

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

Vanessa Cassenote

**IDENTIFICAÇÃO DA CONDIÇÃO DE SONO A PARTIR DE
CARACTERÍSTICAS EXTRAÍDAS DE SINAIS DE EEG UTILIZANDO UM
MÓDULO ORANGE PI ZERO**

Santa Maria, RS
2017

Vanessa Cassenote

**IDENTIFICAÇÃO DA CONDIÇÃO DE SONO A PARTIR DE CARACTERÍSTICAS
EXTRAÍDAS DE SINAIS DE EEG UTILIZANDO UM MÓDULO ORANGE PI ZERO**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Engenharia de Computação**.

ORIENTADOR: Prof. Cesar Ramos Rodrigues

Santa Maria, RS
2017

Vanessa Cassenote

**IDENTIFICAÇÃO DA CONDIÇÃO DE SONO A PARTIR DE CARACTERÍSTICAS
EXTRAÍDAS DE SINAIS DE EEG UTILIZANDO UM MÓDULO ORANGE PI ZERO**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Engenharia de Computação**.

Aprovado em 15 de dezembro de 2017:

Cesar Ramos Rodrigues, Dr. (UFSM)
(Presidente/Orientador)

Cesar Augusto Prior, Dr. (UFSM)

Carlos Henrique Barriquello, Dr. (UFSM)

Santa Maria, RS
2017

DEDICATÓRIA

Aos meus pais.

AGRADECIMENTOS

Agradeço primeiramente as pessoas que mais me motivaram e me apoiaram para que eu conseguisse chegar até a finalização deste trabalho, meus pais: Marilene Felipetto Cassenote e Otacilio Manuel Cassenote e, o meu namorado Luiz Sandro Sartori Meneghetti.

Agradeço a todos que fizeram parte da minha vida em algum momento durante esses cinco anos e que com certeza contribuíram para o meu crescimento de uma forma ou de outra. Em especial ao professor Cesar Ramos Rodrigues pela orientação neste trabalho, pela motivação e por ter me apresentado essa área de estudo e, ao professor Cesar Augusto Prior pelo apoio e incentivo durante estes anos. Agradeço também ao professor Carlos Henrique Barrichello por aceitar fazer parte da banca de avaliação deste trabalho e contribuir para o aperfeiçoamento do mesmo.

Por fim, quero agradecer à família que a universidade me deu. Esses amigos que fizeram os últimos anos os melhores da minha vida, em especial ao pessoal do prédio da ECOMP.

"O céu não é o meu limite...Eu sou."

(T.F. Hodge)

RESUMO

IDENTIFICAÇÃO DA CONDIÇÃO DE SONO A PARTIR DE CARACTERÍSTICAS EXTRAÍDAS DE SINAIS DE EEG UTILIZANDO UM MÓDULO ORANGE PI ZERO

AUTORA: Vanessa Cassenote

ORIENTADOR: Cesar Ramos Rodrigues

Este trabalho em andamento relata os primeiros resultados de um projeto cujo propósito é a implementação de um sistema microprocessado para detecção da fadiga, ou estado de sonolência, a partir de sinais de eletroencefalograma (EEG). O uso da plataforma Orange Pi Zero permite que se tenha um sistema de classificação de estágios de sono de forma compacta, móvel e em tempo real. Até então, os sinais de EEG utilizados são oriundos de um banco de dados público, os quais foram adquiridos de 20 voluntários resultando em 39 arquivos de sinais com 20 horas de gravação. Estes são divididos em épocas (ou faixas de 30 segundos) de onde são filtradas as faixas de frequências importantes para a análise do sono com a transformada wavelet discreta de Daubechies e, em seguida, são extraídas características. Estas características são medidas estatísticas que tem como principais benefícios a redução do volume de dados e o destaque de informações do sinal, sendo elas a variância, a curtose e a assimetria. A partir delas pode-se treinar o classificador florestas aleatórias para identificar se o paciente está acordado (W) ou dormindo (SLP). O desempenho da classificação dos sinais é medido pelo cálculo da acurácia, o qual obteve-se 97% para o grupo de teste, que corresponde à 40% dos dados de entrada (106.285 épocas). Além disso, foram analisados os casos em que o classificador prevê o estado de sono com pelo menos uma época de antecedência para um paciente e, percebeu-se que a variância é a característica mais relevante para o classificador.

Palavras-chave: Processamento de sinais. EEG. Sonolência.

ABSTRACT

IDENTIFICATION OF DROWSINESS CONDITION FROM FEATURE EXTRACTION OF EEG SIGNALS USING A ORANGE PI ZERO MODULE

AUTHOR: Vanessa Cassenote
ADVISOR: Cesar Ramos Rodrigues

This work in progress reports the first results of a project which purpose is the implementation of a microprocessed system for the detection of fatigue, or state of drowsiness, from electroencephalogram (EEG) signals. The use of the Orange Pi Zero platform allows it to have a sleep stage classification system in a compact, mobile and real-time way. So far, the EEG signals used come from a public database, which were acquired from 20 volunteers resulting in 39 signal files with 20 hours of recording. These signal files are divided into epochs (30-second tracks) from which the important frequency bands for the sleep analysis are filtered with the Daubechies' discrete wavelet transform, and then features are extracted. These features are statistical measures that have as main benefits the reduction of data volume and the highlight of information from the signal, being they the variance, kurtosis and skewness. From these, one can train the random forest classifier to identify whether the patient is awake (W) or sleeping (SLP). The performance of the signal classification is measured by the accuracy calculation, which yields 97% for the test group, corresponding to 40% of the input data (106,285 epochs). Also in this work was made the analysis of the cases where the classifier predicts sleep state with at least one time in advance for a patient and, it was realized that the variance is the most relevant feature for the classifier.

Keywords: Signal processing. EEG. Drowsiness.

