoritmos de seleção de atributos são divididos em três categorias de acordo com o critério de avaliação utilizado: filtragem, empacotamento (*wrapping*) e híbrido. O método de filtragem se baseia nas características gerais dos dados para avaliar e selecionar subconjuntos de atributos sem a necessidade de nenhum algoritmo de mineração. O método de empacotamento requer um algoritmo de mineração e usa a performance desse algoritmo como critério de avaliação. Ele procura os atributos que melhor se adequem ao algoritmo visando aumentar a performance da mineração, mas tende a ter maiores custos computacionais do que o método de filtragem. O método híbrido tira vantagem dos dois métodos anteriores aplicando os diferentes critérios de avaliação em estágios diferentes do processo (HUAN LIU; LEI YU, 2005).

Os algoritmos utilizados no presente estudo, o *Sequential Forward Floating Selection* (SFFS) e o *Sequential Backward Floating Selection* (SBFS), são do tipo de empacotamento. O SFFS funciona adicionando os atributos, um por um, ao algoritmo de aprendizado, com o número de amostras classificadas erroneamente sendo o critério de avaliação de desempenho. Quando a adição de um atributo ao modelo de predição diminui o número de erros, ele é mantido e a próxima iteração busca adicionar outro atributo ao modelo. Quando a adição de um atributo não diminui, ou até aumenta os erros, ele é descartado e o algoritmo segue para o próximo atributo. Atributos descartados ainda podem ser testados novamente, observando a sua interferência em diferentes subconjuntos formados durante o empacotamento. O SBFS faz o processo inverso, ou seja, inicia o algoritmo de mineração com todos os atributos disponíveis e busca melhorar o desempenho excluindo os atributos.

3.7 Regressão Linear

Regressão linear é um dos mais comuns e compreensíveis algoritmos de ML e estatística. É utilizado para achar a relação linear entre um ou mais preditores, e pode ser dividido em dois tipos: regressão simples e regressão múltipla (MAULUD; ABDULAZEEZ, 2020). Segundo (CHEIN, 2019), regressão linear pode ser um instrumento estatístico utilizado, simplesmente, para resumir dados e informações, e, na análise de regressão, a preocupação é sempre com dependência estatística entre as variáveis.

Em resumo, regressão linear busca calcular os coeficientes, β_i , que melhor relacionam uma variável dependente, Y , com as variáveis independentes, X_i , de um conjunto de dados, onde $i = \{1, \dots, I\}$ representa o conjunto de preditores escolhidos para compor o problema. Diversos estudos utilizam regressão linear para identificar quais variáveis

(preditores) são mais importantes e relevantes para a predição. Diferentemente dos classificadores, a regressão faz a predição de um valor numérico, e não de um valor categórico.

3.7.1 Métricas de Performance

As métricas de performance utilizadas para analisar a regressão linear são, geralmente, Raiz do Erro Quadrático Médio (*Root Mean Squared Error* – RMSE), Coeficiente de Determinação (R^2) e Coeficiente de Determinação Ajustado (R^2 ajustado). O coeficiente de determinação é uma medida de quanto o modelo se ajusta à variância dos dados, compreendida entre 0 e 1, porém ele aumenta à medida que mais variáveis preditoras são adicionadas ao problema, ao passo que coeficiente de determinação ajustado penaliza o modelo pelas variáveis que não apresentam uma melhoria significativa, sendo uma medida mais realista da qualidade do modelo.

Além disso, o *p-value* é outra métrica muito importante na regressão, utilizada para a análise da importância das variáveis ao modelo de predição. Ele realiza o teste de hipótese nula, ou seja, verifica se uma variável não possui efeito significativo sobre a variável dependente. Dessa forma, quanto menor for o valor obtido de *p-value*, mais significativa essa variável é para o problema.

3.7.2 *Stepwise Regression*

O algoritmo de *stepwise regression* foi o primeiro modelo com procedimento de seleção de atributos, desenvolvido em 1967, por Harold J. Breux. Em resumo, em um conjunto com p variáveis, 2^p modelos podem ser construídos, e possivelmente todos devem ser levados em consideração. Contudo, para um valor de p muito alto, isso se torna inviável. Assim, o algoritmo de *stepwise regression* analisa apenas um subconjunto de todas as possibilidades de regressão. As variáveis são selecionadas uma por vez, em duas abordagens possíveis: avançada e retrógrada, em semelhança ao exposto nos algoritmos SFFS e SBFS, ou ainda uma combinação das duas abordagens. A seleção em cada passo é feita a partir de um critério, que pode ser o menor *p-value*, maior R^2 ajustado, menor erro de predição, entre outros (MAULUD; ABDULAZEEZ, 2020).

4 METODOLOGIA

A metodologia aplicada neste trabalho consiste na aplicação do método de KDD à base de dados disponível e a interpretação dos resultados, tanto dos algoritmos de predição, como de análise de importância dos atributos, com paralelos à estudos relacionados à SM e à QV disponíveis na literatura.

4.1 Base de Dados

A base de dados utilizada foi montada no trabalho de dissertação na área de saúde da família, do curso de medicina da Universidade Federal do Ceará – *Campus* Sobral, intitulado “Qualidade de Vida e Saúde Mental de Estudantes Universitários” (OLIVEIRA, 2020). Ela é composta pelas respostas de 880 estudantes de cursos de graduação da Universidade do Vale do Acaraú, em Sobral – CE, à um FSAC, elaborado pela autora e contido no trabalho citado, e aos formulários ISM e WHOQOL-Bref.

Os dados brutos já haviam sido tratados para a análise estatística (OLIVEIRA, 2020), o que inclui a aplicação das instruções fornecidas no WHOQOL-Bref para o ajuste dos valores em questões com formulação negativa e o cálculo das pontuações por domínio. A ferramenta utilizada para isso foi o Microsoft Excel.

O FSAC, presente no Anexo C, é composto por 26 questões, contemplando dados sociodemográficos, como sexo e idade, dados voltados à vivência acadêmica, como o curso de graduação e recebimento de bolsa ou auxílio, e dados clínicos, como o uso de substâncias psicoativas ou medicamentos. O WHOQOL-Bref é composto também por 26 questões, e o ISM, por 38, totalizando 90 itens compondo a base de dados inicial. O tratamento complementar dos dados e aplicação nos algoritmos de predição e seleção de atributos foram realizados no MATLAB versão 2023a.

4.2 Aplicação do método KDD

Esta seção comenta as etapas do método KDD aplicadas aos dados, sendo elas: 1. Seleção, 2. Pré-processamento, 3. Transformação, 4. Mineração de dados e 5. Avaliação. Como explicado anteriormente, a etapa de seleção já havia sido realizada em (OLIVEIRA, 2020), sendo necessário apenas mais alguns ajustes, comentados na Seção 4.2.1. Os critérios de avaliação escolhidos são expostos na Seção 4.2.4, e a apresentação dos resultados e discussão é realizada na Seção 5.

4.2.1 Seleção e Pré-processamento

A importação da base de dados para a área de trabalho do MATLAB revelou 8 dados faltosos. Optou-se, então, pela exclusão das amostras referentes, atualizando a contagem para 872 amostras utilizadas nos algoritmos de predição.

Foram planejados 4 cenários para avaliação nos algoritmos de mineração, de acordo com o exposto na Tabela 3.

Tabela 3 - Cenários considerados para avaliação

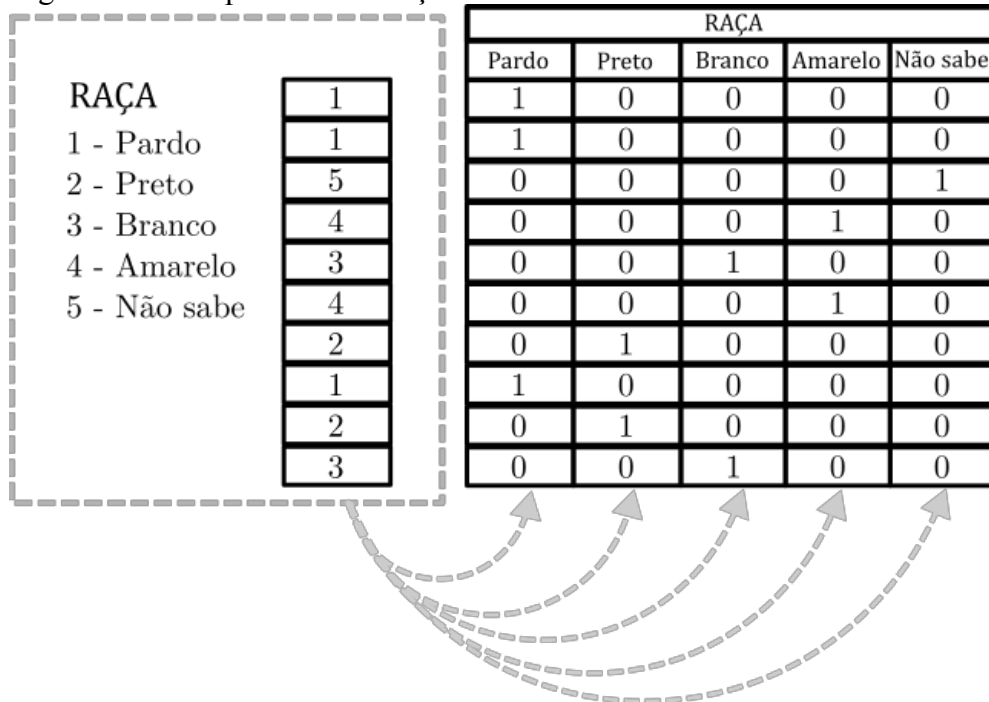
Entrada	Saída
FSAC	Qualidade de Vida
FSAC + ISM	Qualidade de Vida
FSAC	Saúde Mental
FSAC + WHOQOL-Bref	Saúde Mental

Por conta de um desbalanço observado entre as classes em ambos os casos, comentado em detalhes na Seção 4.2.2, foi aplicada a técnica de *undersampling*, que consiste em nivelar a quantidade de amostras entre as classes para evitar que os algoritmos de predição fiquem enviesados à classe em maior número no conjunto de dados. Dessa forma, mais 4 cenários foram adicionados à avaliação, seguindo a mesma orientação dos 4 mencionados anteriormente, mas sobre a influência do método de *undersampling*, totalizando 8 cenários de avaliação.

