

**UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
CURSO DE CIÊNCIA DA COMPUTAÇÃO**

KAIUS DIEGO RODRIGUES DA SILVA

**ANÁLISE DO SONO PARA IDENTIFICAR INDÍCIOS DE DEPRESSÃO
UTILIZANDO ÁRVORE DE DECISÃO**

**SÃO LUÍS-MA
2018**

Kaius Diego Rodrigues da Silva

ANÁLISE DO SONO PARA IDENTIFICAR INDÍCIOS DE DEPRESSÃO UTILIZANDO
ÁRVORE DE DECISÃO

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Tiago Bonini Borchartt

São Luís-MA

2018

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Silva, Kaius Diego Rodrigues da.

Análise do sono para identificar indícios de depressão utilizando árvore de decisão / Kaius Diego Rodrigues da Silva. - 2018.

41 f.

Orientador(a): Tiago Bonini Borchardt.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, São Luís, 2018.

1. Árvore de decisão. 2. Classificação. 3. Hipnograma. I. Borchardt, Tiago Bonini. II. Título.

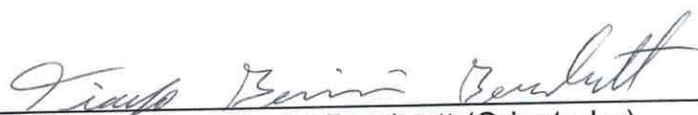
KAIUS DIEGO RODRIGUES DA SILVA

**ANÁLISE DO SONO PARA IDENTIFICAR INDÍCIOS DE DEPRESSÃO
UTILIZANDO ÁRVORE DE DECISÃO**

Trabalho de Conclusão de Curso
apresentado à Universidade Federal do
Maranhão, como requisito parcial para
obtenção do grau de Bacharel em Ciência da
Computação.

Aprovado em: 12/07/2018

BANCA EXAMINADORA



Prof. Dr. Tiago Bonini Borchardt (Orientador)
Universidade Federal do Maranhão



Prof. Dr. Samyr Beliche Vale
Universidade Federal do Maranhão



Prof. Me. Carlos Eduardo Portela Serra de Castro
Universidade Federal do Maranhão

AGRADECIMENTOS

À Deus, pela graça da vida e por prover força e fé para que eu pudesse chegar até aqui. Ao meu professor orientador Tiago Bonini Borchardt, pela paciência, disponibilidade e orientação participativa, clara e flexível. À minha família, que caminha e está comigo em todos os momentos, especialmente à minha mãe pelo incentivo. Aos membros da banca examinadora, pela atenção e participação. À todas as pessoas que direta ou indiretamente contribuíram para que eu estivesse motivado para o desenvolvimento deste trabalho.

"Não me entrego sem lutar, tenho ainda coração,
não aprendi a me render, que caia o inimigo
então"

Metal Contra as Nuvens
Legião Urbana

RESUMO

Os transtornos ou mesmo características do sono que indiquem depressão infelizmente são comuns e nem sempre são de fácil e rápida identificação, sobretudo, quando vários pacientes precisam ter seu sono analisado. Dito isto, este trabalho tem por objetivo apresentar um modelo de classificação utilizando algoritmo de árvore de decisão para auxiliar a detecção de indícios da depressão no sono a partir do uso de hipnogramas. Diversos métodos foram empregados durante a pesquisa como a utilização da pilha de bibliotecas conhecida como *scikit learn*, o pré-processamento e limpeza da base de dados, extração de características, análise exploratória, classificação e por fim, métricas de teste de desempenho do classificador, tais como acurácia, precisão, sensibilidade e especificidade. Os três testes foram desenvolvidos de forma organizada dividindo o conjunto de dados de treino em 40%, 60% e 80%, respectivamente. Durante os resultados foi possível observar que a capacidade do modelo de prever corretamente quem realmente tinha indícios de depressão foi consideravelmente satisfatória, a predição de indivíduos considerados normais, infelizmente, já não apresentou resultado tão satisfatório. Desta forma, tanto a especificidade quanto as demais métricas tiveram seu desempenho melhorado conforme aumentava a quantidade de dados usados para treino do modelo, ao passo que a sensibilidade se mostrou estável e o modelo, de modo geral, teve bom desempenho.

Palavras-chave: árvore de decisão, hipnogramas, classificação

ABSTRACT

Disorders or even sleep characteristics that indicate depression are unfortunately common and are not always easily and quickly identified, especially when several patients need to have their sleep analyzed. That said, this work aims to present a classification model using decision tree algorithm to help detect evidence of sleep depression from the use of hypnograms. Several methods were employed during the research such as the use of the library stack known as *scikit learn*, database preprocessing and cleaning, feature extraction, exploratory analysis, classification and finally, test metrics performance of the classifier, such as accuracy, precision, sensitivity and specificity. The three tests were developed in an organized way by dividing the training dataset by 40%, 60% and 80%, respectively. During the results it was possible to observe that the ability of the model to correctly predict who actually had evidence of depression was considerably satisfactory, the prediction of individuals considered normal, unfortunately, no longer presented such a satisfactory result. In this way, both the specificity and the other metrics had their performance improved as the amount of data used to train the model increased, while the sensitivity was shown to be stable and the model, in general, performed well.

Keywords: decision tree, hypnograms, classification

LISTA DE FIGURAS

Figura 1 – Registro de EEG nas fases do sono	18
Figura 2 – O olho modelado como um dipolo	19
Figura 3 – Exemplo de disposição dos eletrodos no EOG	19
Figura 4 – Hipnograma do sono de um indivíduo normal de 16 anos	20
Figura 5 – Exemplo de árvore de decisão	23
Figura 6 – Exemplo de hipnograma no formato EDF	29
Figura 7 – Exemplo de atributos extraídos da base de dados	30
Figura 8 – Distribuição de indivíduos por quantidade de tempo de latência REM	33
Figura 9 – Distribuição de indivíduos por quantidade de tempo de latência ao sono	34
Figura 10 – Distribuição de indivíduos por quantidade de pacientes com indícios de depressão no sono	34
Figura 11 – Árvore gerada	37

LISTA DE TABELAS

Tabela 1 – Variáveis da Polissonografia	17
Tabela 2 – Matriz de confusão	26
Tabela 3 – Matriz de confusão gerada com 40% do conjunto de dados de treino	35
Tabela 4 – Resultados ao utilizar 40% dos dados para treino	35
Tabela 5 – Matriz de confusão gerada com 60% do conjunto de dados de treino	36
Tabela 6 – Resultados ao utilizar 60% dos dados para treino	36
Tabela 7 – Matriz de confusão gerada com 60% do conjunto de dados de treino	37
Tabela 8 – Resultados ao utilizar 80% dos dados para treino	37

LISTA DE ABREVIATURAS E SIGLAS

CART	Classification and Regression Tree
CIDS	Classificação Internacional dos Distúrbios do Sono
EEG	Eletroencefalograma
EMG	Eletromiograma
EOG	Eletro-oculograma
NREM	Not Rapid Eye Moviment
REM	Rapid Eye Moviment
OMS	Organização Mundial de Saúde
PSG	Polissonografia

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivo	14
1.1.1	Objetivo Geral	14
1.1.2	Objetivos Específicos	15
1.2	Justificativa	15
1.3	Organização do Trabalho	16
2	CONCEITOS BÁSICOS	17
2.1	Sensores	17
2.1.1	Eletroencefalograma	18
2.1.2	Eletro-oculograma	19
2.1.3	Eletromiograma	20
2.2	Extração de Características	20
2.3	Técnica de Classificação	23
2.3.1	Árvore de decisão	23
2.3.2	Índice Gini	25
2.3.3	CART	25
2.4	Avaliação de Resultados	26
2.4.1	Matriz de confusão	26
2.4.2	Acurácia	27
2.4.3	Precisão	27
2.4.4	Sensibilidade	27
2.4.5	Especificidade	27
3	METODOLOGIA	28
3.1	Base de dados	28
3.2	Pré-processamento dos dados	28
3.3	Extração de características	31
3.4	Classificação	31
4	RESULTADOS	33
4.1	Análise exploratória	33
4.2	Avaliação e comparação dos resultados	35
5	CONCLUSÃO	39
	REFERÊNCIAS	40

1 INTRODUÇÃO

Depressão, ansiedade e insônia. Respectivamente, doenças também encontradas através do estudo do sono e um denominador comum entre os transtornos psiquiátricos. Estes são apenas alguns fatores que têm grande relação com o sono de uma pessoa. No total, são 84 doenças catalogadas na Classificação Internacional dos Distúrbios do Sono (MARTINEZ, 1999). Dessa forma, faz-se necessário um estudo analítico acerca do sono.