LISTA DE FIGURAS

Figura 2.1 – Configuração de posição de eletrodos 10-20 para EEG com 21 eletrodos. O canal destacado (Pz-Oz) é utilizado neste trabalho.	14
Figura 2.2 – Decomposição em cinco níveis da 1800ª época da segunda noite do paciente número 11. (a) Sinal original, (b) faixa <i>baixo-gama</i> , (c) faixa <i>Beta</i> , (d) faixa <i>Alfa</i> , (e) faixa <i>Teta</i> , (f) faixa <i>Delta</i>	15
Figura 2.3 – Gráficos da variância, curtose e assimetria do paciente 2 na segunda noite de sono para as bandas baixo-gama, beta, alfa, teta e delta respectivamente. No fundo branco o paciente está acordado (W) e no fundo cinza dormindo (SLP).	17
Figura 2.4 – Formato da função base da DWT de Daubechies.	19
Figura 2.5 – Intersecção na decomposição da DWT de Daubechies.	21
Figura 2.6 – Decomposição <i>wavelet</i> em cinco níveis, faixas de frequência associadas aos ritmos cerebrais em cada nível. C_5 representa o sinal original, $C_4 - C_0$ e $D_4 - D_0$ são as informações médias e de detalhes para cada nível de decomposição.	21
Figura 2.7 – Fluxo geral de um problema de classificação.	22
Figura 2.8 – Classificador florestas aleatórias.	24
Figura 2.9 – Visão frontal da Orange pi zero.	25
Figura 3.1 – O fluxo composto pelos módulos 1,2 e 3 corresponde ao funcionamento do sistema em tempo real. O fluxo restante corresponde ao treino do classificador e a obtenção de importância das características.	26
Figura 3.2 – Gráficos da variância, curtose e assimetria das épocas 820-1900 da segunda noite de sono do paciente 00. O gráfico azul são as classes definidas pelos especialistas (fundo branco é W e fundo azul é SLP) e o gráfico roxo é o resultado do classificador (fundo branco W e fundo roxo SLP). .	29
Figura 4.1 – Variância, curtose e assimetria para a quarta decomposição (banda teta - 4 Hz - 8 Hz) com os momentos de transição de W para SLP destacados. No fundo branco o paciente estava em W e no fundo cinza em SLP.	31
Figura 4.2 – Ampliação da segunda e terceira transição de W para SLP vista na figura 4.1.	32
Figura 4.3 – Gráfico de características por importância para o treino do classificador sem o paciente 00 na segunda noite de gravação. As características mais relevantes são respectivamente a variância em baixo-gama, variância em beta e curtose em baixo-gama.	32
Figura 4.4 – Gráficos da variância, curtose e assimetria respectivamente para os ritmos Baixo-gama e Beta.	33
Figura 4.5 – Gráficos da variância, curtose e assimetria com os momentos para a classificação das primeiras 13 épocas da segunda noite de sono do paciente 00, simulando a leitura dos sinais à 100 Hz. A linha vertical indica o fim de uma época com o tempo gasto para executá-la.	34

LISTA DE TABELAS

Tabela 2.1 – Filtros para normalização da DWT de Daubechies.	20
Tabela 4.1 – Matriz de confusão para os 39 arquivos de sinais (106.285 épocas de 30 segundos).	30
Tabela 4.2 – Matriz de confusão para a segunda noite do paciente 00.	30

LISTA DE ABREVIATURAS E SIGLAS

<i>EEG</i>	Eletroencefalograma
<i>DB2</i>	Daubechies com 2 momentos nulos
<i>DWT</i>	Transformada wavelet discreta
<i>RF</i>	Florestas Aleatórias
<i>W</i>	Estágio de sono acordado
<i>SLP</i>	Estágio de sono dormindo
<i>S1</i>	Estágio de sono 1
<i>S2</i>	Estágio de sono 2
<i>S3</i>	Estágio de sono 3
<i>S4</i>	Estágio de sono 4
<i>REM</i>	Movimento rápido dos olhos
<i>BCI</i>	Interface cérebro-máquina
<i>SPI</i>	Serial Peripheral Interface

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVOS	12
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	SINAIS DE ELETROENCEFALOGRAFIA	13
2.1.1	Faixas de frequências dos sinais de EEG	13
2.1.2	Seleção de Atributos	15
2.2	BASE DE DADOS SLEEP EDF [EXPANDED]	18
2.3	TRANSFORMADA WAVELET DISCRETA	18
2.3.1	DWT de Daubechies	19
2.4	ALGORITMO DE CLASSIFICAÇÃO	22
2.4.1	Classificador Florestas Aleatórias	23
2.5	PROCESSAMENTO DE SINAL EEG EMBARCADO	24
3	METODOLOGIA	26
3.1	IMPLEMENTAÇÃO DO SISTEMA DE DETECÇÃO DE FADIGA NA ORANGE PI ZERO	26
3.2	DESEMPENHO DO CLASSIFICADOR FLORESTAS ALEATÓRIAS	27
3.3	PREDIÇÃO DO ESTADO DE SONOLÊNCIA	28
4	RESULTADOS	30
4.1	RESULTADOS PARCIAIS DA IMPLEMENTAÇÃO EM TEMPO REAL	33
5	CONCLUSÃO	35
5.1	TRABALHOS FUTUROS	35
	REFERÊNCIAS BIBLIOGRÁFICAS	37

1 INTRODUÇÃO

A atividade neural de um cérebro humano começa entre a 17^a e a 23^a semana do desenvolvimento prenatal. Acredita-se que a partir deste estágio inicial e durante a vida os sinais elétricos gerados pelo cérebro representam não apenas as funções cerebrais, mas também o estado do corpo inteiro. Esta suposição promove a motivação para o processamento de sinais de eletroencefalograma (EEG) medidos de um cérebro humano (SANEI; CHAMBERS, 2007).

O estudo de EEGs contribui para o diagnóstico de muitos problemas neurológicos e outras anormalidades no corpo humano. Os sinais elétricos adquiridos de humanos (ou animais) podem ser utilizados para investigar situações de morte cerebral, coma, localização de áreas danificadas por acidentes na cabeça, monitoramento do estado de alerta, entre outros (SANEI; CHAMBERS, 2007). Além disso, os sinais de EEG estão sendo muito usados para controlar interfaces cérebro-máquina (BCI), onde um indivíduo sem capacidade motora, por exemplo, pode controlar um computador ou uma prótese somente com os sinais do cérebro (CURRAN; STOKES, 2003).

Com isso, a partir de sinais de EEG pode-se desenvolver um sistema para monitoramento do estado de alerta de motoristas, por exemplo, já que uma das principais causas de acidentes de trânsito é de motoristas que adormecem. Isto vem sendo provado por muitos estudos que relacionam acidentes de trânsito e sonolência. Um motorista com sono não é capaz de focar e tende a cometer erros. As habilidades de percepção, reconhecimento e de controle do veículo decaem muito (LIN FELLOW; JUNG, 2005). Existem muitos métodos para detecção de sonolência, um deles é a análise de sinais de eletroencefalograma (EEG) em faixas de frequência que variam de acordo com os estágios de sono. Um exemplo é quando as bandas teta e alfa aumentam, o nível do estado de alerta de uma pessoa diminui (EOH MIN K. CHUNG, 2005).

Por isso, um sistema para monitorar sinais cerebrais que seja portátil, sem fio e de tempo real é extremamente útil (LIN et al., 2008), principalmente para aplicações em que a mobilidade é necessária, como é o caso de monitoramento de motoristas, visto anteriormente.

Neste trabalho, foi implementada uma metodologia para classificação dos estados acordado (W) e dormindo (SLP), a partir de sinais de eletroencefalograma (EEG) em um sistema microprocessado. Os dados utilizados são provenientes de um banco de dados público e foram adquiridos pelo canal Pz-Oz de 20 voluntários. Esses sinais foram filtrados nos ritmos importantes para a análise do sono (Delta, Teta, Alfa, Beta e Baixo-gama) por meio da transformada *wavelet* discreta de Daubechies. Em seguida, para cada ritmo foram extraídas características estatísticas (variância, curtose e assimetria). Essas características compõem o treino do classificador florestas aleatórias que, com base neste, determina

para um novo sinal se o sujeito está no estado acordado (W) ou dormindo (SLP). Além disso, foram feitos testes iniciais para verificar a capacidade do sistema de executar em tempo real e, uma análise de alguns casos em que o classificador comete erros.