4.2.2 Transformação

O FSAC contém questões cujas respostas se referem à múltiplas categorias. Por exemplo, a questão 3 se refere à identificação racial, sendo os itens divididos em: (1) Pardo, (2) Preto, (3) Branco, (4) Amarelo, (5) Não sabe. Na base de dados, isso forma uma coluna, representando a variável “raça”, com valores distribuídos de 1 à 5, o que pode ser interpretado erroneamente pelos algoritmos de mineração, induzindo uma associação de pesos. Para evitar esse problema, aplica-se a técnica de binarização, onde se criam novas variáveis para cada valor categórico da variável original, ou seja, a variável “raça” se subdivide em 5 novas variáveis contendo colunas compostas por 0’s e 1’s, onde 1 indica pertencimento à categoria, e zero, não pertencimento. A Figura 4, na página a seguir, exemplifica esse processo.

Figura 4 – Exemplo de binarização de uma variável



Fonte: Autoria própria.

Após uma análise explanatória, algumas questões foram descartadas por terem sido interpretadas como de pouca utilidade aos algoritmos de mineração. Dentre elas, têm-se “local de origem” e “local de residência”, por conterem muitas opções de cidade preenchidas pelos participantes, o que tornaria necessário a criação de muitas variáveis binárias, aumentando dimensionalidade dos dados sem promover grandes ganhos de informação ao problema.

A questão 14 indaga se o participante considera seu curso estressante, e depois abre um leque de opções para selecionar o motivo específico de maior estresse, sendo elas: “matérias”, “didática do professor”, “provas e apresentações de seminários” e “outros”. Esses motivos foram também descartados em razão de tanto terem sido considerados menos relevantes para o problema do que apenas a resposta geral, com 1 para a opção de considerar o curso estressante, e 2 para não considerar, quanto a presença da opção aberta “outros” gerar novamente o problema da criação de muitas variáveis binárias sem grande custo-benefício para os algoritmos.

Por fim, pelos mesmos motivos já citados, as questões referentes à qual bolsa ou auxílio estudantil o participante recebe, quais medicamentos e quais substâncias psicoativas o participante faz uso, também foram descartadas. Para fins de brevidade, a Tabela 4 mostra um resumo dos atributos selecionados do FSAC ao fim do processo.

Tabela 4 - Atributos extraídos do FSAC

1.	Sexo	31.	Motivo afastamento – saúde
2.	Idade	32.	Motivo afastamento – financeiro
3.	Raça – pardo	33.	Motivo afastamento – trabalho
4.	Raça – preto	34.	Motivo afastamento – outros
5.	Raça – branco	35.	Turno – matutino
6.	Raça – Amarelo	36.	Turno – vespertino
7.	Raça – Não sabe	37.	Turno – noturno
8.	Situação civil – solteiro	38.	Turno – integral
9.	Situação civil – casado	39.	Transporte – a pé
10.	Situação civil – união estável	40.	Transporte – coletivo
11.	Situação civil – viúvo	41.	Transporte – próprio
12.	Frequência com que viaja à cidade natal	42.	Transporte – táxi / moto-táxi
13.	Reside com – familiares	43.	Trabalha ou não trabalha
14.	Reside com – sozinho	44.	Estagia ou não estagia?
15.	Reside com – república	45.	Recebe bolsa ou auxílio?
16.	Reside com – amigos/colegas	46.	Faz atividade física?
17.	Religião – católica	47.	Frequência com que faz atividade física
18.	Religião – evangélica	48.	Horas de lazer
19.	Religião – testemunha de jeová	49.	Atividades de lazer – dormir
20.	Religião – espírita	50.	Atividades de lazer – ficar com a família
21.	Religião – outros	51.	Atividades de lazer – ouvir música
22.	Curso – ciências biológicas e saúde	52.	Atividades de lazer – assistir filme
23.	Curso – negócios e administração	53.	Atividades de lazer – passear / viajar
24.	Curso – ciências humanas e sociais	54.	Atividades de lazer – ler
25.	Curso – exatas e tecnologias	55.	Atividades de lazer – fazer atividade física
26.	Qual semestre está cursando?	56.	Atividades de lazer – outras
27.	Quantas disciplinas está cursando?	57.	Faz uso de medicamentos?
28.	Quantas disciplinas já reprovou?	58.	Faz uso de substância psicoativas?
29.	Considera o curso estressante?	59.	Frequência do uso de substâncias psicoativas
30.	Já se afastou dos estudos?	60.	Horas de sono

Seguindo as instruções do manual do ISM, os domínios “Ansiedade”, “Depressão”, “Laços Emocionais”, “Afeto Positivo” e “Perda de Controle Emocional/Comportamental” foram computados, e foi feita a transformação da pontuação para valores de 0 a 100, seguindo a equação (3), vista abaixo:

$$X_{0-100} = \frac{X - \min(X)}{\max(X) - \min(X)} \cdot 100, \quad (8)$$

sendo X um vetor.

Além disso, a pontuação geral também foi calculada e transformada à escala de 0 a 100, e utilizada para definir as classes de SM nas quais os participantes se encontravam, de acordo com as seguintes regras, utilizadas em (OLIVEIRA, 2020):

$$Y_i \leq \bar{Y} - \sigma(Y) \rightarrow \text{Nível baixo} \rightarrow \text{Classe 1}, \quad (9)$$

$$\bar{Y} - \sigma(Y) \leq Y_i \leq \bar{Y} + \sigma(Y) \rightarrow \text{Nível moderado} \rightarrow \text{Classe 2}, \quad (10)$$

$$Y_i \geq \bar{Y} + \sigma(Y) \rightarrow \text{Nível elevado} \rightarrow \text{Classe 3}, \quad (11)$$

sendo Y_i a pontuação individual de cada participante, \bar{Y} a média das pontuações e $\sigma(Y)$ o desvio padrão de Y . A distribuição de classes ficou sendo de 153 classe 1, 570 classe 2 e 149 classe 3.

Em relação à classificação da QV, também foi calculada a pontuação total obtida no WHOQOL-Bref por cada participante e realizada a classificação de acordo com o mesmo processo feito em (OLIVEIRA, 2020) à pontuação na escala Likert, expandido para escala de 0 à 100:

$$1 < Y_i \leq 47,5 \rightarrow \text{Necessita melhorar} \rightarrow \text{Classe 1}, \quad (12)$$

$$47,5 < Y_i \leq 72,5 \rightarrow \text{Regular}, \rightarrow \text{Classe 2}, \quad (13)$$

$$72,5 < Y_i < 100 \rightarrow \text{Boa}. \rightarrow \text{Classe 3}. \quad (14)$$

Mais uma classe com $Y_i = 100$ era mencionada em (OLIVEIRA, 2020), se referindo à QV “muito boa”, mas nenhum participante atingiu essa pontuação. Dessa forma, a contabilização das classes foi de 227 classe 1, 542 classe 2 e 103 classe 3.

Como mencionado anteriormente, foi aplicada também a técnica de *undersampling* devido ao desbalanço observado entre as classes, tanto em relação a SM, quanto a QV. Dessa forma, no caso da predição da SM, a classe em menor quantidade é a 3, com 149 amostras, levando então a serem selecionadas também apenas 149 amostras aleatórias das classes 1 e 2, totalizando um novo conjunto de dados com 447 amostras. No

caso da predição da QV, a menor classe foi novamente a 3, com 103 amostras, reduzindo então as classes 1 e 2 a também 103 selecionadas aleatoriamente, totalizando 309 amostras em um novo conjunto.

4.2.3 Mineração

Os algoritmos escolhidos para etapa de mineração foram os classificadores RF, SVM, MLP e AdaBoost. Cada um foi treinado com os conjuntos de dados dos 8 cenários propostos, visando identificar qual a melhor estratégia de avaliação.

Todos os modelos, com exceção do RF, passaram por otimização de hiperparâmetros feitas por *gridsearch*, que consiste em testar todas as combinações possíveis de valores a fim de encontrar o caso com melhor desempenho. Além disso, o desempenho dos algoritmos foi avaliado pela técnica de validação cruzada, utilizando Kfold com $K = 5$.

Para o algoritmo de RF, a função do MATLAB escolhida foi a *TreeBagger*, por possuir mais parâmetros de ajustes e funcionalidades que a *fitcensemble*, que também executa o algoritmo de RF. A atualização dos hiperparâmetros foi feita manualmente, sendo eles: “*MinLeafSize*”, que consiste no tamanho mínimo dos nós, sendo mantido o valor padrão de 1; “*NPredictorsToSample*”, que se refere ao número de atributos selecionados aleatoriamente para compor o subconjunto de cada árvore, sendo mantido o padrão, que é a raiz quadrada do número total de atributos; e “*NTrees*”, que se refere ao número de árvores criadas para o modelo, cujo valor escolhido foi 100, visto que o seu incremento apresentou aumento de custos computacionais sem ganhos de desempenho. Esses valores foram mantidos para os 8 cenários.

Tendo em vista que o problema envolve 3 classes em ambos os casos, a resolução de problemas de classificação multi-classe, utilizando o SVM, no MATLAB, é feita pela função *fitcecoc*, que resolve problemas de classificação envolvendo múltiplas classes pela combinação de um conjunto de classificadores binários. Em resumo, esse algoritmo necessita de um design de codificação, para definir quais classes cada modelo binário contido no conjunto treina, e um esquema de decodificação, para definir como as predições de cada um são agregadas ao classificador multi-classes. Dessa forma, os hiperparâmetros otimizados para o SVM multi-classe foram: “*Coding*”, para definir qual o design de codificação do problema; “*BoxConstraint*”, que se refere a uma constante de ajuste das margens (largura) da região de decisão; e “*KernelScale*”, que se refere a uma escala de ajuste da curva de decisão.