Os índices apresentados pela depressão têm sido muito grandes, inclusive, chega a ser chamada de “mal do século” e deve atingir pelo menos uma vez na vida entre 15% e 20% da população mundial (TEODORO, 2010). Em decorrência disso, é imprescindível ter mais uma forma de encontrar indícios de que a doença está presente na vida de uma pessoa, a fim de que esta possa o quanto antes criar hábitos mais saudáveis que beneficiem o sono, afastando-se de maiores complicações.

A ansiedade, que por sua vez também pode ser um sintoma dentro do quadro da depressão, possui ao mesmo tempo índices alarmantes. Segundo a Organização Mundial de Saúde (OMS), 264 milhões de pessoas sofrem com este tipo de transtorno psiquiátrico em todo o mundo, o Brasil, por exemplo, com 9,3% da população com alguma forma de transtorno de ansiedade, é o país com os maiores percentuais (PALHARES, 2017).

Definida como a dificuldade de iniciar ou ainda manter o sono, de continuação do sono e despertar precoce nas primeiras horas da manhã (CHELLAPPA; ARAÚJO, 2007), a insônia é um transtorno comum à ansiedade e depressão. Em relação a esta, por exemplo, a insônia pode representar um mecanismo de defesa, visto que a privação do sono *REM* (*Rapid Eye Movement*) tem efeito antidepressivo (MARTINEZ, 1999).

Felizmente, o conjunto de informações obtidas através da análise do sono pode indicar se uma pessoa tem alguma destas doenças ou possui um sono de qualidade. Este conjunto, é conhecido como hipnograma, gráfico de linha xy onde o eixo y representa as fases do sono e o eixo x o tempo do sono. Também conhecido como a melhor maneira de visualizar a arquitetura do sono (MARTINEZ, 1999), através dele é possível inferir se um indivíduo possui sono normal, representando assim sono de qualidade ou se apresenta indício de algum distúrbio do sono.

1.1 OBJETIVO

1.1.1 Objetivo Geral

Desenvolver um método para análise de indícios de depressão no sono utilizando árvore

de decisão e hipnogramas.

1.1.2 Objetivos Específicos

- Identificar características que possuam maior relação com o índice de depressão no sono.
- Realizar uma análise exploratória no conjunto de dados.
- Comparar resultados de classificações para várias distribuições do conjunto de dados de treino e teste.

1.2 JUSTIFICATIVA

No mundo, segundo dados confirmados pela Organização Mundial de Saúde (OMS): 40% da população não descansa o necessário e apresenta algum dos vários transtornos do sono presentes na Classificação Internacional dos Distúrbios do Sono (CIDS) (RUDGE RAMOS JORNAL, 2008). São muitos os problemas ocasionados pela privação do sono, exemplos, podem incluir pequenos acidentes domésticos, graves acidentes de trânsito ou ainda diminuição da eficiência e concentração no trabalho.

As razões para a privação do sono também são várias, dentre as quais pode-se citar: uso de medicamentos, doenças clínicas como asma ou ainda problemas psiquiátricos, tal qual a depressão. É de suma importância, portanto, identificar os motivos por trás de noites mal dormidas, visto que podem acarretar ainda o surgimento de diversos problemas endócrinos como alteração de humor, déficit de atenção, memória e raciocínio além de baixo rendimento imunológico (Segundo OMS, distúrbio do sono afeta 40% dos brasileiros, 2016).

O impacto ocasionado pelo estudo do sono, sobretudo, na análise da qualidade do sono pode impulsionar a detecção de problemas e acelerar os tratamentos de forma a evitar vários dos transtornos presentes na CIDS. A partir do conjunto de informações obtidas nesta análise, o médico especialista do sono é capaz de receitar o tratamento mais adequado para o paciente. A importância do tema também está no incentivo aos possíveis e mais diversos aprofundamentos no campo da medicina do sono, big data e aprendizado de máquina.

Através do uso combinado destas áreas da computação e medicina, é possível o estudo, análise e até mesmo predição de indícios de algum distúrbio do sono, inclusive, para um grande número de pessoas. Por outro lado, a ausência de pesquisas nestes campos de forma conjunta, torna muito mais difícil o diagnóstico para um grande conjunto de dados. Desta forma, a

utilização do aprendizado de máquina dentro da medicina do sono é de extrema relevância e traz grandes benefícios para a qualidade de vida do homem.

1.3 ORGANIZAÇÃO DO TRABALHO

O presente trabalho está estruturado em capítulos tal qual esta introdução e será desenvolvido da seguinte forma:

No Capítulo 2 são apresentados os conceitos, teorias e modelos centrais da pesquisa, tratando de sensores utilizados para obtenção da base de dados, características extraídas, técnica de classificação, etc.

O Capítulo 3 discorre acerca dos procedimentos necessários para a execução da pesquisa, bem como da utilização de uma base de dados, o pré-processamento dos dados, extração das características, análise exploratória e classificação.

Por outro lado, o Capítulo 4 expõe a avaliação dos resultados e os compara com outros trabalhos.

E o Capítulo 5 exibirá conclusões acerca dos objetivos e/ou hipóteses de forma a indicar quais destas hipóteses não foram alcançadas.

2 CONCEITOS BÁSICOS

Neste capítulo são introduzidos os conceitos básicos, tecnologias e métricas adotadas neste trabalho. Inicialmente, uma explicação sobre alguns dos sensores utilizados para se analisar o sono. Em seguida, são introduzidos os conceitos e regras das características extraídas. Finalmente, são apresentados princípios sobre técnica de classificação e métricas para avaliação dos resultados.

2.1 SENSORES

A fim de registrar dados acerca do sono, é utilizada a Polissonografia (PSG), vista como o exame símbolo da medicina do sono (MARTINEZ, 1999), ela é utilizada para investigação de vários distúrbios do sono. Um leque de sensores é usado nesta técnica para obtenção de informações que possibilitem a análise do sono, cada equipamento age de acordo com o fenômeno e variável a ser medida, conforme a Tabela 1 (MARTINEZ, 1999):

Tabela 1 – Variáveis da Polissonografia

Fenômeno avaliado	Variável medida	Equipamento empregado
Sono	Eletroencefalograma Eletro-oculograma Eletromiograma	Amplificador AC
Circulação	Eletrocardiograma Pressão arterial	Amplificador AC Cateter intra-arterial, Finapress
Respiração	Fluxo aéreo Volume corrente Movimentos torácicos e abdominais Pressão esofágica Saturação de oxigênio Capnografia Sons respiratórios	Termistor, transdutor de pressão Pletismografia de indução (RIP), magnetômetro RIP, magnetômetro, sensor de distensão, Sonda ligada a transdutor de pressão Oxímetro Analisador de CO2 Microfone
Movimentos	De braços e pernas	Eletromiograma, acelerômetros

No presente trabalho, apenas serão considerados as variáveis de medida relacionadas ao fenômeno "sono": Eletroencefalograma, Eletro-oculograma e Eletromiograma, conforme a

tabela acima.


2.1.1 Eletroencefalograma

Exame não invasivo e de grande aceitação, o EEG é um dos exames fundamentais na medicina. Em razão da grande variedade de doenças que podem ser detectadas através do seu uso.