1.1 OBJETIVOS

O objetivo deste trabalho é implementar a metodologia desenvolvida por (SILVEIRA, 2016), em um sistema microprocessado. Esta consiste em extrair e classificar características estatísticas para detecção dos estados acordado (W) e dormindo (SLP), a partir de sinais de eletroencefalograma (EEG) oriundos de um banco público de sinais fisiológicos.

Inicialmente, é proposto um modelo de implementação da metodologia estudada para um sistema embarcado, de forma que possa ser flexível para que em um próximo trabalho seja possível substituir o banco de sinais por um módulo de aquisição de sinais de eletroencefalograma em tempo real de forma rápida. Acredita-se que esta implementação proposta possa compor aplicações que venham a salvar vidas de pessoas no trânsito, em fábricas ou em outras atividades semelhantes.

Por fim, fez-se uma análise dos resultados do classificador para buscar possíveis explicações para alguns casos em que o classificador comete erros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão introduzidos os conceitos estudados necessários para o entendimento deste trabalho. São eles: sinais de eletroencefalograma (EEG), transformada *wavelet* discreta, seleção de atributos (ou características), algoritmos classificadores e sistemas microprocessados.

2.1 SINAIS DE ELETROENCEFALOGRAFIA


Um sinal de eletroencefalograma é a medida das correntes que fluem no cortex cerebral. As células cerebrais (neurônios) quando ativas produzem uma corrente que gera um campo elétrico sobre o couro cabeludo, o qual é medido por sistemas de eletroencefalograma (SANEI; CHAMBERS, 2007).

A aquisição desses sinais é feita através de eletrodos. A Federação Internacional de Sociedades de Eletroencefalografia e Neurofisiologia Clínica recomenda a configuração convencional de eletrodos (também chamada 10-20). Uma representação do posicionamento de 21 eletrodos (excluindo os eletrodos nos lóbulos das orelhas) é mostrada na figura 2.1. A posição dos eletrodos tem relação com diferentes partes do cérebro. De acordo com a aplicação define-se qual é o melhor eletrodo a ser utilizado, muitas vezes utiliza-se mais de um (SANEI; CHAMBERS, 2007). A leitura do sinal de qualquer um dos eletrodos (ou canal) é denominada derivação e, um conjunto de derivações chama-se montagem (SILVEIRA, 2009). Neste trabalho os sinais de EEG utilizados foram adquiridos pela derivação Pz-Oz (PHYSIONET, 2013), eletrodos destacados na figura 2.1.

2.1.1 Faixas de frequências dos sinais de EEG

O uso de sinais de EEG para aplicações de BCIs não invasivas é largamente utilizado (KAWALA-JANIK; PELC; PODPORA, 2015). Para isto, é preciso selecionar as bandas de frequência necessárias para aquela aplicação. Existem cinco principais ritmos cerebrais importantes para a análise do sono que se diferenciam pelos intervalos de frequência. Estas bandas de frequência de baixa para alta frequência são: Delta, Teta, Alfa, Beta e Baixo-gama. A sonolência acontece quando um sujeito transita do estado acordado para o dormindo, ou seja, das frequências mais altas para as mais baixas e, o EEG é capaz de medir estas transições muito bem, por isso é considerado um indicador muito bom de sonolência (LIANG et al., 2017).


Figura 2.1 – Configuração de posição de eletrodos 10-20 para EEG com 21 eletrodos. O canal destacado (Pz-Oz) é utilizado neste trabalho.



Fonte: Adaptado de (SANEI; CHAMBERS, 2007).

As ondas delta estão no intervalo de 0.5 Hz e 4 Hz. Elas são associadas ao sono profundo e podem estar presentes no estado acordado. Já as ondas teta possuem frequências entre 4 Hz e 8 Hz. Este é o estado entre a consciência e a sonolência. Elas são associadas com o acesso ao material inconsciente, inspiração criativa e meditação profunda. Os ritmos alfa ficam entre 8 Hz e 13 Hz, podendo indicar tanto um estado relaxado de consciência sem nenhuma atenção, quanto concentração. As ondas beta são atividades elétricas do cérebro que variam entre 13 Hz e 25 Hz (SAHAYADHAS; MURUGAPPAN, 2012). Estas indicam o ritmo acordado que está associado ao pensamento ativo, atenção, foco e resolução de problemas. Um nível alto de beta é captado quando uma pessoa está em estado de pânico. Por fim, baixo-gama são as ondas que se referem a frequências de 25 Hz-50 Hz. Apesar das amplitudes destes ritmos serem baixas e sua ocorrência ser rara, a detecção destes ritmos pode ser usada para confirmar certos distúrbios cerebrais (SANEI; CHAMBERS, 2007). A figura 2.2 mostra a decomposição de um sinal nas faixas de frequência citadas.

Figura 2.2 – Decomposição em cinco níveis da 1800^a época da segunda noite do paciente número 11. (a) Sinal original, (b) faixa *baixo-gama*, (c) faixa *Beta*, (d) faixa *Alfa*, (e) faixa *Teta*, (f) faixa *Delta*



Fonte: Autor.

2.1.2 Seleção de Atributos

Após feita a decomposição do sinal nas faixas de frequências citadas anteriormente, é preciso eleger um grupo de atributos que ressalte bem as informações do sinal, para que se possa perceber com clareza as transições de estado. A escolha adequada de um conjunto de atributos é a tarefa mais difícil e mais importante (ZHU; WEN, 2014). Um conjunto muito grande de dados tende a gerar o problema de "*overfitting*" (AGGARWAL, 2014), onde o classificador se ajusta muito bem aquele conjunto de dados, mas se mostra ineficaz para prever novos resultados (GRUNWALD; RISSANEN, 2007), ocasionando na degeneração da performance. Por isso, a busca por características mais relevantes para um conjunto de dados específico é importante, já que um conjunto de características pode ser muito bom para um grupo de dados e muito ruim para outro.

Para cada faixa de frequência decomposta, importantes alterações no comportamento do sinal são destacadas. Com o intuito de evidenciar estas alterações e, principalmente, reduzir o conjunto de dados, são extraídas a variância (Eq. 2.1), a curtose (Eq. 2.2) e a assimetria (Eq. 2.3). O uso de medidas estatísticas é amplamente utilizado para a análise do sono e, as três características citadas anteriormente já foram utilizadas para análise de sinais fisiológicos no domínio do tempo, demonstrando a sua eficiência. Os sinais utilizados nesses estudos foram originalmente adquiridos com o intuito de auxiliar profissionais da área médica na tarefa de classificação das fases do sono (SILVEIRA, 2016).

A variância indica a dispersão de uma distribuição ou de uma amostra, a curtose representa o grau de compressão de uma distribuição e a assimetria mede o grau de obliquidade de uma distribuição.

$$Var(X) = \frac{\sum_{i=1}^T (X_i - \bar{X})^2}{T} \quad (2.1)$$

$$Kurt(X) = \frac{1}{T} \frac{\sum_{i=1}^T (X_i - \bar{X})^4}{Var(X)^2} - 3 \quad (2.2)$$

$$Skew(X) = \frac{1}{T} \frac{\sum_{i=1}^T (X_i - \bar{X})^3}{Var(X)^{\frac{3}{2}}} \quad (2.3)$$

A figura 2.3 mostra como cada medida se altera em relação as faixas de frequência e, como as informações ressaltadas por umas são complementadas pelas informações destacadas pelas outras.