Em relação ao MLP, a função utilizada foi a *fitcnet*, e os hiperparâmetros otimizados foram: “*NumLayers*”, que define a quantidade de camadas ocultas na rede; “*LayerSizes*”, define a quantidade de neurônios em cada camada; “*Activation*”, define a função de ativação dos neurônios entre ReLu, sigmoide e tangente hiperbólica; e “*Lambda*”, que controla a penalização dos pesos para evitar *overfitting*.

Por fim, o AdaBoost multi-classe é utilizado pela função *fitcensemble*, com os parâmetros de entrada: (“*Method*”, “*AdaBoostM2*”). Os hiperparâmetros otimizados foram: “*NumLearningCycles*”, que define o número de modelos que serão treinados para compor o conjunto (*ensemble*); “*LearnRate*”, que define a taxa de aprendizado, ou seja, a velocidade de ajuste dos modelos; e “*MinLeafSize*”, que define o tamanho mínimo dos nós.

Ao final do treinamento dos 4 algoritmos nos 8 cenários propostos, gerando 32 modelos, foi realizada a seleção de atributos com os algoritmos SFFS e SBFS usando o modelo de melhor desempenho geral, o RF. Além disso, ainda empregando o algoritmo de RF, também foi testada a predição de cada domínio individualmente, tanto do WHOQOL-Bref, quanto do ISM, visando também observar onde existe a maior correlação dos dados e qual domínio se adequa mais aos conjuntos de dados de treinamento.

Para a regressão linear, o algoritmo utilizado foi o *stepwiselm*, que adiciona ou retira variáveis do modelo a partir de critérios estatísticos que medem a adequação do modelo à variância dos dados. Como saída, o algoritmo fornece os valores de RMSE, R^2 , R^2 ajustado, entre outros, para análise de performance do modelo, e os valores de *p-value* para cada variável selecionada. Dois modelos foram gerados, um para predição da QV, usando como entrada os dados do FSAC e o ISM, e um para a predição da SM, utilizando como entrada os dados do FSAC e o WHOQOL-Bref.

4.2.4 Avaliação

Para os classificadores, a acurácia foi tida como o critério geral de avaliação de desempenho, sendo calculada para todos os modelos, e as métricas de precisão, sensibilidade, especificidade e f1 score foram calculadas apenas para os melhores modelos, com o intuito de aprofundar a análise. Para a regressão, foram calculadas métricas de RSME, R^2 e R^2 ajustado para a avaliação de quanto o modelo se ajusta à variância dos dados.

Sobre a importância dos atributos, pelo método de classificação, ela foi obtida como uma das propriedades do modelo de RF gerado pela função *TreeBagger*, chamada “*OOBPermutedPredictorDeltaError*”. O valor obtido por cada atributo é o resultado da média

calculada entre as árvores do modelo cujo cada atributo foi permutado, dividida pelo desvio padrão do *ensemble* inteiro. Pelo método de regressão, ela é interpretada pelos valores de *p-value* calculados para cada variável pela função *stepwiselm*. Os resultados foram comparados também com os obtidos pela seleção de atributos realizada pelos algoritmos SFFS e SBFS, afim de verificar a compatibilidade dos resultados obtidos por diferentes abordagens.

5 RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados obtidos pelos algoritmos de predição e a análise de importância dos atributos, acompanhados de paralelos traçados com a discussão disponível na literatura. Na Subseção 5.1, serão expostos os resultados das predições, da otimização de parâmetros e demais métricas de avaliação dos modelos, realizando-se um comparativo entre os desempenhos dos algoritmos. A Subseção 5.2 disserta sobre o resultado da seleção de atributos e cálculo da importância dos atributos, comparando os atributos com maiores ganhos de informação com os selecionados pelos métodos de SFFS e SBFS. Por fim, a Seção 5.3 apresenta os resultados da regressão linear.

5.1 Modelos de Predição

Foram gerados 32 modelos de predição a partir de 4 algoritmos sendo treinados por 8 conjuntos de dados diferentes, de acordo com os cenários propostos pela Tabela 3, com e sem a aplicação de *undersampling*. Os comentários sobre os resultados da otimização dos hiperparâmetros serão reservados apenas para os modelos de melhor desempenho. A Tabela 5 mostra as acurácias obtidas pelos modelos sem a aplicação da técnica de *undersampling*.

Tabela 5 - Acurácias dos modelos de predição sem *undersampling* ($N = 872$ Amostras)

Entrada	Saída	Random Forest	SVM	MLP	AdaBoost
FSAC (I)	WHOQOL-Bref	64,79%	66,31%	65,82%	63,26%
FSAC + ISM (II)	WHOQOL-Bref	77,40%	76,60%	75,00%	76,36%
FSAC (III)	ISM	66,28%	65,60%	67,32%	66,74%
FSAC + WHOQOL-Bref (IV)	ISM	78,44%	76,60%	77,29%	78,21%

É possível observar os ganhos na capacidade de predição ao adicionar as informações do WHOQOL-Bref e do ISM, evidenciando uma correlação significativa entre os dois instrumentos de avaliação, como também observado entre os instrumentos avaliados em (AY-WOAN et al., 2006). Além disso, observa-se que utilizar os dados do WHOQOL-Bref para realizar a predição da SM computada pelo ISM retorna resultados melhores que o caso contrário, indicando que o WHOQOL-Bref faz uma análise indireta da SM de forma mais eficiente do que o ISM faz da QV. O melhor modelo foi o RF, tanto para a predição da QV,

com 77,40% de acurácia, quanto para a SM, com 78,44% de acurácia. Em contrapartida, os dados do FSAC se mostram insuficientes para servir como base para a análise da QV e SM, atingindo acurácia máxima de apenas 66,31% para a QV, utilizando o modelo de SVM, e 67,32% para a SM, utilizando o modelo de MLP. A Tabela 6 mostra os hiperparâmetros otimizados dos modelos dos casos II e IV da Tabela 5.

Tabela 6 - Hiperparâmetros dos casos sem *undersampling*

Modelos	FSAC + ISM	FSAC + WHOQOL-Bref
Random Forest	NTree – 100 MinLeafSize – 1 NPredictores - 11	NTree – 100 MinLeafSize – 1 NPredictores - 10
SVM	Coding – onevsone BoxConstraint – 0.1 KernelScale – 10	Coding – onevsone BoxConstraint – 215.44 KernelScale – 215.44
MLP	NumLayers – 3 Activations – none Lambda – 1.913e-06 LayersSizes – [1 1 24]	NumLayers – 2 Activations – none Lambda – 0.053229 LayersSizes – [300 159 0]
AdaBoost	NumLearningCycles – 324 LearnRate – 0.21544 MinLeafSize - 113	NumLearningCycles – 136 LearnRate – 1 MinLeafSize - 113

A Tabela 7 mostra os resultados para os modelos treinados após a aplicação da técnica de *undersampling*, redimensionando os conjuntos de treinamento para 309 amostras para a classificação da QV e 447 amostras para a classificação da SM.

Tabela 7 - Acurácias dos modelos de predição com *undersampling*

Entrada	Saída	Random Forest	SVM	MLP	AdaBoost
FSAC (I)	WHOQOL-Bref	60,84%	57,58%	56,63%	52,69%
FSAC + ISM (II)	WHOQOL-Bref	76,05%	74,11%	75,73%	77,35%
FSAC (III)	ISM	59,28%	54,14%	52,90%	52,81%
FSAC + WHOQOL-Bref (IV)	ISM	75,83%	72,49%	72,91%	75,17%

Fica evidente uma piora geral de desempenhos dos algoritmos, mas mais severa nos modelos treinados apenas pelos dados do FSAC, atingindo acurácias próximas a 50%, que são valores equivalentes à classificação realizada por palpites aleatórios. Isso demonstra que a queda no número de amostras utilizadas para treinamento foi drástica, prejudicando o treinamento dos modelos, tornando inviável a obtenção de frutos provenientes da técnica de *undersampling*. A utilização do WHOQOL-Bref e do ISM para as predições manteve sua importância, dado que os algoritmos apresentaram apenas uma pequena queda de desempenho. Os melhores casos foram o modelo de AdaBoost, para a predição da QV, com 77,35% de acurácia, e o RF para a predição da SM, com 75,83% de acurácia. A Tabela 8 mostra os hiperparâmetros otimizados para os casos II e IV da Tabela 7.

Tabela 8 - Hiperparâmetros dos casos com *undersampling*

Modelos	FSAC + ISM	FSAC + WHOQOL-Bref
Random Forest	NTree – 100 MinLeafSize – 1 NPredictores - 11	NTree – 100 MinLeafSize – 1 NPredictores - 10
SVM	Coding – onevsone BoxConstraint – 46.416 KernelScale – 46.416	Coding – onevsone BoxConstraint – 0.46416 KernelScale – 10
MLP	NumLayers – 1 Activations – sigmoid Lambda – 0.01163 LayersSizes – [24 0 0]	NumLayers – 1 Activations – sigmoid Lambda – 0.0080399 LayersSizes – [300 0 0]
AdaBoost	NumLearningCycles – 10 LearnRate – 1 MinLeafSize - 2	NumLearningCycles – 10 LearnRate – 1 MinLeafSize - 11

As Figuras 5 e 6, e as Tabelas 9 e 10 mostram as matrizes de confusão e os valores de precisão, sensibilidade, especificidade e f1 score obtidos pelos modelos de RF sem *undersampling* que atingiram acurácias de 77,40% para a predição da QV, e 78,44% para a predição da SM, respectivamente.