No sono, este exame pode indicar a presença de distúrbios (SAUDÁVEL, 2017) e poderá ter duração de 8 a 24 horas, dependendo apenas do tipo de Polissonografia escolhida pela equipe médica. Durante o processo, para que o correto registro da atividade elétrica cerebral o paciente necessita ficar com eletrodos fixados no couro cabeludo, onde estes são colocados em posições estratégicas, obedecendo o sistema convencional denominado "Sistema Internacional 10-20 de Colocação de Eletrodos"(TUFIK, 2008).

É também através do EEG que é possível diferenciar e classificar os estágios do sono que se repetem durante a noite (TUFIK, 2008), isto ocorre em razão das diversas amplitudes e frequências das ondas registradas, como na Figura 1 abaixo:

Figura 1 – Registro de EEG nas fases do sono




Fonte: Sabbatini (1997)

2.1.2 Eletro-oculograma

Muito utilizado para a detecção de dois ritmos: movimentos rápidos e lentos dos olhos, respectivamente, REM e SEM (ESTRADA et al., 2006). O EOG consiste em medir a amplitude média de potencial entre a região anterior e posterior do globo ocular; são utilizados dois canais para o registro de alterações horizontais e verticais; os eletrodos calculam a voltagem dentro dos olhos, onde a córnea possui carga positiva e a retina possui carga negativa (TUFIK, 2008) como demonstrado na Figura 2.

Figura 2 – O olho modelado como um dipolo

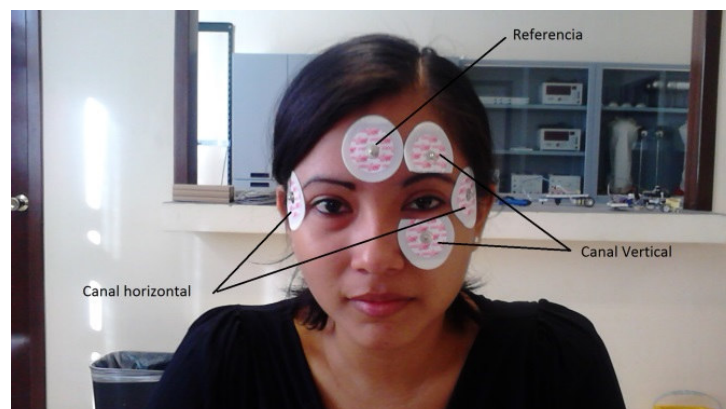


Fonte: Bautista et al. (2014)

Ao efetuar movimentos oculares horizontais, a diferença de potencial varia proporcionalmente à diferença de potencial de repouso e à amplitude dos movimentos (RHEIN, 2010).

Assim como o EEG, o EOG também tem posições corretas para disposição de eletrodos, como é possível ver na Figura 3:

Figura 3 – Exemplo de disposição dos eletrodos no EOG



Fonte: Bautista et al. (2014)

2.1.3 Eletromiograma


A importância do eletromiograma se dá, também, pelo estagiamento do sono REM (embora o principal fornecedor de dados para estagiamento seja o EEG), detectado através da atonia muscular (TUFIK, 2008). Exame responsável pela detecção de movimentos ou contrações musculares que geram potencial elétrico bifásico, dentre as atividades ou informações captadas pelo EMG estão (OENNING, 2005):

- Registro da atividade eletromiográfica em repouso.
- Determinação da atividade muscular durante deglutição e máxima intercuspidação habitual (MIH).
- Investigação de posições adaptativas dos côndilos mandibulares.
- Avaliação de torque muscular.
- Análise de tônus muscular na posição de eventuais contatos prematuros

2.2 EXTRAÇÃO DE CARACTERÍSTICAS

De posse dos dados fornecidos pela PSG, ao fim da ocorrência dos fenômenos e registro das variáveis fisiológicas como eletroencefalograma (EEG), eletromiograma (EMG) e eletroculograma (EOG), é possível obter os parâmetros que formarão as características do sono representado também pelo hipnograma, que facilita a visualização da arquitetura de uma noite de sono, como se pode observar na Figura 4 (TUFIK, 2008).

Figura 4 – Hipnograma do sono de um indivíduo normal de 16 anos



Fonte: Nicolau (2007)

Parâmetros (características) que determinam as regras de produção segundo Tufik (2008) e Martinez (1999):

- Eficiência do sono
 - É determinada pelo resultado da razão entre o tempo total dormindo e o tempo total no leito. Normalmente acontece de o paciente dormir entre 80 e 90% do tempo no leito. Em idosos, no entanto, pode-se admitir que esta eficiência caia até 75%.
- Latência ao estágio 1
 - Medida de tempo que se inicia no apagar das luzes e vai até a primeira aparição do estágio 1; como este é fugaz e por ainda ser possível conservar parte da consciência, é então considerado um falso início do sono. Em geral, o valor esperado varia entre 5 e 29 minutos.
- Latência ao sono (estágio 2)
 - Semelhantemente ao estado anterior, este também é uma medida de tempo que é iniciada no momento em que as luzes se apagam e vai até a primeira ocorrência do estágio 2, definido como o verdadeiro início do sono. Para que sejam considerados normais, os valores desta característica devem estar entre 10 e 30 minutos.
- Latência ao estágio de ondas lentas (estágios 3 e 4)
 - Consiste no intervalo de tempo entre o início do sono, em estágio 2, até a primeira ocorrência do sono profundo (estágios 3 e 4). Analogamente ao item anterior, esta característica deve ter valores variando entre 10 e 30 minutos.
- Latência ao estágio REM
 - Tempo que o paciente demora a chegar no sono REM após a primeira ocorrência do estágio 2. Esta é uma medida valiosa da PSG e no estudo do sono com um todo, através dela é possível identificar sinais ou indícios de vários distúrbios do sono, como por exemplo, a depressão. Por conta do exame normalmente ser realizado em laboratório, pode acontecer de esta latência ser inexistente ou ocorrer com atraso, desta forma, são aceitos valores de até 3 horas, no entanto, valor menor que 60 minutos é forte indício de depressão, e menor que 20, sugere existência de narcolepsia.
- Tempo total dormindo

- Medida de tempo obtida através da soma de todos os estágios do sono NREM e REM. 6 horas é o tempo mínimo tido como normal e até onde pode-se evitar novos problemas de saúde.
- Tempo de sono
 - Quantidade de tempo passado desde a primeira ocorrência do estágio 2, até o último despertar, portanto, abrange praticamente todos os estágios do sono. Nesta contagem a vigília após o despertar não é levada em consideração, de maneira que o valor esperado para esta característica é próximo do tempo total no leito.
- Número de despertares longos
 - Acontece quando o tempo de uma ocorrência do estágio vigília tem período igual ou maior que cinco minutos. Usualmente, são aceitos de dois a três despertares, desde que a porcentagem em estágio vigília seja inferior a 10% do tempo de sono.
- Estágio vigília
 - É a vigília que acontece após o início do estágio 2 ou ainda durante o tempo de sono. Os valores para esta fase podem variar conforme a idade do paciente, sendo de 5 a 50 minutos em jovens e de 10 a 90 minutos em idosos; usualmente ocupa 7% da noite e tem limite máximo de 10% para jovens e até 20% para idosos.
- Duração do estágio 1
 - O sono superficial costuma durar de 5 a 30 minutos, com porcentagem variando de 2 a 9%.
- Duração do estágio 2
 - Considerado o início do sono, esta fase tem porcentagem variando de 40 a 60% do tempo de sono ou duração de 3 a 4 horas.
- Duração do estágio de ondas lentas
 - Estágios 3 e 4 são agrupados, formando assim o sono de ondas lentas e juntos duram entre 40 e 120 minutos ou porcentagem de 10 a 30% em jovens, no entanto em idosos essa porcentagem baixa para 5 a 15%.
- Duração do estágio REM

- Costuma ocupar de 10 a 30% do tempo de sono em jovens, enquanto que em idosos dura entre 5 e 25%.