Figura 2.3 – Gráficos da variância, curtose e assimetria do paciente 2 na segunda noite de sono para as bandas baixo-gama, beta, alfa, teta e delta respectivamente. No fundo branco o paciente está acordado (W) e no fundo cinza dormindo (SLP).



Fonte: Autor.

2.2 BASE DE DADOS SLEEP EDF [EXPANDED]

A plataforma *PhysioNet* disponibiliza sinais biomédicos com o intuito de estimular novas pesquisas. Muitas vezes os pesquisadores não tem acesso a dados de qualidade, corretamente validados e, além disso, como os dados da *PhysioNet* são públicos, isto possibilita que comparações entre trabalhos sejam realizadas e evita a produção de pesquisas redundantes (GOLDBERGER, 2000). Esta plataforma possui o banco de dados *Physio-Bank* com mais de 75 bases de dados, sendo uma delas a *Sleep EDF [Expanded]*. Os dados contidos nesta base foram obtidos de 10 homens e 10 mulheres com idades entre 25 e 34 anos, sem uso de medicação relacionada ao sono, pelos canais Fpz-Cz e Pz-Oz, com taxa de amostragem de 100 Hz (PHYSIONET, 2013). Neste trabalho somente os dados da derivação Pz-Oz foram utilizados dado que ele fornece melhores resultados de classificação para problemas de análise de sonolência (ZHU; WEN, 2014).

A base de dados *Sleep EDF [Expanded]* contém 39 arquivos com gravações de duas noites (em média 20 horas). Além disso, encontram-se também arquivos de hipnogramas, os quais contém anotações de especialistas sobre os estágios de sono (PHYSIONET, 2013). Estes estágios podem ser: acordado (W), estágio 1 (S1), estágio 2 (S2), estágio 3 (S3), estágio 4 (S4), movimento rápido do olhos (REM), "tempo de movimento" ou "não classificado" (SILVEIRA, 2016).

Os profissionais analisam os dados gravados em faixas de tempo chamadas épocas e não o sinal completo. Cada época tem 30 segundos e, considerando uma frequência de 100 Hz obtém-se 3000 pontos para classificação (uma linha do arquivo de hipnograma) (SILVEIRA, 2016).

2.3 TRANSFORMADA WAVELET DISCRETA

As *wavelets* são funções para serem usadas como base para representação de outras funções, assim como os senos e cossenos são as bases para a decomposição por Fourier, ou seja, uma função pode ser escrita em termos de funções *wavelets* (VIDAKOVIC; MUELLER, 1994). Porém, as *wavelets* são mais eficientes em relação à Fourier na análise de sinais não-periódicos e que contenham mudanças abruptas, como é o caso dos sinais de EEG (SILVEIRA, 2016). Isto é devido as duas principais características das funções *wavelets*, os fatores de escala e translação. O fator de escala representa o processo de alongar ou encolher uma função no tempo e ele é inversamente proporcional à frequência. Uma *wavelet* alongada ajuda a encontrar mudanças que variam lentamente em um sinal, enquanto a *wavelet* comprimida ajuda a capturar mudanças abruptas. Já a translação é quando o início da função é atrasado ou adiantado para que a *wavelet* fique alinhada com uma característica específica que se está buscando no sinal. Estas características

possibilitam que as *wavelets* sejam localizadas em frequência (pela escala) e no tempo (pela translação), ou seja, é possível saber "quando" no tempo aquelas frequências estão acontecendo. O que não acontece nas transformadas de Fourier (VIDAKOVIC; MUELLER, 1994).

Além disso, funções com descontinuidades e picos podem ser representadas de forma mais compacta com funções *wavelets*, ou seja, para aproximar este tipo de funções com Fourier, é necessário um número de senos e cossenos muito maior do que de funções *wavelets*. Estas características fazem das *wavelets* excelentes ferramentas para problemas de compressão de imagens, por exemplo.


Por isso, assim como em SILVEIRA (2016), neste trabalho as *wavelets* serão utilizadas para decompor o sinal de entrada nas faixas de frequência vistas anteriormente.

Um guia mais completo sobre *wavelets* pode ser encontrado em SILVEIRA (2016).

2.3.1 DWT de Daubechies

Em (SILVEIRA, 2016) a *wavelet* trabalhada foi a db2, ou seja, *wavelet* de Daubechies com 2 momentos nulos. As funções bases para db2 possuem um formato de "barbatanas de tubarão"(Figura 2.4). Estas funções tem a característica de que fora de um intervalo definido, elas são sempre nulas.

Figura 2.4 – Formato da função base da DWT de Daubechies.



Fonte: (SILVEIRA, 2016)

A partir de um vetor de dados inicial C_j é feita a transformada *wavelet* discreta de Daubechies através do cálculo dos vetores de coeficientes, ou médias (Eq. 2.4) e, de detalhes (Eq. 2.5). O primeiro representa as informações médias do sinal e o segundo a variação do sinal original em relação a estas médias. Cada vetor contém metade do tamanho do vetor original, ou seja, o espaço para guardar os vetores de coeficientes e detalhes é o mesmo que o espaço do vetor original, não há aumento no custo de memória. Nas equações 2.4 e 2.5 o parâmetro $D = 2M$, sendo M o número de momentos nulos, portanto $D = 4$. Além disso, l representa a posição do elemento no novo vetor, h_k e g_k

são os filtros aplicados em cada elemento do vetor original (Tabela 2.1) e $\langle . \rangle$ representa a operação de módulo.

$$C_{j-1,l} = \sum_{k=0}^{D-1} h_k \cdot C_{j, \langle 2l+k \rangle_{2^j}} \quad (2.4)$$

$$D_{j-1,l} = \sum_{k=0}^{D-1} g_k \cdot C_{j, \langle 2l+k \rangle_{2^j}} \quad (2.5)$$

Tabela 2.1 – Filtros para normalização da DWT de Daubechies.