Percebe-se que a maior sensibilidade foi obtida para a predição da classe 2, o que indica maior capacidade do modelo de identificar instâncias da classe 2, refletindo no F1 score, que também foi o maior entre as 3 classes. Além disso, observa-se a menor sensibilidade à classe 3, sendo também a de maior percentual de erro visto na matriz de confusão da Figura 5, atribuindo-se esses valores ao fato de ser a classe menos abundante entre as amostras. Então, em resumo, o modelo tem mais facilidade em identificar pessoas com QV regular e os erros são, em geral, são em classificar pessoas com baixa ou boa QV, como regular.

Figura 6 - Matriz de confusão do modelo de RF para a predição da SM

		Acurácia		
Classes Verdadeiras	1	91	62	59,48%
	2	20	520	91,23%
	3		82	44,97%
		1	2	3
		Classes Preditas		

A Figura 6 mostra a distribuição dos erros e acertos da predição da SM. Observa-se que, em comparação com a classificação da QV, as amostras se concentram ainda mais na classe 2, sendo esta referente à SM regular. Além disso, de forma semelhante ao caso anterior, não houveram erros de classificação entre as classes 1 e 3. Contudo, novamente, foram computados mais erros que acertos para a predição da classe 3, atingindo 55,03% das amostras classificadas como classe 2, e 40,52% em relação a classe 1.

A classe 2, por sua vez, obteve 91,23% de acertos nas predições, revelando um percentual alto de acurácia, ao passo que 3,51% foram erroneamente classificadas como classe 1, e 5,26% como classe 3. As demais métricas são vistas na Tabela 10.

Tabela 10 - Métricas de avaliação do modelo de RF para a predição da SM

Classe	Precisão	Especificidade	Sensibilidade	F1 score
Classe 1	0,8198	0,9722	0,5948	0,6894
Classe 2	0,7831	0,5232	0,9123	0,8428
Classe 3	0,6907	0,9585	0,4497	0,5447

Pela Tabela 10, observa-se que, novamente, a classe 2 obteve os melhores resultados, sendo a classe com o maior número de amostras do conjunto de dados, compondo 65,36% do total, atingindo o valor de 0,9123 de sensibilidade, e, apesar de uma precisão menor que a classe 1, obteve o melhor F1 score. A classe 3, por sua vez, obteve novamente os piores índices de predição, sendo a classe em menor quantidade. Ou seja, o modelo tem dificuldade em identificar pessoas com boa SM, é bem calibrado para identificar pessoas com SM regular, e obtém mais acertos do que erros em identificar pessoas com baixa SM.

5.2 Seleção e Importância dos Atributos

Os atributos selecionados pelo método SFFS e apagados pelo SBFS são vistos na Tabela 11 e na Tabela 12, acompanhados das acurácias obtidas. O modelo treinado em ambos foi o de RF.

Tabela 11 - Resultados da seleção de atributos utilizando SFFS

Entrada	Saída	Atributos Selecionados	Acurácia
FSAC + WHOQOL-Bref	ISM	<ul style="list-style-type: none"> - Religião – Católica - Motivo de afastamento – Trabalho - WHOQOL-Bref – Em que medida você acha que a sua vida tem sentido? - WHOQOL-Bref – Domínio Psicológico 	74,70%
FSAC + ISM	WHOQOL-Bref	<ul style="list-style-type: none"> - Raça – Amarela - Situação Civil – União Estável - Religião – Testemunha de Jeová - ISM – Durante quanto tempo, no mês que passou, se sentiu calmo e em paz? - ISM – Durante quanto tempo, no mês que passou, se sentiu emocionalmente estável? 	75,20%

O método de SFFS conseguiu resumir drasticamente a dimensionalidade dos dados, o que reduz os custos computacionais, sem apresentar grandes perdas de desempenho.

Em relação aos atributos selecionados para a predição da SM, destaca-se a presença do domínio psicológico do WHOQOL-Bref, sendo intuitivamente a variável de maior correlação com a medição de SM do ISM. A seleção da variável “Em que medida você acha que a sua vida tem sentido?” reflete o exposto em (ZIKA; CHAMBERLAIN, 1992), onde fica evidente que a percepção sobre o sentido da vida é de suma importância para o bem estar psicológico e autoaceitação.

Sobre as variáveis sociodemográficas, a religião se fez presente em ambos os problemas de classificação, sendo apontado por (LUCCHETTI; KOENIG; LUCCHETTI, 2021) como capaz de ter efeitos positivos ou negativos na SM, dependendo de como cada pessoa utiliza suas crenças para lidar com os problemas. Já nos trabalhos (BORGES et al., 2021; MOREIRA-ALMEIDA; NETO; KOENIG, 2006), aponta-se que maiores índices de envolvimento religioso estão relacionados a melhores índices de SM, em geral para adultos e pessoas em situações de estresse.

Sobre a variável “Motivo de afastamento – Trabalho”, o afastamento dos estudos em decorrência da necessidade de trabalhar é um tema recorrente entre estudantes de ensino superior. Segundo relatado em (ALBUQUERQUE*, 2023; APUFSC, 2023), as dificuldades financeiras para se manter na universidade acabam por desmotivar os estudantes, que muitas vezes sofrem pela falta de amparo de bolsas de auxílio, ou pela necessidade de dividir uma rotina de trabalho e estudo, o que frequentemente se torna inviável de conciliar.

Em relação a predição da QV, as variáveis selecionadas do ISM refletem a importância da estabilidade emocional para a manutenção da QV. Segundo (ALMEIDA; BENEDITO; FERREIRA, 2017), a estabilidade emocional de um indivíduo é essencial pois reflete em vários aspectos da vida, de forma que, quando há uma alteração nesse equilíbrio, a QV do indivíduo é afetada.

Dentre as variáveis sociodemográficas, a variável “Religião” foi novamente selecionada, evidenciando sua importância tanto para SM, quanto para a QV. (ALMEIDA; BENEDITO; FERREIRA, 2017) também aponta que o exercício da prática religiosa ajuda a estabelecer o equilíbrio de sentimentos e emoções, que são fatores cruciais para a manutenção da QV.

A variável “Situação Civil” também foi selecionada, sendo indicado por (“The Effects of Marriage on Health”, 2007) que pessoas casadas são geralmente mais saudáveis que pessoas não casadas, e observado que o casamento leva à melhora de alguns pontos

relacionados a SM, diminuição do uso de serviços de saúde de alto custo, como enfermeiro(a) particular ou cuidador(a), e aumento da probabilidade da contratação de planos de saúde.

A questão racial se faz presente na seleção da variável “Raça”. O racismo é um fator de impacto em múltiplos âmbitos da QV. Segundo (WILLIAMS; PRIEST, 2015), o racismo está presente: institucionalmente, através de políticas e práticas que limitam o acesso a recursos e oportunidades na sociedade, o que restringe a mobilidade social e cria diferenças raciais no status socioeconômico e nas condições de vida e trabalho, prejudiciais ao bem-estar; culturalmente, provocando e sustentando o racismo institucional, criando um ambiente político hostil à políticas igualitárias; e individualmente, através dos estereótipos negativos, sustentados pelo racismo cultural, que fomentam respostas psicológicas prejudiciais a saúde, como o racismo internalizado. Além disso, a experiência subjetiva de discriminação racial é um tipo de experiência de vida estressante que pode levar a mudanças adversas nas condições de saúde e a padrões alterados de comportamento que aumentam os riscos à saúde. É possível perceber as relações entre o exposto e as facetas componentes dos domínios do WHOQOL-Bref, vistas na Tabela 2.

Em complemento, Faro e Pereira (2011) mencionam uma série de trabalhos, nacionais e internacionais, que revelam dados como: maiores taxas de mortalidade à crianças negras quando comparadas à brancas e pardas; maiores probabilidades de minorias étnicas/raciais vivenciarem situações prejudiciais ao desenvolvimento durante a vida, antecipando a morte; maior histórico de adoecimento, grave ou crônico, e maior propensão a doenças como hipertensão, diabetes, AIDS, tabagismo, alcoolismo, amputações, cegueira e doença renal-crônica, à pessoas negras. Além disso, negros também apresentam maiores índices de depressão, menores índices de bem-estar psicológico e autoestima, maior exposição ao estresse crônico e maior prevalência de transtornos adaptativos comuns.

Tabela 12 - Resultados da seleção de atributos utilizando SBFS

Entrada	Saída	Atributos Apagados	Acurácia
FSAC + WHOQOL-Bref	ISM	- Lazer – Ouvir música	76,80%
FSAC + ISM	WHOQOL- Bref	- Situação Civil – União Estável - Fez uso de alguma substância psicoativa durante os últimos três meses? - ISM – Durante o último mês, com	77,80%

		que frequência sentiu que você não tinha futuro, que não tinha para onde orientar a sua vida? - ISM – Domínio Laços Emocionais	
--	--	---	--

No caso do SBFS, observa-se que a maioria dos atributos são mantidos, não reduzindo tanto os custos computacionais, mas mantendo então a acurácia um pouco melhor do que os casos do SFFS.

O atributo apagado para o caso da predição da SM foi apenas “Ouvir música como atividade de lazer”, do questionário sociodemográfico, o que não gera muito impacto e nem indica algo significativo. Contudo, a diferença observada entre a acurácia de 76,80% obtida nesse caso e de 78,44% obtida na Tabela 5, pode ser evidencia tanto do caráter aleatório do algoritmo de RF, quanto de uma dificuldade de adaptação dos modelos ao conjunto de treinamento. Uma maior quantidade de amostras de treinamento seria o indicado para diminuir a variância dos dados.

Para a predição da QV, observa-se que a variável “Situação Civil – União Estável” é descartada, revelando uma contradição com algoritmo de SFFS, que a mantém no conjunto de treinamento. Isso possivelmente indica uma incapacidade de adequação dos algoritmos aos dados de treinamento, principalmente referentes ao FSAC, que apresenta um caráter mais heterogêneo. Isso se reflete mais uma vez no descarte da variável “Fez uso de alguma substância psicoativa durante os últimos três meses?”, também pertencente ao FSAC, uma vez que é de conhecimento geral que o uso de psicoativos degrada a QV dos usuários. Por fim, as variáveis “Durante o último mês, com que frequência sentiu que você não tinha futuro, que não tinha para onde orientar a sua vida?” e “Domínio Laços Emocionais” também foram descartadas.