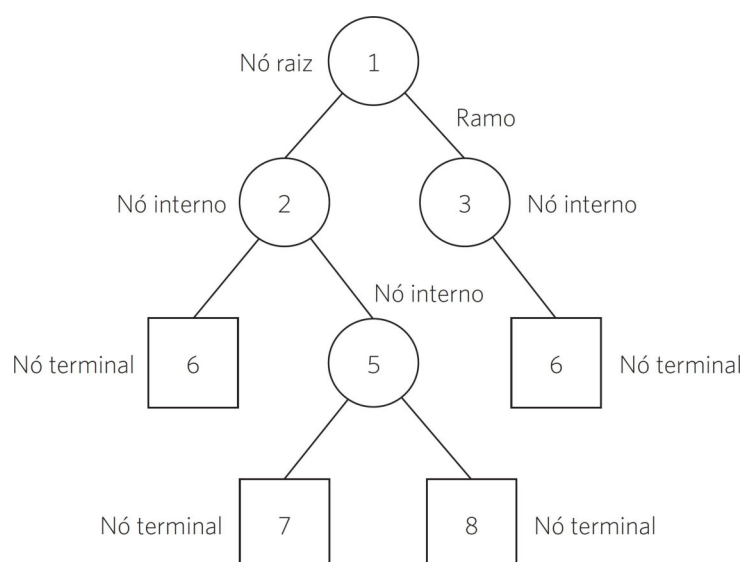
2.3 TÉCNICA DE CLASSIFICAÇÃO

A fim de entender a pesquisa como um todo, é imprescindível que tenha conhecimentos a cerca de uma árvore de decisão. A qual representa um modelo de classificador, neste caso, para treinamento supervisionado. Durante esta seção, serão introduzidos conceitos do funcionamento de uma árvore de decisão.

2.3.1 Árvore de decisão

Um dos pontos fortes desta técnica é a flexibilidade que a faz particularmente bastante atrativa, sobretudo porque está presente a vantagem de uma visualização muito sugestiva, onde a árvore basicamente sintetiza a classificação (GORUNESCU, 2011). A abordagem desta técnica é dividir para conquistar, a árvore é dividida em árvores mais simples e este procedimento ocorre recursivamente em cada subárvore (SILVA, 2005). Ela define uma hierarquia de nós pai e/ou filhos ou ainda nós internos e externos ligados através de ramos (SOBRAL, 2003), como é possível ver na Figura 5 abaixo.

Figura 5 – Exemplo de árvore de decisão



Fonte: Medeiros et al. (2014)

Para Salzberg e Kingsford (2008), árvores de decisão como o CART, ID3 e C4.5 são modelos estatísticos que fazem uso do treinamento supervisionado e que predizem uma

classe para cada item dos dados informados. Elas são úteis, uma vez que proveem um modo compreensivo de prever situações onde existem muitas variáveis interagindo de maneira não linear; ao utilizar o conjunto de dados os nós intermediários aplicam testes lógicos e estes direcionarão o novo caminho que a árvore deverá percorrer, desta maneira, cada caminho será resultado de um conjunto de testes lógicos e o mesmo procedimento ocorre recursivamente até que seja alcançado um nó folha, também conhecido como nó terminal (SOBRAL, 2003).

Segundo Pedregosa et al. (2011) podemos pesar o uso desta técnica com base no problema escolhido analisando as vantagens e desvantagens da mesma, como segue:

- Vantagens

- Simples para entender e para interpretar, pode ser visualizada.
- Requer pouca preparação de dados. Outras técnicas frequentemente requerem normalização de dados, variáveis falsas precisam ser criadas e valores em branco devem ser removidos.
- O custo do uso de uma árvore para prever dados é logarítmico, em número de pontos de dados usados para treiná-la.
- Capaz de manusear dados numéricos e categóricos; outras técnicas normalmente são especializadas em analisar conjunto de dados com um único tipo de variável.
- Capaz de trabalhar com problemas de múltiplas saídas.
- É possível validar um modelo utilizando testes estatísticos. Isto deixa mais visível a confiabilidade do modelo.

- Desvantagens

- Árvores de decisão criam árvores complexas que não generalizam bem os dados. Isto é chamado de "overfitting". Alternativamente, um mecanismo como a poda, setando o número mínimo de exemplos requeridos nas folhas ou a definição do tamanho máximo de profundidade da árvore é algo necessário para evitar este problema.
- Podem ser instáveis, uma vez que pequenas variações nos dados podem resultar numa árvore completamente diferente.
- O resultado pode gerar árvores tendenciosas caso algumas classes dominem, desta maneira, é recomendado equilibrar o conjunto de dados antes de utilizar a árvore de decisão.

2.3.2 Índice Gini

Diversas medidas foram criadas para validar o grau de heterogeneidade dos dados, ou impureza, para árvores de decisão as mais comuns são Entropia e Índice Gini (SALZBERGL; KINGSFORD, 2008). A utilização do Gini, dá uma noção do quão boa é uma divisão de acordo com a forma como as classes são misturadas nos dois grupos criados, caso o índice seja igual a zero, o nó analisado é considerado puro, no entanto, se o valor se é mais próximo de 1, o nó é considerado impuro, o índice é utilizado para definir o ponto de corte da árvore (BARBOSA et al., 2011).

A formulação do índice num nó é dada por:

$$G = -1 \sum_{i=1}^c p_i^2$$

Onde:

p_i é a frequência relativa de cada classe em cada nó

c é o número de classes

2.3.3 CART

A representação do modelo CART é binária, cada nó raiz representa uma variável de entrada única e um ponto de divisão, partindo do princípio que a variável seja numérica. Neste algoritmo a árvore cresce buscando sempre gerar nós filhos mais puros, utilizando apenas uma variável de previsão para cada divisão, a seleção de qual variável de entrada usar e a divisão específica ou ponto de corte é escolhida usando um algoritmo guloso. A construção da árvore termina com um critério de parada predefinido, como um número mínimo de instâncias de treinamento atribuídas a cada nó folha da árvore (BROWNLEE, 2016).

Dentre as características mais relevantes do algoritmo, segundo Sobral (2003), pode-se citar:

- Definir o conjunto de regras para dividir cada nó da árvore.
- Determinar quando a árvore está completa
- Associar cada nó terminal a uma classe.

Os passos de execução do algoritmo CART são dados como segue (BARBOSA et al., 2011) :

- Encontrar a melhor divisão para cada preditor. Esta divisão é dada pela redução de impuridade em dividir os nós em filhos direito e esquerdo, onde para cada atributo, a

melhor divisão é a que tem menor impuridade dentre todas as divisões possíveis para este atributo. Para cada preditor ordene os valores do menor para o maior valor. Após a ordenação, percorra cada valor a partir do topo para examinar cada candidato a ponto de divisão para localizar o melhor atributo. O ponto mais indicado é aquele que maximiza o critério de divisão quando o nó é dividido de acordo com o ponto de divisão.

- Divida o nó usando a melhor divisão encontrada na etapa 2, se as regras de parada não forem satisfeitas.
- O critério de parada define que a árvore cresce camada por camada até saturar, criando assim um particionamento recursivo, é possível parar a divisão através da atribuição do número de exemplos, porém, deixar que a árvore sature ao ponto em que os nós restantes sejam os mais puros possíveis.

2.4 AVALIAÇÃO DE RESULTADOS

A fim de fazer uma análise mais detalhada, serão utilizadas várias métricas para avaliar o desempenho do classificador.

2.4.1 Matriz de confusão

A matriz de confusão é uma das mais intuitivas e fáceis métricas para se descobrir a exatidão e precisão do modelo, exibindo a quantidade de registros que foram classificados corretamente ou incorretamente em cada classe prevista; é usada para problemas de classificação onde a saída pode ser de dois ou mais tipos de classes (BECCENERI et al., 2004).