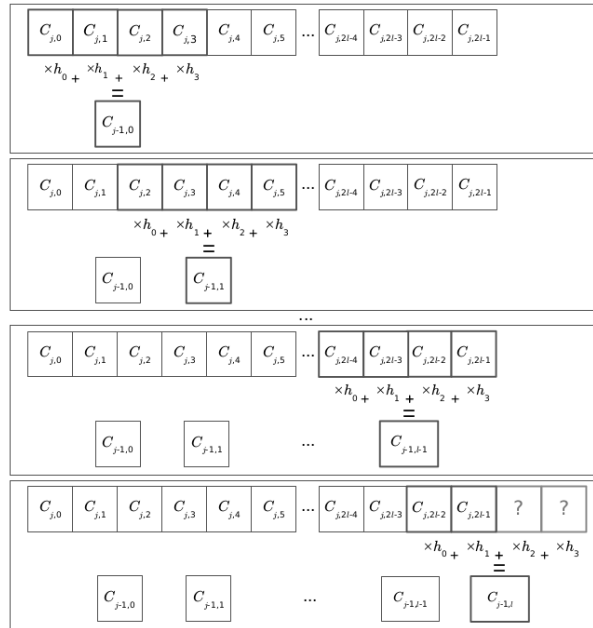
k	h_k	g_k
0	0,4829629131445341	-0,1294095225512603
1	0,8365163037378077	-0,2241438680420134
2	0,2241438680420134	0,8365163037378077
3	-0,1294095225512603	-0,4829629131445341

Fonte: (SILVEIRA, 2016)

Para se obter o vetor C_{j-1} os filtros devem ser aplicados a cada quatro valores e, há intersecção entre duas iterações (Figura 2.5). Ainda, podemos perceber que na última iteração será necessário fazer uma extrapolação de dois pontos. Uma possibilidade é considerar o sinal periódico, onde considera-se para os elementos faltantes os primeiros elementos do vetor. Porém, para problemas de processamento de sinais EEG, considerar o sistema periódico não é plausível, por isso, como o sinal é dividido em épocas (30s) por convenção, pode-se utilizar pontos da época seguinte e, portanto o cálculo é realizado com valores exatos. Além disso, em (SILVEIRA, 2016) foi feito um ajuste no algoritmo de Daubechies para que este permita um conjunto de valores que não seja do formato $L = 2^j$, e sim na forma $L = R \cdot 2^k$, sendo k o número de vezes que pode-se decompor e R o tamanho dos vetores de coeficientes e detalhes na última decomposição.

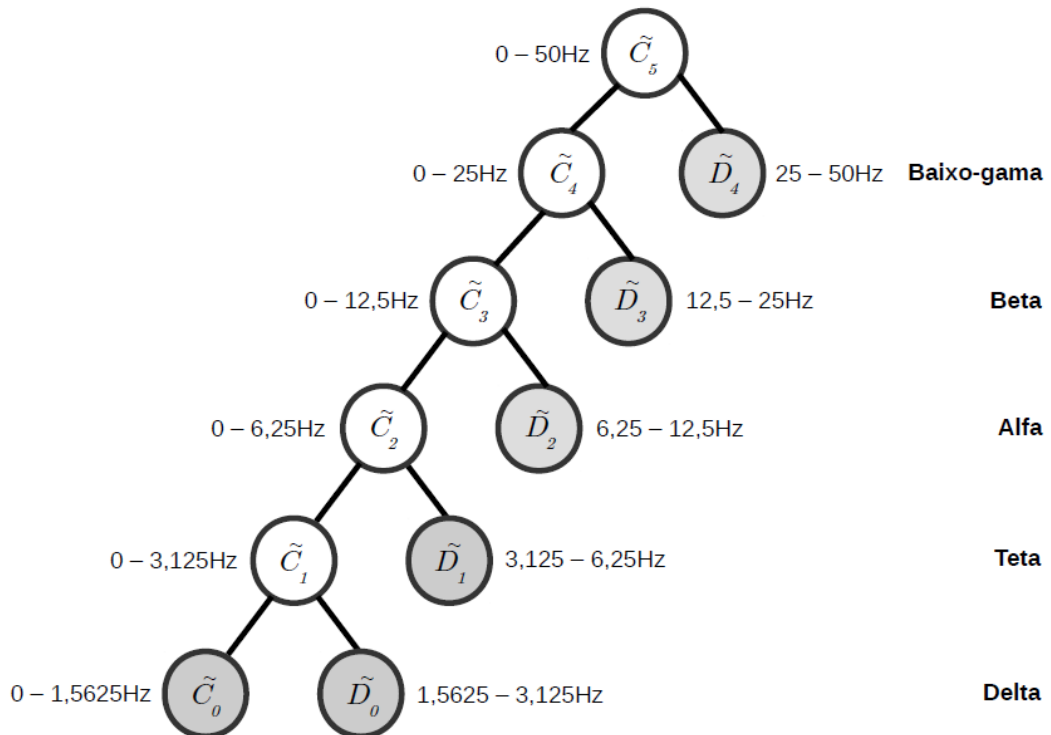
Após o ajuste, para possibilitar um maior número de decomposições, obtém-se 8 amostras da época seguinte. Considerando que se tem 3000 pontos por época, agora serão 3008. Não há deslocamento nas épocas, permitindo-se decompor estes vetores até seis vezes. Pelo teorema de Nyquist só se pode representar frequências até a metade da frequência de amostragem, portanto sendo 100 Hz a frequência amostrada só podemos descrever frequências de 0 - 50 Hz (Fig. 2.6).

Figura 2.5 – Intersecção na decomposição da DWT de Daubechies.



Fonte: (SILVEIRA, 2016)

Figura 2.6 – Decomposição *wavelet* em cinco níveis, faixas de frequência associadas aos ritmos cerebrais em cada nível. C_5 representa o sinal original, $C_4 - C_0$ e $D_4 - D_0$ são as informações médias e de detalhes para cada nível de decomposição.

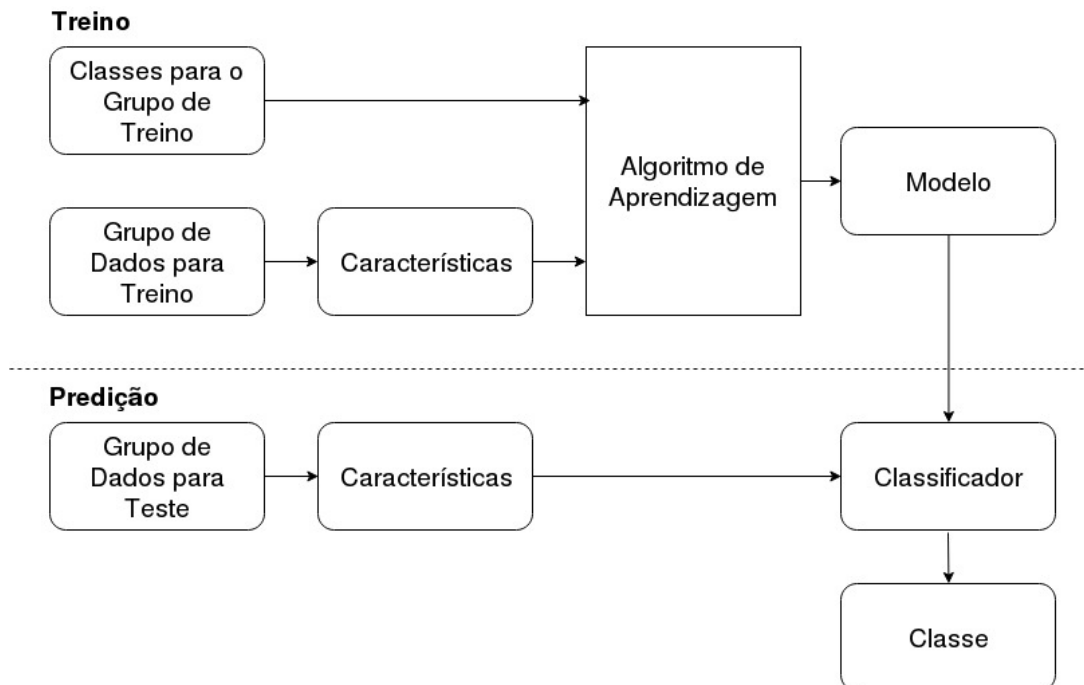


Fonte: (SILVEIRA, 2016)