Em relação à importância dos atributos, os dez atributos com os maiores ganhos de informação calculados pela função *TreeBagger* durante a execução do algoritmo de RF para a predição da SM e da QV são vistos nas Tabelas Tabela 13 e Tabela 14, respectivamente.

Tabela 13 – 10 maiores ganhos de informação dos atributos para a predição da SM

Atributos	Ganho de Informação
Domínio Psicológico	1.3290
Com que frequência você tem sentimentos negativos tais como: mau humor, desespero, ansiedade, depressão?	0.9574
Domínio Físico	0.7921
Quão satisfeito(a) você está consigo mesmo?	0.6968
Domínio Ambiente	0.5343
Quão seguro(a) você se sente em sua vida diária?	0.4998
Você tem energia suficiente para o seu dia a dia?	0.4864
Em que medida você acha que sua vida tem sentido?	0.4428
O quanto você precisa de algum tratamento médico para levar sua vida diária?	0.4370
Domínio Relações Sociais	0.4226

É notório que todos os atributos da Tabela 13 são provenientes do WHOQOL-Bref, sendo o “Domínio Psicológico” o de maior importância para a predição, como já havia sido indicado nos resultados do SFFS. Além disso, a variável “Em que medida você acha que sua vida tem sentido?” também fez parte dos resultados do SFFS, evidenciando a robustez da relevância das variáveis em diferentes métodos de avaliação. Além disso, os demais domínios também se fizeram presentes, reforçando como o WHOQOL-Bref é uma ferramenta bem elaborada e de suma importância para a análise também da SM.

Tabela 14 - 10 maiores ganhos de informação dos atributos para a predição da QV

Atributos	Ganho de Informação
Domínio Afeto Positivo	0.9952
Domínio Controle Emocional	0.7558
Quanto feliz e satisfeito você tem estado com a sua vida pessoal?	0.6950
Domínio Ansiedade	0.6166
Domínio Depressão	0.5646
Domínio Laços Emocionais	0.4986
Sentiu-se deprimido durante o último mês?	0.4366
Situação Civil – Viúvo	0.4280
Durante quanto tempo, no mês que passou, se sentiu triste e para baixo, de tal modo que nada o conseguia animar?	0.4213
Durante o último mês, com que frequência sentiu prazer nas coisas que fazia?	0.4175

Para a predição da QV, de forma semelhante à Tabela 13, quase todos os atributos fazem parte do ISM, com exceção do “Situação Civil – Viúvo”, sendo pertencente ao FSAC. É válido notar também que a variável “Situação Civil”, de forma geral, foi presente também nos resultados da seleção de atributos, mostrando-se de grande relevância para a QV. Todos os domínios do ISM também se firmaram entre os 10 atributos mais importantes, sendo o “Domínio Afeto Positivo” o de maior relevância.

Os maiores ganhos de informações, em ambos os casos de classificação, terem sido obtidos pelas variáveis do WHOQOL-Bref e do ISM, demonstra concordância com o apresentado em (OLIVEIRA, 2020), que aponta que quanto maior forem os índices dos domínios do WHOQOL-Bref, menores são as chances de desenvolver problemas psicológicos como depressão e ansiedade. Tendo isso em vista, a correlação entre os dois instrumentos foi medida também usando os domínios de cada um como saída dos algoritmos, utilizando o modelo de RF. Os resultados são vistos na Tabela 15.

Tabela 15 - Acurácias obtidas nas predições por domínio

Entrada	Saída	Acurácia
FSAC + ISM	Domínio Físico WHOQOL-Bref	65,13%
	Domínio Psicológico WHOQOL-Bref	71,21%
	Domínio Relações Sociais WHOQOL-Bref	55,04%
	Domínio Ambiente WHOQOL-Bref	66,51%
FSAC + WHOQOL-Bref	Domínio Ansiedade ISM	72,13%
	Domínio Depressão ISM	76,94%
	Domínio Controle Emocional ISM	75,00%
	Domínio Afeto Positivo ISM	77,63%
	Domínio Laços Afetivos ISM	68,59%

Em relação aos domínios do WHOQOL-Bref, como já indicado pelos resultados da seleção de atributos e ganho de informação, a predição do “Domínio Psicológico” é a que mais se adequa ao treinamento dos dados com a presença do ISM, atingindo a maior acurácia dentre os demais domínios. Além disso, a predição do “Domínio Relações Sociais” se mostrou ser a menos adequada aos dados do ISM, tendo sido também a variável com o menor ganho de informação da Tabela 13.

Em relação aos domínios do ISM, a predição do “Domínio Afeto Positivo” se mostrou ser a que mais se adequa ao treinamento utilizando o WHOQOL-Bref, e a razão disso pode ser observada pela comparação temática entre os itens que compõem o domínio de “Afeto Positivo” do ISM, na Tabela 1, e a temática geral do WHOQOL-Bref, na Tabela 2. Contudo, os demais domínios também obtiveram bons valores de acurácia, inclusive acima do obtido pelo domínio “Psicológico” do ISM, com exceção do domínio “Laços Afetivos”. Isso indica mais uma vez que o WHOQOL-Bref aborda de forma muito eficiente também as questões de SM, mais do que o ISM aborda questões de QV.

5.3 Regressão Linear

Os resultados da *stepwise regression* para a predição da QV retornou um modelo com RMSE de 7,44, R^2 de 0,729 e R^2 ajustado de 0,72. Diante da presença de dados heterogêneos, principalmente os que compõem o FSAC, o modelo apresentou um bom ajuste. Para termos de comparação com as análises anteriores, os 10 atributos de maior importância, utilizando a métrica do *p-value*, são vistos na Tabela 16, dado que o *p-value* é o resultado

para o teste de hipótese nula, onde quanto menor o valor de *p-value*, mais importante a variável é para a predição.

Tabela 16 - Seleção de atributos por *stepwise regression* para predição da QV

Variável	<i>p-value</i>
ISM – Quanto feliz e satisfeito você tem estado com a sua vida pessoal?	8.8191e-16
ISM – Domínio Controle Emocional	3.9824e-06
ISM – Durante o último mês, com que frequência sentiu prazer nas coisas que fazia?	1.3437e-05
FSAC – Já se afastou dos estudos?	1.7875e-05
ISM – Domínio Afeto Positivo	0.00019199
ISM - Com que frequência durante o último mês, acordou de manhã sentindo-se fresco e repousado?	0.00040777
FSAC - Horas de sono	0.0013249
ISM – Domínio Depressão	0.0016596
ISM - Com que frequência se sentiu nervoso ou apreensivo perante coisas que aconteceram, ou perante situações inesperadas, no último mês?	0.0041611
FSAC – Turno: vespertino	0.0074071

Observa-se que apenas três domínios do ISM foram contemplados por essa abordagem, sendo deixados de fora os domínios “Ansiedade” e “Laços Afetivos”, que foram também os de menores acurácias obtidas na Tabela 15. Por outro lado, variáveis pontuais figuraram na parte superior da tabela, sendo elas “Quanto feliz e satisfeito você tem estado com a sua vida pessoal?” e “Durante o último mês, com que frequência sentiu prazer nas coisas que fazia?”, sendo a primeira também selecionada entre os maiores ganho de informação da Tabela 14.

Além disso, a variável referente ao afastamento dos estudos foi novamente evidenciada, também tendo sido selecionada pelo SFFS, na Tabela 11. A variável referente ao turno de aulas do curso foi também dada como significativa.

Os resultados da predição da SM retornaram um modelo com RMSE de 10,8, R^2 de 0,766 e R^2 ajustado de 0,758. Os atributos selecionados com os 10 menores valores de *p-value* são vistos na Tabela 17.

Tabela 17 - Seleção de atributos por *stepwise regression* para predição da SM

Variável	p-value
WHOQOL-Bref – Com que frequência você tem sentimentos negativos tais como: mau humor, desespero, ansiedade, depressão?	4.3404e-15
WHOQOL-Bref – Domínio Psicológico	6.3963e-15
WHOQOL-Bref – Domínio Físico	2.5112e-10
FSAC – Turno: vespertino	1.8057e-07
WHOQOL-Bref – Em que medida você tem oportunidades de atividade de lazer?	0.00027902
WHOQOL-Bref – Quão satisfeito(a) você está com a sua saúde?	0.00064873
FSAC – Faz atividade física?	0.0015297
FSAC – Atividades de lazer: ficar com a família	0.0030128
FSAC – Qual semestre está cursando	0.004088
WHOQOL-Bref – Domínio Relações Sociais	0.0052269

A Tabela 17 mostra que os domínios foram novamente selecionados entre as variáveis mais importantes, com exceção do domínio “Ambiente”. A variável “Com que frequência você tem sentimentos negativos tais como: mau humor, desespero, ansiedade, depressão?” foi novamente selecionada, já tendo figurado como o segundo atributo com o maior ganho de informação da Tabela 13. Quatro variáveis do FSAC foram selecionadas, sendo a referente ao turno presente em ambos os modelos de regressão. Além disso, a prática de atividades física e lazer com a família também foram consideradas variáveis significativas.

6 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho teve como objetivo principal a verificação da eficácia do uso de algoritmos de ML para a predição da SM e QV de estudantes universitários, utilizando uma base de dados composta por dados sociodemográficos, acadêmicos e clínicos, presentes no FSAC, e dados obtidos das aplicações do questionário WHOQOL-Bref e do ISM. Além disso, outro objetivo era a análise de quais variáveis são mais relevantes para as predições.