Uma das formas mais comuns de representar as estatísticas para a avaliação de um modelo de classificação é por meio de uma tabulação cruzada entre a classe prevista pelo modelo e a classe real dos exemplos. Essa tabulação é conhecida como tabela de contingência ou ainda matriz de confusão (KOHAVI, 1998). Também pode ser vista como uma forma simples de se estabelecer e visualizar o cálculo de medidas (SILVA, 2008).

Tabela 2 – Matriz de confusão

	Previsão Positiva	Previsão Negativa
Caso Positivo	Verdadeiro Positivo - VP	Falso Negativo - FN
Caso Negativo	Falso Positivo - FP	Verdadeiro Negativo - VN

2.4.2 Acurácia

Também conhecida como taxa de acerto, a acurácia é uma das medidas mais utilizadas em problemas de classificação, medindo a frequência com que o classificador faz uma previsão correta, é a razão entre o número de previsões corretas e a quantidade total de previsões (JOHNY, 2014).

$$Acuracia = \frac{VP + VN}{VP + VN + FP + FN}$$

2.4.3 Precisão

Aplicando o conceito ao tema deste trabalho, precisão é a medida que nos diz qual a proporção de pacientes que após o cálculo foram rotulados como tendo indício de depressão e os que realmente tinham indícios (SUNASRA, 2017). Segundo (PEDREGOSA et al., 2011) a precisão é intuitivamente a capacidade do classificador de não rotular como positiva uma amostra que é negativa.

$$Precisao = \frac{VP}{VP + FP}$$

2.4.4 Sensibilidade

Mede o quão correto é o classificador ao reconhecer indivíduos da classe positiva (DAS, 2017). Também pode ser interpretado como a fração dos casos positivos corretamente previstos pelo modelo, em relação ao número total de casos no conjunto de dados (JOHNY, 2014).

$$Sensibilidade = \frac{VP}{VP + FN}$$

2.4.5 Especificidade

Mede a taxa ou proporção com que um caso verdadeiramente negativo é classificado como negativo (DAS, 2017).

$$Especificidade = \frac{VN}{VN + FP}$$

3 METODOLOGIA

Neste capítulo são apresentadas de forma detalhada as tecnologias utilizadas para o desenvolvimento do referente trabalho. Por fim, explica todo o processo de busca de informações, pré-processamento, extração de características, análise exploratória, bem como ajustes finais no conjunto de dados e classificação.

3.1 BASE DE DADOS

Os dados utilizados foram obtidos a partir de 79 pessoas saudáveis, com idades entre 25 e 101 anos, sem uso de qualquer medicação relacionada ao sono (MOURTAZAEV et al., 1995). Duas PSGs de cerca de 20 horas cada, foram gravadas em dois períodos de dia e noite subsequentes na casa de cada paciente, os dados da gravação das primeiras noites dos pacientes de número 36 e 52 foram perdidas, assim como a segunda noite do paciente 13.

Posteriormente, dados foram perdidos devido a uma falha nos discos, fazendo que com sobrassem 39 pacientes com idades entre 25 e 34 anos, na época da gravação (GOLDBERGER et al., 2000).

A base contém hipnogramas com a extensão ".edf" e traz consigo anotações de padrão do sono de cada pessoa que realizou o exame. Estas anotações são feitas manualmente a partir da análise de técnicos bem treinados seguindo o manual de Rechtschaffen and Kales (RECHTSCHAFFEN, 1968).

Os hipnogramas, também conhecidos como arquitetura do sono (MARTINEZ, 1999), possuem padrão que consiste nos estágios do sono NREM (1, 2, 3 e 4), bem como do sono REM, estágio de vigília e movimentos; apresenta também o momento de início, assim como o tempo de permanência em um determinado estágio, tempo este conhecido como "período" (TUFIK, 2008).

Acompanha a base, ainda, um arquivo contendo informações específicas de cada pessoa como por exemplo a idade, número de registro do paciente, sexo e a hora do apagar das luzes, informação importantíssima para a contagem das latências do sono.

3.2 PRÉ-PROCESSAMENTO DOS DADOS

O arquivo contendo os dados do hipnograma possui um cabeçalho com informações detalhadas, como data exata do início da gravação, sexo, idade, etc, estas relativas ao paciente, assim como ao seu exame realizado. A Figura 6 mostra exatamente como os dados foram fornecidos.

Figura 6 – Exemplo de hipnograma no formato EDF

```

0      X F X Female_33yr
      Startdate 24-APR-1989 X X X
          24.04.8916.13.00512      EDF+C
          1      0      1      EDF Annotations
      0
1      -32768  32767
          2054
+0| +0|30630|Sleep stage W| +30630|120|Sleep stage 1| +30750|390|Sleep
stage 2| +31140|30|Sleep stage 3| +31170|30|Sleep stage 2| +31200|150|Sleep
stage 3| +31350|30|Sleep stage 4| +31380|60|Sleep stage 3| +31440|60|Sleep
stage 4| +31500|30|Sleep stage 3| +31530|120|Sleep stage 4| +31650|30|Sleep
stage 3| +31680|120|Sleep stage 4| +31800|30|Sleep stage W| +31830|60|Sleep
stage 3| +31890|60|Sleep stage 2| +31950|120|Sleep stage 3| +32070|30|Sleep
stage 4| +32100|30|Sleep stage 3| +32130|120|Sleep stage 4| +32250|210|Sleep
stage 2| +32460|30|Sleep stage 3| +32490|60|Sleep stage 2| +32550|120|Sleep
stage 3| +32670|30|Sleep stage 1| +32700|150|Sleep stage 2| +32850|60|Sleep
stage 3| +32910|30|Sleep stage 2| +32940|30|Sleep stage 3| +32970|30|Sleep
stage 2| +33000|120|Sleep stage 3| +33120|150|Sleep stage 4| +33270|30|Sleep
stage 3| +33300|30|Sleep stage 2| +33330|60|Sleep stage 3| +33390|30|Sleep
stage 4| +33420|90|Sleep stage 3| +33510|1890|Sleep stage 4| +35400|30|Sleep
stage 1| +35430|210|Sleep stage 3| +35640|60|Sleep stage 2| +35700|90|Sleep
stage 3| +35790|150|Sleep stage 2| +35940|30|Sleep stage 3| +35970|870|Sleep
stage R| +36840|180|Sleep stage 1| +37020|240|Sleep stage 2| +37260|30|Sleep
stage 3| +37290|120|Sleep stage 1| +37410|90|Sleep stage 2| +37500|30|Sleep
stage 1| +37530|930|Sleep stage 2| +38460|30|Sleep stage 3| +38490|30|Sleep
stage 2| +38520|60|Sleep stage 3| +38580|30|Sleep stage 4| +38610|30|Sleep

```

Fonte: Goldberger et al. (2000)

A fim de aumentar a acurácia do modelo resultante, foram obtidas apenas variáveis e/ou atributos relevantes para posterior uso na extração de características. A seleção de atributos se deu de forma manual, ou seja, escolha direta feita pelo usuário, sem uso de algoritmos específicos, porém baseando-se sempre na literatura, sobretudo em (MARTINEZ, 1999) e (TUFIK, 2008).