2.4 ALGORITMO DE CLASSIFICAÇÃO

Classificação é o problema de identificar a qual das categorias (ou classes) definidas um novo dado pertence, com base em um grupo de dados treinados do qual se sabe a que categoria pertencem. Muitas situações da vida real podem ser modeladas por problemas de classificação, como: enviar um e-mail para caixa de *spam* ou não, definir automaticamente se uma notícia é de esportes ou entretenimento e, diagnosticar uma doença em um paciente com base em características observadas nele (ex: gênero, pressão sanguínea, presença ou ausência de algum sintoma, etc). O processo de classificação de uma forma geral é apresentado na figura 2.7.

Figura 2.7 – Fluxo geral de um problema de classificação.



Fonte: Baseado em (AGGARWAL, 2014)

Os problemas de classificação são divididos em duas fases: o treino e a predição. Na fase de treino, o algoritmo de aprendizagem recebe tanto as características extraídas do conjunto de dados separados para treino, quanto as classes as quais os dados pertencem. Estas classes normalmente são geradas por especialistas da área, por exemplo, no caso de uma investigação para determinar se um paciente possui ou não uma determinada doença, o médico especialista classificará os dados do grupo de treino como "sim" ou "não" caso a pessoa tenha ou não a doença estudada. A partir disso, o algoritmo de aprendizagem gera um modelo com base nas características dadas determinando quando será uma classe ou outra.

Na fase de predição, o classificador escolhido recebe tanto o modelo gerado durante

o treino, quando as características geradas a partir de dados novos. Estes dados não possuem a classificação dada pelos especialistas. Assim, com base no modelo gerado o classificador tenta prever a que classe pertence esse novo dado.

Existem muitos métodos de classificação na literatura. Estes podem ser categorizados de forma geral em: classificadores lineares, máquinas de vetor de suporte, árvores de decisão e redes neurais. A escolha do melhor método depende do tipo de dado que se está processando (AGGARWAL, 2014).

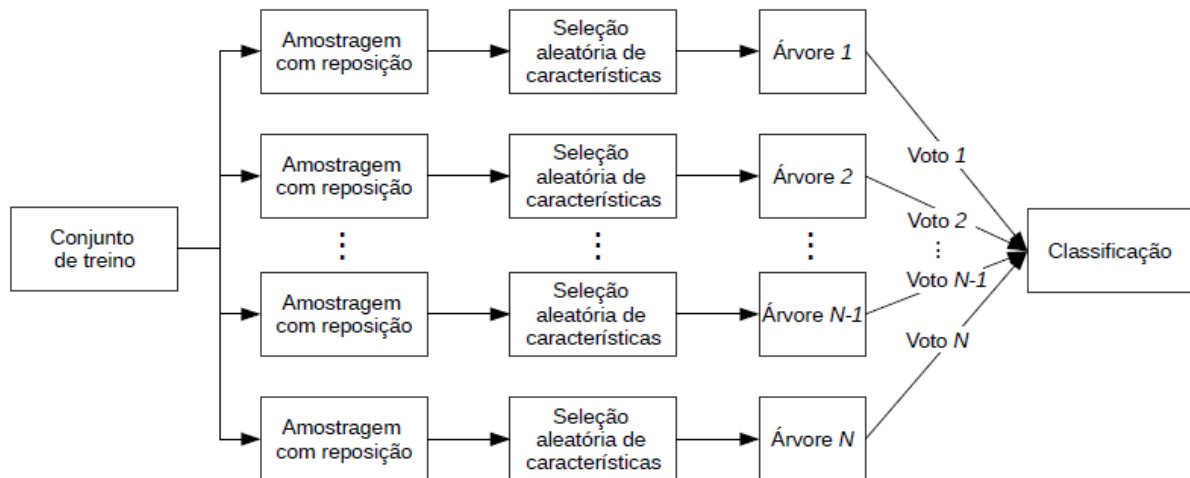
2.4.1 Classificador Florestas Aleatórias

O classificador florestas aleatórias (RF - *Random Forest*) é composto por um conjunto de árvores de decisão que votam pela classe mais popular (BREIMAN, 2001). O grupo de treino é dividido de forma aleatória em vários subgrupos (com reposição) que formam as árvores de decisão (DIAZ-URIARTE; ANDRES, 2006). O objetivo é combinar as classificações individuais das N árvores de decisão, cada uma construída com F características, em uma só categoria. O número de características F obedece $F = \lfloor \log_2 P + 1 \rfloor$, sendo P a quantidade total de atributos do conjunto de dados. Neste estudo, têm-se $P = 18$ e, portanto, cada árvore de decisão é gerada com $F = 5$ atributos.

Além disso, pode-se definir o número de árvores que se deseja criar. Alguns autores (OSHIRO; PEREZ; BARANAUSKAS (2012)) fizeram experimentos com 64, 128, 256, 512 e 1024 árvores levando em conta a densidade do conjunto de dados e, percebeu-se que a acurácia é praticamente a mesma entre os conjuntos citados. O grupo de dados deste trabalho, segundo as métricas propostas por esses autores, é considerado de baixa densidade. Por isso, definiu-se em SILVEIRA (2016) $N = 64$, já que o aumento do número de árvores gera maior custo computacional e a acurácia converge para um limite.

A construção de uma floresta aleatória é feita como mostra a figura 2.8. A partir do grupo de treino, N conjuntos de mesmo tamanho são criados com a técnica de amostragem com reposição. Cada uma das N árvores considera seu conjuntos como conjunto de treino, selecionando aleatoriamente F atributos para seu crescimento. Segundo BREIMAN (2001) a combinação dos conjuntos com redundância e a seleção aleatória das características aumenta o desempenho do classificador tornando-o mais robusto a ruídos (SILVEIRA, 2016). A implementação do Florestas aleatórias na linguagem *python* utiliza a média para melhorar a acurácia e controlar o *overfitting*. Além disso, pode-se definir se a amostragem será ou não com reposição, ou seja, com ou sem *bootstrap* (SCIKIT-LEARN DEVELOPERS, 2017).

Figura 2.8 – Classificador florestas aleatórias.



Fonte: (SILVEIRA, 2016)

2.5 PROCESSAMENTO DE SINAL EEG EMBARCADO

Um sistema que possa monitorar e analisar sinais fisiológicos em tempo real, sem fio e de forma portátil é extremamente útil em diversas áreas. Uma aplicação de tempo real é aquela que deve completar uma tarefa dentro de um prazo bem definido (SHIN; RAMANATHAN, 1994). A partir de um estímulo visual, uma pessoa leva em torno de 331 milissegundos para reagir e, 284 milissegundos para um alerta sonoro (SHELTON; KUMAR, 2010). Por isso, segundo Khan et al. (2016) um sistema de detecção de sonolência para motoristas, por exemplo, deve enviar um sinal de alerta em alguns segundos.