Os dados do FSAC passaram pelas etapas de seleção e pré-processamento, conforme realizado no processo de KDD, além da etapa de transformação aplicada também aos dados do WHOQOL-Bref e do ISM. Assim, a base geral foi composta por 872 amostras. Após isso, quatro cenários de investigação foram propostos, dois utilizando apenas os dados do FSAC para a predição dos níveis de SM e de QV, e outros dois adicionando as contribuições do WHOQOL-Bref e do ISM aos dados de entrada. Além disso, a técnica de *undersampling* também foi aplicada aos quatro cenários citados, totalizando então oito cenários testados.

Para a etapa de mineração de dados, os algoritmos escolhidos para treinamento foram Random Forest, SVM, MLP e AdaBoost, com o Random Forest apresentando melhores resultados gerais. Os hiperparâmetros utilizados foram de 100 árvores compondo o *ensemble*, entre 10 e 11 atributos selecionados por árvore e tamanho mínimo dos nós de decisão de 1 amostra, para todos os cenários propostos. As acurácias obtidas nos cenários treinados apenas pelos dados do FSAC ficaram entre 63% e 67%, e com a utilização dos dados do WHOQOL-Bref e do ISM, subiram para entre 77% e 78%. A aplicação de *undersampling* piorou o desempenho dos modelos.

A seleção de atributos demonstrou que o domínio “Psicológico” do WHOQOL, a variável acerca de enxergar sentido na própria vida, a variável “Religião” e “Motivo de afastamento – Trabalho”, foram suficientes para realizar as predições da SM; e as variáveis “Raça”, “Religião”, “Situação Civil” e relacionadas a controle emocional do ISM, foram suficientes para a predição da QV, sem perdas significativas de acurácia, diminuindo então os custos computacionais envolvidos. Além disso, tanto os domínios do WHOQOL-Bref, quanto os do ISM, figuraram entre os maiores ganhos de informação para ambas as predições.

Para trabalhos futuros, visa-se a obtenção de mais amostras, advindas de estudantes de outras instituições de ensino superior, buscando assim tornar os modelos mais robustos à variância dos dados. Além disso, um grande potencial de melhoria é observado no ajuste do FSAC, buscando torná-lo mais eficiente à dinâmica dos algoritmos de predição.

REFERÊNCIAS

- ALBUQUERQUE*, 'DIOGO. **Dificuldades financeiras limitam permanência de estudantes no ensino superior.** Disponível em: <<https://www.correiobraziliense.com.br/euestudante/trabalho-e-formacao/2023/04/5085024-os-desafios-da-permanencia-estudantil.html>>. Acesso em: 31 maio. 2024.
- APUFSC, I. **Evasão estudantil: Desmotivação e dificuldades financeiras são travas à permanência de estudantes na UFSC.** Disponível em: <<https://www.apufsc.org.br/2023/06/27/evasao-estudantil-desmotivacao-e-dificuldades-financeiras-sao-travas-a-permanencia-de-estudantes-na-ufsc/>>. Acesso em: 31 maio. 2024.
- AWAD, A. G.; VORUGANTI, L. N. P. Intervention Research in Psychosis: Issues Related to the Assessment of Quality of Life. **Schizophrenia Bulletin**, v. 26, n. 3, p. 557–564, 1 jan. 2000.
- AY-WOAN, P. et al. Quality of Life in Depression: Predictive Models. **Quality of Life Research**, v. 15, n. 1, p. 39–48, 1 fev. 2006.
- BORGES, C. C. et al. Association between spirituality/religiousness and quality of life among healthy adults: a systematic review. **Health and Quality of Life Outcomes**, v. 19, n. 1, p. 246, 21 out. 2021.
- CHEIN, F. **Introdução aos modelos de regressão linear: um passo inicial para compreensão da econometria como uma ferramenta de avaliação de políticas públicas.** [s.l.] Enap, 2019.
- CORONEL-SANTOS, M. A.; RODRÍGUEZ-MACÍAS, J. C. Integral definition and conceptual model of mental health: Proposal from a systematic review of different paradigms. **Frontiers in Sociology**, v. 7, p. 978804, 25 nov. 2022.
- COURONNÉ, R.; PROBST, P.; BOULESTEIX, A.-L. Random forest versus logistic regression: a large-scale benchmark experiment. **BMC Bioinformatics**, v. 19, n. 1, p. 270, dez. 2018.
- Cresce a preocupação com a saúde mental dos estudantes.** Disponível em: <<https://www.institutounibanco.org.br/boletim/cresce-a-preocupacao-com-a-saude-mental-dos-estudantes/>>. Acesso em: 6 maio. 2024.
- DANOWITZ, A.; BEDDOES, K. **A Snapshot of Mental Health and Wellness of Engineering Students Across the Western United States.** 2020 IEEE Frontiers in Education Conference (FIE). **Anais...** Em: 2020 IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE). Uppsala, Sweden: IEEE, 21 out. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9273885/>>. Acesso em: 20 mar. 2024
- DE LA HOZ, E. et al. Feature selection by multi-objective optimisation: Application to network anomaly detection by hierarchical self-organising maps. **Knowledge-Based Systems**, v. 71, p. 322–338, nov. 2014.

ERDOĞAN, Z.; NAMLI, E. A living environment prediction model using ensemble machine learning techniques based on quality of life index. **Journal of Ambient Intelligence and Humanized Computing**, 3 set. 2019.

FARO, A.; PEREIRA, M. E. Raça, racismo e saúde: a desigualdade social da distribuição do estresse. **Estudos de Psicologia (Natal)**, v. 16, n. 3, p. 271–278, dez. 2011.

FAYYAD, U. From Data Mining to Knowledge Discovery in Databases. [s.d.].

GAINO, L. V. et al. O conceito de saúde mental para profissionais de saúde: 2018.

HUAN LIU; LEI YU. Toward integrating feature selection algorithms for classification and clustering. **IEEE Transactions on Knowledge and Data Engineering**, v. 17, n. 4, p. 491–502, abr. 2005.

LAIJAWALA, V. et al. **Classification Algorithms based Mental Health Prediction using Data Mining**. 2020 5th International Conference on Communication and Electronics Systems (ICCES). **Anais...** Em: 2020 5TH INTERNATIONAL CONFERENCE ON COMMUNICATION AND ELECTRONICS SYSTEMS (ICCES). Coimbatore, India: IEEE, jun. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9137856/>>. Acesso em: 30 set. 2023

LIANG, X. et al. Investigation of college students' mental health status via semantic analysis of Sina microblog. **Wuhan University Journal of Natural Sciences**, v. 20, n. 2, p. 159–164, abr. 2015.

LUCCHETTI, G.; KOENIG, H. G.; LUCCHETTI, A. L. G. Spirituality, religiousness, and mental health: A review of the current scientific evidence. **World Journal of Clinical Cases**, v. 9, n. 26, p. 7620–7631, 16 set. 2021.

MARTON, S. et al. GRANDE: Gradient-Based Decision Tree Ensembles for Tabular Data. 2023.

MAULUD, D.; ABDULAZEEZ, A. M. A Review on Linear Regression Comprehensive in Machine Learning. **Journal of Applied Science and Technology Trends**, v. 1, n. 2, p. 140–147, 31 dez. 2020.

MEDVEDEV, O. N.; LANDHUIS, C. E. Exploring constructs of well-being, happiness and quality of life. **PeerJ**, v. 6, p. e4903, 1 jun. 2018.

Mental health. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/mental-health-strengthening-our-response>>. Acesso em: 26 abr. 2024a.

Mental health. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/mental-health-strengthening-our-response>>. Acesso em: 26 abr. 2024b.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997.

MOREIRA-ALMEIDA, A.; NETO, F. L.; KOENIG, H. G. Religiousness and mental health: a review Religiosidade e saúde mental: uma revisão. **Rev Bras Psiquiatr.**, [s.d.].

OLIVEIRA, L. D. S. UNIVERSIDADE FEDERAL DO CEARÁ-UFC FACULDADE DE MEDICINA- CAMPUS SOBRAL MESTRADO ACADÊMICO EM SAÚDE DA FAMÍLIA. 2020.

OMS destaca necessidade urgente de transformar saúde mental e atenção - OPAS/OMS | Organização Pan-Americana da Saúde. Disponível em: <<https://www.paho.org/pt/noticias/17-6-2022-oms-destaca-necessidade-urgente-transformar-saude-mental-e-atencao>>. Acesso em: 6 maio. 2024.

Pandemia de COVID-19 desencadeia aumento de 25% na prevalência de ansiedade e depressão em todo o mundo - OPAS/OMS | Organização Pan-Americana da Saúde. Disponível em: <<https://www.paho.org/pt/noticias/2-3-2022-pandemia-covid-19-desencadeia-aumento-25-na-prevalencia-ansiedade-e-depressao-em>>. Acesso em: 6 maio. 2024.

PRISCILLA DOOSHIMA, M. A Predictive Model for the Risk of Mental Illness in Nigeria Using Data Mining. **International Journal of Immunology**, v. 6, n. 1, p. 5, 2018.

RIBEIRO, J. L. P. INVENTÁRIO DE SAÚDE MENTAL. [s.d.].

RUSSELL, S. J.; NORVIG, P.; DAVIS, E. **Artificial intelligence: a modern approach**. 3rd ed. Upper Saddle River: Prentice Hall, 2010.

SEIDL, E. M. F.; ZANNON, C. M. L. D. C. Qualidade de vida e saúde: aspectos conceituais e metodológicos. **Cadernos de Saúde Pública**, v. 20, n. 2, p. 580–588, abr. 2004.

SRIVIDYA, M.; MOHANAVALLI, S.; BHALAJI, N. Behavioral Modeling for Mental Health using Machine Learning Algorithms. **Journal of Medical Systems**, v. 42, n. 5, p. 88, maio 2018.

TAN, P.-N.; STEINBACH, M.; KUMAR, V. **Introduction to data mining**. New internat. edition ed. Harlow: Pearson, 2014.

The Effects of Marriage on Health: A Synthesis of Recent Research Evidence. Research Brief. Disponível em: <<https://aspe.hhs.gov/reports/effects-marriage-health-synthesis-recent-research-evidence-research-brief>>. Acesso em: 2 jun. 2024.