A seleção de atributos, portanto, se deu através da leitura dos hipnogramas como arquivos de texto, buscando fazer varreduras por padrões que pudessem separar cada atributo e salvar sua informação sempre relacionando-a ao seu estágio e ao paciente a que se refere o hipnograma. A captura de cada padrão foi fundamentalmente possível através do uso de expressões regulares e gerou informações como as da Figura 7:

Figura 7 – Exemplo de atributos extraídos da base de dados

```
key = 0 array(4) {
  ["name"]=>
  string(1) "W"
  ["period"]=>
  int(330)
  ["time"]=>
  string(8) "00:38:00"
  ["timeSeconds"]=>
  int(2280)
}

key = 1 array(4) {
  ["name"]=>
  string(1) "1"
  ["period"]=>
  int(120)
  ["time"]=>
  string(8) "00:43:30"
  ["timeSeconds"]=>
  int(89010)
}

key = 2 array(4) {
  ["name"]=>
  string(1) "2"
  ["period"]=>
  int(390)
  ["time"]=>
  string(8) "00:45:30"
  ["timeSeconds"]=>
  int(89130)
}

key = 3 array(4) {
  ["name"]=>
  string(1) "3"
  ["period"]=>
  int(30)
  ["time"]=>
  string(8) "00:52:00"
  ["timeSeconds"]=>
  int(89520)
}
```

Fonte: Própria

O atributo "time" foi preterido pelo "timeSeconds", visto que este segundo facilitava os cálculos, assim como sua rapidez. Para cada hipnograma, foi gerado um vetor com dados como o da Figura 7, onde os índices iniciais eram os referentes ao momento de início da PSG e o índice final do vetor corresponde aos dados imediatamente anteriores ao instante em que o paciente acorda.

Inicialmente, foram utilizados os seguintes atributos:

- Idade
- Sexo
- Data completa de início da PSG (contendo dia, mês, ano, hora, minuto e segundos)
- Horário do apagar das luzes
- Momento em que o paciente acorda definitivamente

- Tempo em segundos, referente ao horário de início para cada estágio do sono (1, 2, 3, 4, REM, Vigília, etc)
- Período de permanência em cada estágio do sono
- Nome do estágio atual

3.3 EXTRAÇÃO DE CARACTERÍSTICAS

Após o processo de pré-processamento do conjunto de dados, a extração segue o que foi descrito nas regras de produção, definidas na Seção 2.2 que representam o conhecimento de especialistas no estudo do sono. O procedimento adotado ocorreu através do uso de regras simples "se-então" ao iterar pelo vetor de atributos referente a cada paciente, somando-se em cada caso, os tempos em segundos da duração de cada estágio do sono, bem como a diferença de tempo entre o fim de um estágio e início de outro. Os cálculos de latências foram realizados através de somatórios dos períodos de cada estágio, até que se chegasse ao critério de parada de cada latência.

De maneira semelhante, foi feita a análise e extração da classe que demonstra o início de depressão no sono. De acordo com (MARTINEZ, 1999) e (TUFIK, 2008), tendo a redução da latência ao sono REM como o maior indicador de depressão, seguido de déficit na duração dos estágios 3 e 4 (sono de ondas lentas), aumento da latência ao sono e acréscimo do número de despertares longos.

3.4 CLASSIFICAÇÃO

A classificação foi realizada utilizando a biblioteca *Scikit-learn* que possui código aberto, inclusive, pode ser utilizado comercialmente; traz consigo uma série de ferramentas simples e eficientes como o NumPy, Pandas e matplotlib, empregadas na mineração e análise de dados (PEDREGOSA et al., 2011). Mais precisamente, foi escolhida a classe "DecisionTreeClassifier", uma vez que o mesmo possui a implementação do algoritmo CART, anteriormente descrito na Seção 2.3.3

Definidas as características, assim como as classes a elas relacionadas, foi possível definir os dados de treino e teste. Ao utilizar a rotina *train_test_split()*, pertencente à *scikit-learn*, foram configurados os parâmetros que separavam os dados em conjunto de treino e teste, passando-se como valores a quantidade ou porcentagem requerida para teste através da variável

$test_size = 0.3$, de forma que o restante ficará disponível para treino, desta forma, 70% do conjunto de dados foi usado para treino e 30% para teste.

Posteriormente, de posse dos dados corretamente distribuídos, é realizado o treinamento para o modelo do classificador. Durante o processo de separação de dados de treino e teste, o parâmetro *random_state* referente a rotina "*train_test_split()*" foi alterado, isto ocorre em razão da sensibilidade da árvore a pequenas alterações no conjunto de dados, e portanto, foi necessário manter fixo os indivíduos que seriam usados para treino e teste; de resto, foi seguido o padrão especificado na biblioteca.

Para avaliar o classificador foram utilizados testes de acurácia, precisão, sensibilidade, especificidade, além da geração da matriz de confusão. A impressão de uma árvore de decisão também foi importante para ilustrar o processo que será detalhado na Seção 4.2.

4 RESULTADOS

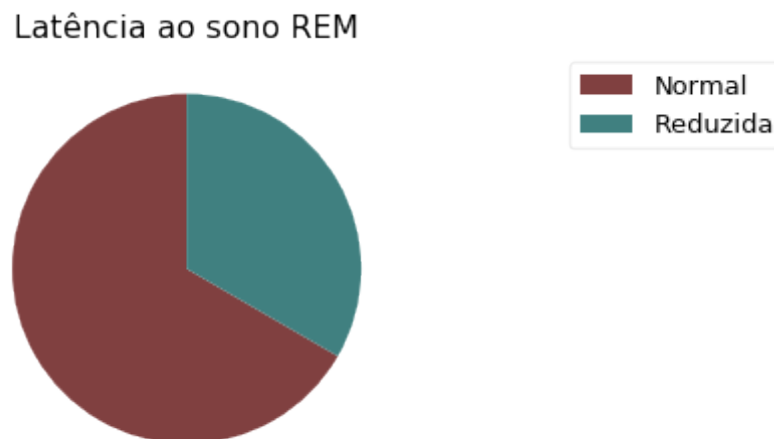
Este capítulo é destinado a apresentar os resultados obtidos, assim como uma discussão entre eles com o intuito de expor e analisar o processo da classificação.

4.1 ANÁLISE EXPLORATÓRIA

Esta seção tem por objetivo responder questionamentos acerca de algumas características do conjunto de dados citado no capítulo anterior.

Dentre os atributos escolhidos para análise estão: Latência ao sono REM, Latência ao sono(estágio 2) e índice de depressão no sono.

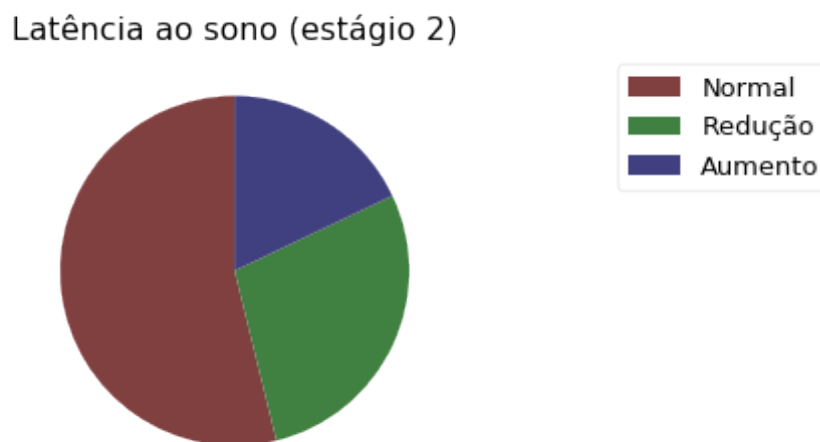
Figura 8 – Distribuição de indivíduos por quantidade de tempo de latência REM



Fonte: Própria

A maioria dos pacientes, cerca de 66%, apresentou latência normal ao sono REM, enquanto 33% demonstrou latência reduzida ao sono REM, indicando fortemente depressão

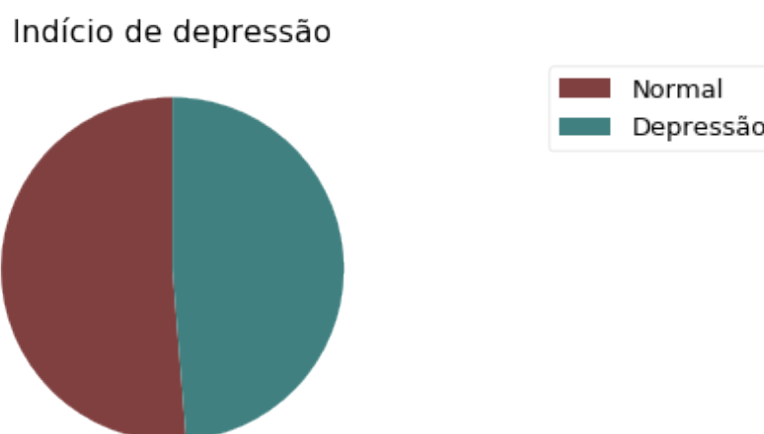
Figura 9 – Distribuição de indivíduos por quantidade de tempo de latência ao sono



Fonte: Própria

Para uma pequena maioria dos pacientes, cerca de 54%, a latência ao sono foi considerada normal, com o número de pacientes com latência reduzida ficando na segunda posição e porcentagem de 28% seguido pela quantidade de pacientes com latência elevada, aproximadamente 18% dos participantes.