Tradicionalmente, estas aplicações são medidas e analisadas por computadores de mesa, o que prejudica a mobilidade do usuário e a portabilidade. Por isso, aparelhos pequenos e que podem ser levados para outros ambientes são desejáveis (LIN et al., 2008).


Uma maneira de evitar as limitações que os computadores tradicionais impõem, é a utilização de um sistema embarcado (SENTHILKUMAR; GOPALAKRISHNAN; KUMAR, 2014). A Orange Pi Zero (Figura 2.9) é um mini computador portátil, com suporte à vários sistemas operacionais e é *open source*. O fato desta ser *open source* possibilita que ela seja uma ferramenta para um número grande de aplicações, além de que, ela é tão poderosa quanto muitos computadores de mesa (ORANGEPIZERO, 2016).

Além disso, a orange pi zero tem suporte a comunicação SPI (Serial Peripheral Interface). Esta é uma característica importante, pois em paralelo com este trabalho esta

sendo desenvolvida, por uma colega em seu trabalho de conclusão de curso, uma placa para comportar o circuito ADS1299-4. Este circuito é um conversor analógico-digital de 24 bits, com 4 canais e, uma de suas aplicações é a aquisição de sinais de eletroencefalograma (EEG). A comunicação com este circuito é feita por SPI.

Por isso, a orange pi zero foi a ferramenta utilizada neste trabalho para embarcar a metodologia proposta em SILVEIRA (2016), já que o objetivo é que, em um próximo trabalho, esta se comunique com o circuito conversor para que se tenha um sistema de detecção de sonolência em tempo real.

Figura 2.9 – Visão frontal da Orange pi zero.



Fonte: (ORANGEPIZERO, 2016)

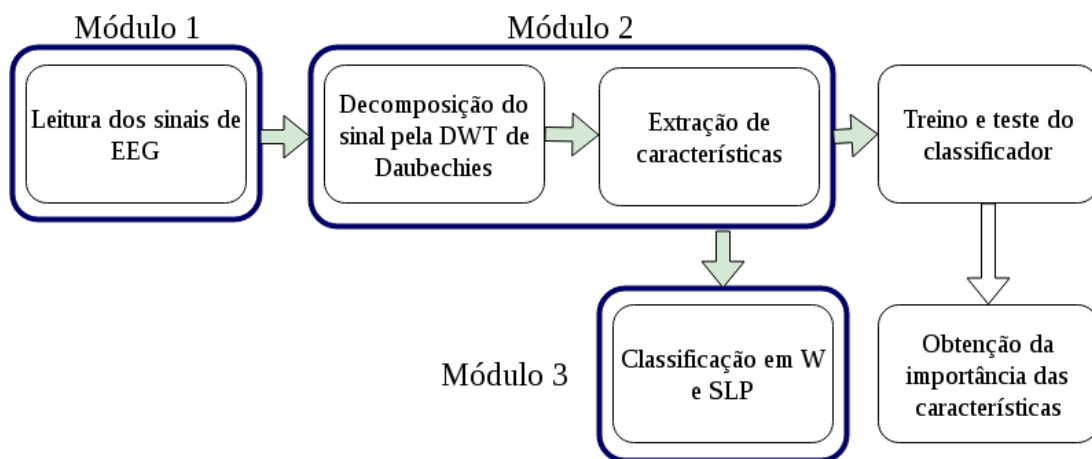
3 METODOLOGIA

O desenvolvimento deste trabalho pode ser dividido em três partes: o desenvolvimento de um algoritmo compatível com um sistema embarcado para a leitura de dados, decomposição e classificação do sinal, a avaliação da importância das características para a tomada de decisão do classificador e o uso de medidores estatísticos para verificar a eficiência do classificador utilizado.

3.1 IMPLEMENTAÇÃO DO SISTEMA DE DETECÇÃO DE FADIGA NA ORANGE PI ZERO

A implementação do sistema proposto neste trabalho foi dividida em três módulos: a leitura dos sinais de eletroencefalograma, a decomposição do sinais e a extração de características e, por fim a classificação destas características. A figura 3.1 mostra o diagrama com a sequência citada.

Figura 3.1 – O fluxo composto pelos módulos 1,2 e 3 corresponde ao funcionamento do sistema em tempo real. O fluxo restante corresponde ao treino do classificador e a obtenção de importância das características.



Fonte: Autor.

O fluxo da figura 3.1 foi desenvolvido na linguagem *Python*. Cada um dos módulos são processos que executam paralelamente para que se possa minimizar o tempo de processamento, para isso utilizou-se as funções da biblioteca *multiprocessing*. O fluxo destacado em verde corresponde ao funcionamento do sistema em tempo real.

No primeiro módulo os sinais do arquivo de sinais fisiológicos vão sendo lidos até que se complete uma época (3.000 pontos). Porém, como visto anteriormente, a TWD de Daubechies espera receber 3.008 pontos mais uma quantidade de pontos utilizados para

extrapolar nas bordas de cada nível de decomposição. Por isso, para a classificação de uma época é necessário fazer a leitura de 3.072 pontos. Com isso, o processamento de uma época precisa de um tempo um pouco maior do que 30 segundos para executar. A principal vantagem da leitura dos sinais estar em um processo separado é que torna-se mais flexível a mudança do banco de dados por um sistema de aquisição em tempo real.

No segundo módulo é feita a decomposição do sinal em : Delta, Teta, Alfa, Beta e Baixo-Gama e, a extração das características estatísticas: variância, curtose e assimetria. Para cada época decomposta são extraídas 18 características, tendo-se assim uma redução de 3.008 pontos para 18 características. Além disso, para cada época lida (no módulo 1) um novo processo é disparado para decomposição e extração de características, assim permite-se que a leitura de novos dados aconteça ao mesmo tempo que a execução dos dados lidos na última época.

No terceiro módulo é feita a classificação das épocas. Como classificador utilizou-se o algoritmo florestas aleatórias proveniente da biblioteca *Sklearn* da linguagem *Python*. Este recebeu os 39 arquivos de sinais (ou 106.285 épocas de 30 segundos) que foram divididos em dois grupos aleatoriamente: 60% para treino e o restante para teste do classificador. Na fase de treino do classificador este recebe tanto os arquivos de sinais, quanto os arquivos com a classificação feita pelos especialistas para aqueles sinais. Já na fase de teste este recebe somente os sinais, os quais ele nunca esteve em contato antes. O treino do classificador é feito somente uma vez, é salvo em um arquivo (.pkl) através da biblioteca *pickle* e será carregado toda vez que o sistema for acionado.

Vimos anteriormente que a classificação mais completa é a de 6 cenários, composta pelos estados: W (acordado), REM (movimento rápido dos olhos), S1 (estágio de sono 1), S2 (estágio de sono 2), S3 (estágio de sono 3) e S4 (estágio de sono 4). Como este trabalho tem o objetivo de detectar apenas o estado de fadiga de um indivíduo em tempo real para, em seguida, se necessário, gerar algum tipo de alerta, a classificação em 2 estados é a que melhor representa este cenário. Esta é composta pelo estado W (acordado) e uma combinação entre os estados restantes, chamada estágio de repouso (SLP).