The World Health Organization quality of life assessment (WHOQOL): Position paper from the World Health Organization. **Social Science & Medicine**, v. 41, n. 10, p. 1403–1409, nov. 1995.

VAN LENTE, E. et al. Measuring population mental health and social well-being. **International Journal of Public Health**, v. 57, n. 2, p. 421–430, abr. 2012.

WILLIAMS, D. R.; PRIEST, N. Racismo e Saúde: um corpus crescente de evidência internacional. **Sociologias**, v. 17, n. 40, p. 124–174, dez. 2015.

ZIKA, S.; CHAMBERLAIN, K. On the relation between meaning in life and psychological well-being. **British Journal of Psychology**, v. 83, n. 1, p. 133–145, 1992.

ANEXOS

ANEXO A – INVENTÁRIO DE SAÚDE MENTAL

QUEST.:

Abaixo vai encontrar um conjunto de questões acerca do modo como se sente no dia a dia. responda a cada uma delas assinalando um dos retângulos com X a resposta que melhor se aplica a si.

1- QUANTO FELIZ E SATISFEITO VOCE TEM ESTADO COM A SUA VIDA PESSOAL?					
Extremamente feliz, não pode haver pessoa mais feliz ou satisfeita	Muito feliz e satisfeito a maior parte do tempo	Geralmente satisfeito e feliz	Por vezes ligeiramente satisfeito, por vezes ligeiramente infeliz	Geralmente insatisfeito, infeliz	Muito insatisfeito, e infeliz a maior parte do tempo
2- DURANTE QUANTO TEMPO SE SENTIU SÓ NO MÊS PASSADO?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
3- COM QUE FREQUENCIA SE SENTIU NERVOSO OU APREENSIVO PERANTE COISAS QUE ACONTECERAM, OU PERANTE SITUAÇÕES INESPERADAS, NO ÚLTIMO MÊS?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
4- DURANTE O MÊS PASSADO COM QUE FREQUENCIA SENTIU QUE TINHA UM FUTURO PROMISSOR E CHEIO DE ESPERANÇA?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
5- COM QUE FREQUÊNCIA, DURANTE O ÚLTIMO MÊS, SENTIU QUE A SUA VIDA NO DIA A DIA ESTAVA CHEIA DE COISAS INTERESSANTES?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
6- COM QUE FREQUENCIA, DURANTE O ÚLTIMO MÊS, SE SENTIU RELAXADO E SEM TENSÃO?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
7- DURANTE O ULTIMO MES, COM QUE FREQUENCIA SENTIU PRAZER NAS COISAS QUE FAZIA?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
8- DURANTE O ULTIMO MÊS, TEVE ALGUMA VEZ QUE SE QUESTIONOU SE ESTARIA A PERDER A CABEÇA, OU A PERDER O CONTROLE SOBRE OS SEUS ATOS, AS SUAS PALAVRAS, OS SEUS PENSAMENTOS, SENTIMENTOS OU MEMÓRIA?					

Não, nunca	Talvez um pouco	Sim, mas não o suficiente para ficar preocupado com isso	Sim, e fiquei um bocadinho preocupado	Sim, e isso me preocupa	Sim, e estou muito preocupado com isso
------------	-----------------	--	---------------------------------------	-------------------------	--

9- SENTIU-SE DEPRIMIDO DURANTE O ÚLTIMO MÊS?

Sim, até ao ponto de não me interessar por nada durante esses dias	Sim, muito deprimido quase todos os dias	Sim, deprimido muitas vezes	Sim, por vezes sinto-me um pouco deprimido	Não, nunca me sinto deprimido
--	--	-----------------------------	--	-------------------------------

10- DURANTE O ÚLTIMO MÊS, QUANTAS VEZES SE SENTIU AMADO E QUERIDO?

Sempre	Quase sempre	A maior parte das vezes	Algumas vezes	Muito poucas vezes	Nunca
--------	--------------	-------------------------	---------------	--------------------	-------

11- DURANTE QUANTO TEMPO, NO MÊS PASSADO SE SENTIU MUITO NERVOSO?

Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
--------	--------------	------------------------	---------------------	-------------	-------

12- DURANTE O ÚLTIMO MÊS, COM QUE FREQUÊNCIA ESPERAVA TER UM DIA INTERESSANTE AO LEVANTAR-SE?

Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
--------	----------------------	----------------	----------------------	-------------	-------

13- NO ÚLTIMO MÊS, DURANTE QUANTO TEMPO SE SENTIU TENSO E IRRITADO?

Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
--------	--------------	------------------------	---------------------	-------------	-------

14- DURANTE O ÚLTIMO MÊS SENTIU QUE CONTROLAVA PERFEITAMENTE O SEU COMPORTAMENTO, PENSAMENTO, EMOÇÕES E SENTIMENTOS?

Sempre	Sim, geralmente	Sim, penso que sim	Não muito bem	Não, e ando um pouco perturbado por isso	Não, e ando muito perturbado por isso
--------	-----------------	--------------------	---------------	--	---------------------------------------

15 DURANTE O ÚLTIMO MÊS, COM QUE FREQUÊNCIA SENTIU AS MÃOS A TREMER QUANDO FAZIA ALGUMA COISA?

Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
--------	----------------------	----------------	----------------------	-------------	-------

16- DURANTE O ÚLTIMO MÊS, COM QUE FREQUÊNCIA SENTIU QUE VOCÊ NÃO TINHA FUTURO, QUE NÃO TINHA PARA ONDE ORIENTAR A SUA VIDA?

Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
--------	----------------------	----------------	----------------------	-------------	-------

17- DURANTE QUANTO TEMPO, NO MÊS QUE PASSOU, SE SENTIU CALMO E EM PAZ?

Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
--------	--------------	------------------------	---------------------	-------------	-------

18- DURANTE QUANTO TEMPO, NO MÊS QUE PASSOU, SE SENTIU EMOCIONALMENTE ESTÁVEL?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
19- DURANTE QUANTO TEMPO, NO MÊS QUE PASSOU, SE SENTIU TRISTE, PRA BAIXO?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
20- COM QUE FREQUENCIA, NO MÊS PASSADO SE SENTIU COMO SE FOSSE CHORAR?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
21- DURANTE O ÚLTIMO MÊS, COM QUE FREQUENCIA VOCE SENTIU QUE AS OUTRAS PESSOAS SE SENTIRIAM MELHOR SE VOCÊ NÃO EXISTISSE?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
22- QUANTO TEMPO, DURANTE O ÚLTIMO MÊS, SE SENTIU CAPAZ DE RELAXAR SEM DIFICULDADE?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
23- NO ÚLTIMO MÊS, DURANTE QUANTO TEMPO SENTIU QUE AS SUAS RELAÇÕES AMOROSAS ERAM TOTAL OU COMPLETAMENTE SATISFATÓRIAS?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
24- COM QUE FREQUENCIA, DURANTE O ÚLTIMO MÊS, SENTIU QUE TUDO ACONTECIA AO CONTRÁRIO DO QUE DESEJAVA?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
25- DURANTE O ÚLTIMO MÊS, QUÃO INCOMODADO VOCÊ SE SENTIU DEVIDO ESTAR NERVOSO?					
Extremamente, ao ponto de não poder fazer as coisas que devia	Muito incomodado	Um pouco incomodado pelos meus nervos	Incomodado, o suficiente para que sentisse isso	Apenas de forma muito ligeira	Nada incomodado
26- NO MÊS QUE PASSOU, DURANTE QUANTO TEMPO SENTIU QUE A SUA VIDA ERA UMA AVENTURA MARAVILHOSA?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca

ANEXO B – QUESTIONÁRIO WHOQOL-BREF

QUEST.:

Instruções: Este questionário é sobre como você se sente a respeito de sua qualidade de vida, saúde e outras áreas de sua vida.

POR FAVOR RESPONDA A TODAS AS QUESTÕES. Se você não tem certeza sobre que resposta dar em uma questão, por favor, escolha entre as alternativas a que lhe parece mais apropriada. Esta, muitas vezes, poderá ser sua primeira escolha.

Por favor, tenha em mente seus valores, aspirações, prazeres e preocupações. Nós estamos perguntando o que você acha de sua vida, tomando como referência as **DUAS ÚLTIMAS SEMANAS**. Por exemplo, pensando nas últimas duas semanas, uma questão poderia ser:

Você recebe dos outros o apoio de que necessita?

Portanto, você deve circular o número 4 se você recebeu "muito" apoio como abaixo.

Nada	Muito pouco	Médio	Muito	Completamente
1	2	3	4	5

Você deve circular o número 1 se você não recebeu "nada" de apoio.

Por favor, leia cada questão, veja o que você acha e circule no número e lhe parece a melhor resposta.

		Muito ruim	Ruim	Nem ruim nem boa	Boa	Muito boa
1	Como você avaliaria sua qualidade de vida?	1	2	3	4	5

		Muito insatisfeito	Insatisfeito	Nem satisfeito nem insatisfeito	Satisfeito	Muito satisfeito
2	Quão satisfeito (a) você está com a sua saúde?	1	2	3	4	5

As questões seguintes são sobre **O QUANTO** você tem sentido algumas coisas nas últimas duas semanas.

		Nada	Muito pouco	Mais ou menos	Bastante	Extremamente
3	Em que medida você acha que sua dor (física) impede você de fazer o que você precisa?	1	2	3	4	5
4	O quanto você precisa de algum tratamento médico para levar sua vida diária?	1	2	3	4	5
5	O quanto você aproveita a vida?	1	2	3	4	5
6	Em que medida você acha que a sua vida tem sentido?	1	2	3	4	5
7	O quanto você consegue se concentrar?	1	2	3	4	5
8	Quão seguro(a) você se sente em sua vida diária?	1	2	3	4	5
9	Quão saudável é o seu ambiente físico (clima, barulho, poluição, atrativos)?	1	2	3	4	5

As questões seguintes perguntam sobre **QUÃO COMPLETAMENTE** você tem sentido que ou é capaz de fazer certas coisas nestas últimas duas semanas.