Figura 10 – Distribuição de indivíduos por quantidade de pacientes com indícios de depressão no sono



Fonte: Própria

Embora a diferença seja pequena, a maioria dos participantes apresenta sono livre de

indícios de depressão, cerca de 51,2%.

4.2 AVALIAÇÃO E COMPARAÇÃO DOS RESULTADOS

Para realizar a avaliação foram construídas matrizes de confusão, testes de acurácia, precisão, sensibilidade e especificidade, para cada divisão em porcentagem do conjunto de dados de treino e teste passado para o classificador. Foram realizados três testes, para cada um definindo-se os seguintes percentuais de dados para treino do modelo 40, 60 e 80%, as porcentagens foram escolhidas de forma crescente a fim de avaliar o classificador com muito e com pouco treino, porém, não existe outro motivo especial para a escolha destes valores.

Com o objetivo de evitar valores muito diferentes no resultado final apenas por pequenas alterações no conjunto de dados, foi realizada a separação de um grupo fixo de dados através do parâmetro *random_state* com valor 24 na rotina *train_test_split* para uso em todas as predições.

É de grande importância que ambas as classes sejam reconhecidas, portanto, destaca-se que os indivíduos com índice de depressão representam a classe 'Depressão' ('positiva') assumindo o valor 1, enquanto que indivíduos normais, ou ainda, sem indícios de depressão são referenciados pela classe 'Normal' ('negativa') que assume o valor 0.

Ao utilizar 40% do conjunto de dados somente para treino e 60% para teste, foram obtidos os seguintes resultados:

Matriz de confusão

Tabela 3 – Matriz de confusão gerada com 40% do conjunto de dados de treino

	Previsão Positiva	Previsão Negativa
Depressão(1)	7	0
Normal(0)	5	12

Tabela 4 – Resultados ao utilizar 40% dos dados para treino

Métrica	Valor
Acurácia	0,79
Precisão	0,58
Sensibilidade	1,0
Especificidade	0,70

De acordo com a Tabela 4, é possível verificar que o classificador se mostrou insatisfatório ao apresentar valor consideravelmente baixo e igual a 58% no teste de precisão. Por outro lado, a métrica de sensibilidade, responsável por reconhecer pacientes que realmente possuem transtornos do sono relacionados à depressão, apresentou desempenho satisfatório com valor igual a 100%, enquanto que a especificidade, resultou em 70% de acerto para indivíduos considerados normais quanto a indícios de depressão no sono, o que justificou um índice também satisfatório para a acurácia de 79% encontrada.

A partir de 60% do conjunto de dados somente para treino e 40% para teste, foram obtidos os seguintes resultados:

Matriz de confusão

Tabela 5 – Matriz de confusão gerada com 60% do conjunto de dados de treino

	Previsão Positiva	Previsão Negativa
Depressão(1)	4	0
Normal(0)	1	11

Tabela 6 – Resultados ao utilizar 60% dos dados para treino

Métrica	Valor
Acurácia	0,937
Precisão	0,8
Sensibilidade	1,0
Especificidade	0,916

Verificando os valores obtidos na Tabela 6, pode-se afirmar que as métricas de acurácia, precisão, sensibilidade e especificidade com 93%, 80%, 100% e 91,6%, respectivamente, mostraram resultados satisfatórios. Nota-se ainda, que houve aumento no percentual de acurácia, precisão e especificidade, enquanto que a sensibilidade se mostrou estável e com ótimo desempenho.

Ao utilizar 80% do conjunto de dados somente para treino e 20% para teste, foram obtidos os seguintes resultados:

Matriz de confusão

Tabela 7 – Matriz de confusão gerada com 60% do conjunto de dados de treino

	Previsão Positiva	Previsão Negativa
Depressão(1)	2	0
Normal(0)	0	6

Tabela com resultados de

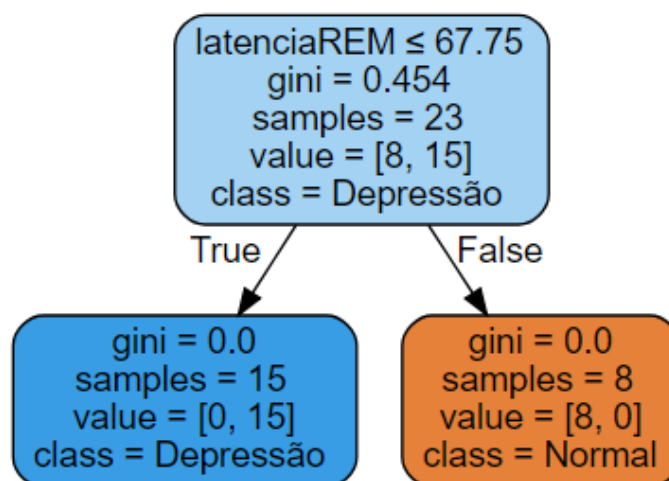
Tabela 8 – Resultados ao utilizar 80% dos dados para treino

Métrica	Valor
Acurácia	1,0
Precisão	1,0
Sensibilidade	1,0
Especificidade	1,0

Por fim, foi visto que todos os índices de desempenho alcançaram resultados muito satisfatórios no último teste com valores consideravelmente altos, como foi observado na Tabela 8 acima.

Ao comparar todas as previsões com suas respectivas porcentagens de dados de treino e teste, foi observado que conforme foi aumentada a quantidade de dados para treino, o classificador teve também o seu desempenho melhorado. Isto ocorreu em quase todas as métricas, exceto a sensibilidade que independente do quanto o classificador foi treinado, manteve valor constante durante todas as previsões.

Figura 11 – Árvore gerada



Fonte: Própria

A métrica de maior variação foi a precisão, indo de 58% a 100% ao utilizar 40% e 80% dos dados para treino da árvore respectivamente. Acima, na Figura 11, pode-se encontrar a árvore gerada pelo modelo, nela a característica "latenciaREM" possui o maior valor de índice Gini para corte da árvore, sendo também considerada o principal atributo para detecção de indícios da depressão no sono.

5 CONCLUSÃO

Atualmente, transtornos do sono tal qual a depressão são frequentes em todo o mundo, atingindo pessoas de várias idades, independente do gênero ou mesmo região. O fato de o hipnograma trazer a arquitetura do sono de forma clara, contribui para a detecção do transtorno. Somado a isto, o uso de um modelo classificador como o utilizado neste trabalho busca tornar o encontro de diversos indícios da depressão mais eficaz e de maneira rápida, inclusive para um conjunto de dados.

Analisou-se a capacidade de classificação do algoritmo de árvore de decisão, CART, como descrito na Seção (2.3.3) após diversos processos como obtenção e limpeza de dados, pré-processamento e extração de características.

Neste contexto, os dados referentes a arquitetura do sono dos pacientes foram divididos e utilizados de forma organizada e visando aumentar a carga de dados de treino. Foi observado que mesmo para uma menor quantidade de dados (40%) a capacidade do classificador de identificar indivíduos com indício de depressão foi consideravelmente satisfatória e se manteve constante durante todas as predições.