		Nada	Muito pouco	Médio	Muito	Completamente
10	Você tem energia suficiente para seu dia-a-dia?	1	2	3	4	5
11	Você é capaz de aceitar sua aparência física?	1	2	3	4	5
12	Você tem dinheiro suficiente para satisfazer suas necessidades?	1	2	3	4	5
13	Quão disponíveis para você estão as informações que precisa no seu dia-a-dia?	1	2	3	4	5
14	Em que medida você tem oportunidades de atividade de lazer?	1	2	3	4	5

As questões seguintes perguntam sobre **QUÃO BEM OU SATISFEITO** você se sentiu a respeito de vários aspectos de sua Vida nas últimas duas semanas.

		Muito ruim	Ruim	Nem ruim nem bom	Bom	Muito bom
15	Quão bem você é capaz de se locomover?	1	2	3	4	5

		Muito insatisfeito	Insatisfeito	Nem satisfeito nem insatisfeito	Satisfeito	Muito satisfeito
16	Quão satisfeito(a) você está com o seu sono?	1	2	3	4	5
17	Quão satisfeito(a) você está com sua capacidade de desempenhar as atividades do seu dia-a-dia?	1	2	3	4	5
18	Quão satisfeito(a) você está com sua capacidade para o trabalho?	1	2	3	4	5
19	Quão satisfeito(a) você está consigo mesmo?	1	2	3	4	5
20	Quão satisfeito(a) você está com suas relações pessoais (amigos, parentes, conhecidos, colegas)?	1	2	3	4	5
21	Quão satisfeito(a) você está com sua vida sexual?	1	2	3	4	5
22	Quão satisfeito(a) você está com o apoio que você recebe de seus amigos?	1	2	3	4	5
23	Quão satisfeito(a) você está com as condições do local onde mora?	1	2	3	4	5

24	Quão satisfeito(a) você está com o seu acesso aos serviços de saúde?	1	2	3	4	5
25	Quão satisfeito(a) você está com o seu meio de transporte?	1	2	3	4	5

A questão seguinte refere-se a **COM QUE FREQUÊNCIA** você sentiu ou experimentou certas coisas nas últimas duas semanas.

		Nunca	Algumas vezes	Frequentemente	Muito frequentemente	Sempre
26	Com que frequência você tem sentimentos negativos tais como mau humor, desespero, ansiedade, depressão?	1	2	3	4	5

Alguém lhe ajudou a preencher este questionário? _____

Quanto tempo você levou para preencher este questionário? _____

ANEXO C – FORMULÁRIO SOCIODEMOGRÁFICO, ACADÊMICO E CLÍNICO

- Nome: _____ Telefone: () _____
- 1-Sexo: 1() Feminino 2() Masculino 2- Idade: _____ Data de nascimento: _____
- 3-Raça: 1() Parda 2() Preta 3() Branca 4() Amarela 5() Não sabe
- 4-Situação civil: 1() Solteiro 2() Casado 3() União estável 4() Viúvo
- 5-Local de origem: 1() Sobral 2() Outra cidade: _____
- 6-Local de Residência: 1() Sobral 2() Outra cidade: _____
- 7-Caso sua cidade de origem não seja Sobral. Com que frequência viaja para sua cidade?
1() Todos os dias 2() Finais de semana 3() Quinzenalmente 4() Mensalmente 5() Semestralmente
- 8- Atualmente reside com:
1() Familiares 2() Sozinho 3() República estudantil 4() Amigos/colegas
- 9- Qual a sua religião?
1() Católica 2() Evangélica 3() Testemunha de Jeová 4() Espírita 5() Outros
- 10- Qual o curso de Graduação cursa na UVA: _____
- 11- Em que semestre você está matriculado?
1() 1º Semestre 2() 2º Semestre 3() 3º Semestre 4() 4º Semestre 5() 5º Semestre
6() 6º Semestre 7() 7º Semestre 8() 8º Semestre 9() 9º Semestre 10() 10º Semestre
- 12- Quantas disciplinas e/ou módulos está cursando no semestre em questão? _____
- 13- Já reprovou alguma disciplina/ módulo? 1() Sim 2() Não
- 14-Em termos gerais, você considera seu curso estressante? 1() Sim 2() Não
- 14.1 Indique o/os principais fatores de estresse:
1() Matérias 2() Didática do professor 3() Provas- apresentação de seminários
4() outras: _____
- 15- Já se afastou dos estudos por algum motivo? 1() Sim 2() Não
- 15.1-Qual motivo do afastamento:
1() Saúde/ Doença 2() Financeiro 3() Trabalho 4() outras: _____
- 16- Em que turno você está frequentando a maior parte das disciplinas?
1() Matutino 2() Vespertino 3() Somente Noturno 4() Integral
- 17- Qual o transporte que você utiliza para chegar a Universidade?
1() A pé/de carona/de bicicleta 2() Transporte coletivo 3() Transporte próprio 4() Táxi/Moto-táxi
- 18- Atividades profissionais: 1() Não trabalha 2() Trabalha
19. Atividades acadêmicas: 1() Não Realizam estágio 2() Realizam estágio
- 20- Quanto a Bolsas ou Auxílio Universitário:
1() Não recebe algum tipo de auxílio universitário 2() Recebe algum tipo de auxílio universitário
- 20.1 Caso receba, especifique qual ou quais: _____

- 21-Desenvolve algum tipo de atividade física de forma regular? 1() Sim 2() Não
21. 1- Se sim, qual a frequência (por semana)? _____
- 22- Quantas horas por semana dispõem para atividades de lazer? _____
- 23- Quais são as suas principais atividades de Lazer:
- 1() Dormir 2() Ficar com a família 3() Ouvir música 4() Assistir filmes 5() Passear/ Viajar
6() Ler um livro 7() Realizar atividade física 8() Outras: _____
- 24- Faz uso contínuo de algum medicamento para tratamento da saúde?
- 1() Sim 2() Não
24. 1- Qual medicamento? _____
- 25-Faz uso de alguma substância psicoativa durante os últimos três meses? 1() Sim 2() Não
25. 1 Qual ou quais as substâncias psicoativas:
- 1() Bebidas Alcoólicas(cerveja, vinho, licor) 2() Derivados do Tabaco (cigarro, charuto)
3() Maconha (baseado, erva) 4() Drogas estimulantes (crack, cocaína, rebites)
5() Drogas Inalantes (lança-perfume, cola) 6() Hipnóticos/ Sedativos (ansiolíticos, tranquilizantes,
diazepan) 7() Alucinógenos (LSD, Ecstasy) 8() Opióides (Morfina, Heroína, codeína, ópio)
9() Outros: _____
25. 2 Durante os três últimos meses, com que frequência você utilizou essa(s) substância(s)
- 1() Uma ou duas vezes 2() Mensalmente 3() Semanalmente 4() Diariamente ou quase todos os dias
- 26- Em geral, qual a quantidade aproximada de horas de sono diárias? _____

27- DURANTE QUANTO TEMPO, NO MÊS QUE PASSOU, SE SENTIU TRISTE E PARA BAIXO, DE TAL MODO QUE NADA O CONSEGUIA ANIMAR?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
28- DURANTE O ÚLTIMO MÊS, ALGUMA VEZ PENSOU EM ACABAR COM A PRÓPRIA VIDA?					
Sim, muitas vezes	Sim, algumas vezes	Sim, umas poucas de vezes	Sim, uma vez	Não, nunca	
29- NO ÚLTIMO MÊS, DURANTE QUANTO TEMPO SE SENTIU, CANSADO, INQUIETO E IMPACIENTE?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
30- NO ÚLTIMO MÊS, DURANTE QUANTO TEMPO SE SENTIU RABUGENTO OU DE MAU HUMOR?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
31- DURANTE QUANTO TEMPO, NO ÚLTIMO MÊS, SE SENTIU ALEGRE, ANIMADO E BEM DISPOSTO?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
32 -DURANTE O ÚLTIMO MÊS, COM QUE FREQUENCIA SE SENTIU CONFUSO OU PERTURBADO?					
Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
33- DURANTE O ÚLTIMO MÊS SENTIU-SE ANSIOSO OU PREOCUPADO?					
Sim, extremamente, ao ponto de ficar doente ou quase	Sim, muito	Sim, um pouco	Sim, o suficiente para me incomodar	Sim, de forma muito ligeira	Não. De maneira nenhuma
34- NO ÚLTIMO MÊS DURANTE QUANTO TEMPO SE SENTIU UMA PESSOA FELIZ?					
Sempre	Quase sempre	A maior parte do tempo	Durante algum tempo	Quase nunca	Nunca
35- COM QUE FREQUENCIA DURANTE O ÚLTIMO MÊS, SE SENTIU COM DIFICULDADE EM SE MANTER CALMO?					

Sempre	Com muita frequência	Frequentemente	Com pouca frequência	Quase nunca	Nunca
36- NO ULTIMO MÊS, DURANTE QUANTO TEMPO SE SENTIU ESPIRITUALMENTE PARA BAIXO?					
Sempre	Quase sempre	Uma boa parte do tempo	Durante algum tempo	Quase nunca	Nunca
37- COM QUE FREQUENCIA DURANTE O ULTIMO MÊS, ACORDOU DE MANHÃ SENTINDO-SE FRESCO E REPOUSADO?					
Sempre, todos os dias	Quase todos os dias	Frequentemente	Algumas vezes, mas, normalmente não	Quase nunca	Nunca
38- DURANTE O ULTIMO MÊS, ESTEVE, OU SENTIU-SE DEBAIXO DE GRANDE PRESSÃO OU STRESS?					
Sim, quase a ultrapassar os meus limites	Sim, muita pressão	Sim, alguma, mais do que o costume	Sim, alguma, como de costume	Sim, um pouco	Não, nenhuma.