Por outro lado, a capacidade do classificador de prever corretamente indivíduos rotulados como "normais" se mostrou razoável para uma pequena massa de dados de treino. Consta-se, no entanto, que a métrica da especificidade a exemplo da precisão e também da acurácia, apresentaram melhora e um desempenho com crescimento proporcional à quantidade de dados separados para treino. Em decorrência disso, ao comparar os resultados é notória a importância e a diferença que a quantidade de treino ocasiona.

Portanto, é importante para trabalhos futuros fazer uso de uma massa de dados maior, a fim de analisar o desempenho do classificador, inclusive, para indivíduos com diversas idades. Também é essencial realizar mais testes de desempenho com outras métricas como curvas ROC, coeficientes de correlação Matthews e coeficiente Kappa para as mesmas porcentagens de divisões do conjunto de dados para treino e teste.

REFERÊNCIAS

- BARBOSA, J. M.; CARNEIRO, T. G. d. S.; TAVARES, A. I. Métodos de classificação por Árvores de decisão. 2011.
- BAUTISTA, D. P.; BADILLO, I. A.; MEJÍA, D. D. L. R.; JIMÉNEZ, A. H. H. **Interfaz humano-computadora basada en señales de electrooculografía para personas con discapacidad motriz**. 2014. Disponível em: <<http://recibe.cucei.udg.mx/revista/es/vol3-no2/biomedica02.html>>.
- BECCENERI, J. C.; KONO, Y.; GATTO, R. C.; SANTOS, R. Avaliação de Árvores de decisão para data mining de dados meteorológico. Rio de Janeiro, Dezembro 2004.
- BROWNLEE, J. **Classification And Regression Trees for Machine Learning**. 2016. Disponível em: <<https://machinelearningmastery.com/classification-and-regression-trees-for-machine-learning/>>.
- CHELLAPPA, S. L.; ARAÚJO, J. F. O sono e os transtornos do sono na depressão. **Archives of Clinical Psychiatry - São Paulo**, scielo, v. 34, p. 285 – 289, 00 2007. ISSN 0101-6083. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0101-60832007000600005&nrm=iso>.
- DAS, S. **Important Evaluation Metrics for the ML Classifiers - DZone AI**. 2017. Disponível em: <<https://dzone.com/articles/important-evaluation-metrics-for-the-classifiers>>.
- ESTRADA, E.; NAZERAN, H.; BARRAGAN, J.; BURK, J. R.; LUCAS, E. A.; BEHBEHAN, K. Eog and emg: Two important switches in automatic sleep stage classification. 2006.
- GOLDBERGER, A. L.; AMARAL, L. A. N.; GLASS, L.; HAUSDORFF, J. M.; IVANOV, P. C.; MARK, R. G.; MIETUS, J. E.; MOODY, G. B.; PENG, C.-K.; STANLEY, H. E. Physiobank, physiotoolkit, and physionet. **Circulation**, American Heart Association, Inc., v. 101, n. 23, p. e215–e220, 2000. ISSN 0009-7322. Disponível em: <<http://circ.ahajournals.org/content/101/23/e215>>.
- GORUNESCU, F. **Data Mining: Concepts, Models and Techniques**. 1. ed. Springer-Verlag Berlin Heidelberg, 2011. (Intelligent Systems Reference Library 12). ISBN 3642197205,9783642197208. Disponível em: <<http://gen.lib.rus.ec/book/index.php?md5=26C9C1C21C75978DA27C0F9D7FAE8608>>.
- JOHNY, G. **Árvores de Decisão Desequilibradas para detecção de erros em transações de comércio externo usando técnicas de datamining**. 10–12 p. Tese (Doutorado) — Faculdade de Engenharia - Universidade do Porto - FEUP, 2014.
- KOHAVI, F. P. R. Glossary of terms, machine learning. v. 30, n. 2/3, p. 271–274, Agosto 1998.
- MARTINEZ, D. **Prática da Medicina do Sono**. São Paulo: Fundo Editorial BYK, 1999.
- MEDEIROS, A. R. C.; ARAÚJO, Y. B. d.; VIANNA, R. P. d. T.; MORAES, R. M. d. **Modelo de suporte à decisão aplicado à identificação de indivíduos não aderentes ao tratamento anti-hipertensivo**. [S.l.]: scielo, 2014. 104 - 118 p.
- MOURTAZAEV, M.; KEMP, B.; ZWINDERMAN, A.; KAMPHUISEN, H. **Age and gender affect different characteristics of slow waves in the sleep EEG**. [S.l.]: Sleep 18, 1995. 557-564 p. (Intelligent Systems Reference Library 12).

NICOLAU, P. F. M. **A Arquitetura do Sono**. 2007. Disponível em: <<https://www.psiquiatriageral.com.br/sono/arquitetura.htm>>.

OENNING, E. O uso da polissonografia e da eletromiografia de superfície como meios complementares de diagnóstico do bruxismo do sono. 2005.

PALHARES, J. C. e I. **Brasil tem maior taxa de transtorno de ansiedade do mundo, diz OMS**. O Estado de S. Paulo, 2017. Disponível em: <<https://saude.estadao.com.br/noticias/geral,brasil-tem-maior-taxa-de-transtorno-de-ansiedade-do-mundo-diz-oms,70001677247>>.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

RECHTSCHAFFEN, A. K. A. **A manual of standardized terminology, techniques and scoring systems for sleep stages of human subjects**. [S.l.]: Brain Research Institute 10, 1968. (UCLA Brain Information Service).

RHEIN, L. D. O. **Semiologia Visual: Eletro-oculograma (EOG)**. 2010. Disponível em: <<https://opticanet.com.br/secao/colunaseartigos/4239/artigo-prof-leandro-rhein-semiologia-visual-eletro-oculograma-eog>>.

RUDGE RAMOS JORNAL. **Dados da OMS apontam que 40mal**. 2008. Disponível em: <<http://www.metodista.br/rroonline/noticias/saude/pasta-1/dados-da-oms-apontam-que-40-das-pessoas-dorme-mal>>. Acesso em: 13 de Maio 2018.

SABBATINI, R. M. **Mapeando o Cérebro**. 1997. Disponível em: <http://www.cerebromente.org.br/n03/tecnologia/eeg_p.htm>.

SALZBERGL, S.; KINGSFORD, C. What are decision trees? **Nature Biotechnology**, v. 26, n. 9, p. 1011–1013, Setembro 2008.

SAUDÁVEL, R. M. **Eletroencefalograma (EEG): o que é, tipos e para que serve o exame?** 2017. Disponível em: <<https://minutosaudavel.com.br/eletroencefalograma-eeg-o-que-e-tipos-e-para-que-serve-o-exame-2/>>.

SILVA, L. M. O. da. **Uma Aplicação de Árvores de Decisão, Redes Neurais e KNN para a Identificação de Modelos ARMA Não-Sazonais e Sazonais**. 41–48 p. Tese (Doutorado) — PUC, 2005.

SILVA, P. H. F. da. Medidas do valor preditivo de modelos de classificação aplicados a dados de crédito. São Carlos, Agosto 2008.

SOBRAL, A. P. B. **Previsão de Carga Horária - Uma nova abordagem por árvore de decisão**. 21–27 p. Tese (Doutorado) — PUC, 2003.

SUNASRA, M. **Performance Metrics for Classification problems in Machine Learning**. Augmenting Humanity, 2017. Disponível em: <<https://medium.com/greyatom/performance-metrics-for-classification-problems-in-machine-learning-part-i-b085d432082b>>.

TEODORO, W. L. G. **Depressão - Corpo, Mente e Alma**. Uberlândia: [s.n.], 2010. ISBN 978-85-61353-01-8.

TUFIK, S. **Medicina e Biologia do Sono**. Barueri - SP: Editora Manole Ltda, 2008.