3.2 DESEMPENHO DO CLASSIFICADOR FLORESTAS ALEATÓRIAS

O desempenho do sistema foi medido de acordo com o cálculo da acurácia (3.1), o qual é dado a partir da matriz de confusão (M). A matriz de confusão é uma matriz quadrada que relaciona todos os acertos e erros do método de classificação avaliado.

$$Acc(M) = \frac{\sum_{i=1}^Q M_{ii}}{\sum_{i=1}^Q \sum_{j=1}^Q M_{ij}} \quad (3.1)$$

Como visto anteriormente, os 39 arquivos de sinais dados como entrada para o classificador foram divididos em dois grupos selecionados aleatoriamente: o treino com 60% dos dados e o teste com o restante. A matriz de confusão mostra o resultado que o classificador obteve para o grupo de teste. Esta é separada em verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. Os verdadeiros positivos são aqueles dados que eram da classe acordado e foram classificados como acordado, os falsos positivos são aqueles que foram classificados como acordado mas na verdade eram dormindo e, o mesmo se aplica para os verdadeiros e falsos negativos, sendo que o negativo é o estado dormindo (SLP).

$$Pre(M, i) = \frac{\sum_{i=1}^Q M_{ii}}{\sum_{j=1}^Q M_{ji}} \quad (3.2)$$

$$Rev(M, i) = \frac{\sum_{i=1}^Q M_{ii}}{\sum_{j=1}^Q M_{ij}} \quad (3.3)$$

Além disso, com os mesmos parâmetros calcula-se a precisão (Equação 3.2) e a revocação (Equação 3.3). A primeira indica a relação entre a quantidade de instâncias classificadas corretamente pela quantidade de instâncias rotuladas como pertencentes àquela classe. E, a segunda apresenta a porcentagem de objetos que foram corretamente classificados como referentes àquela classe (SILVEIRA, 2016).

3.3 PREDIÇÃO DO ESTADO DE SONOLÊNCIA

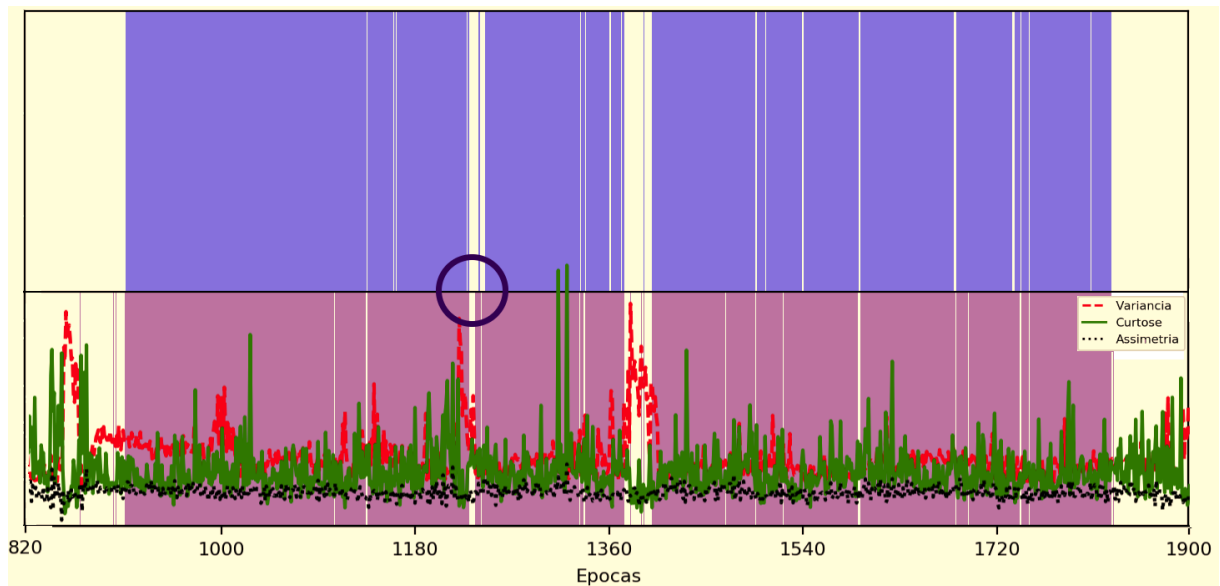
Durante o desenvolvimento deste trabalho percebeu-se que os casos em que as florestas aleatórias classificavam como dormindo, mas na verdade eram estados de acordado (falsos negativos), não eram erros críticos para o sistema. Na verdade estes casos se tornaram muito relevantes, já que, após uma análise dos resultados do classificador comparado com o dos especialistas verificou-se que eles acontecem, muitas vezes, pouco antes de uma transição do estado acordado (W) para o dormindo (SLP). Este é um fato importante, pois permite que o sistema alerte um motorista, por exemplo, antes deste adormecer.

Por isso, foi feita uma análise destes casos de transição, para um paciente, em busca de uma pista sobre qual a razão de o classificador fazer essa detecção prévia. A figura 3.2 mostra a variância, curtose e assimetria para algumas épocas do paciente 00. O gráfico azul é a classificação dada pelos especialistas e o gráfico roxo é o resultado do classificador. Os fundos azul e roxo são SLP e o fundo branco W. Um dos casos de predição está destacado na figura com um círculo. Considerou-se uma transição válida do estado W para SLP quando o paciente permaneceu mais de uma época em ambos os

estados. Os casos em que o paciente estava em SLP por muitas épocas, ficou em W por uma época e volta para SLP, por exemplo, foram desconsiderados.

Além disso, investigou-se a importância de cada característica na decisão do classificador, pode-se perceber também pela figura 3.2 que as características variam muito de acordo com o estágio de sono. Após o treino do florestas aleatórias, utilizando um atributo do conjunto recém treinado (*treino.feature_importances_*) foi possível adquirir a ordem de relevância das características utilizadas, ou seja, determinar quais delas exercem maior impacto na decisão do classificador. O fluxo para obtenção destas importâncias foi mostrado na figura 3.1.

Figura 3.2 – Gráficos da variância, curtose e assimetria das épocas 820-1900 da segunda noite de sono do paciente 00. O gráfico azul são as classes definidas pelos especialistas (fundo branco é W e fundo azul é SLP) e o gráfico roxo é o resultado do classificador (fundo branco W e fundo roxo SLP).



Fonte: Autor.

4 RESULTADOS

O classificador florestas aleatórias obteve uma acurácia de 97,01% para a classificação em duas classes, W (acordado) e SLP (dormindo). A matriz de confusão para o grupo de teste é apresentada na Tabela 4.1. Além disso, podemos ver a medida de precisão e revocação para os dados.

Tabela 4.1 – Matriz de confusão para os 39 arquivos de sinais (106.285 épocas de 30 segundos).

	Método Proposto	
	W	SLP
W	28442	420
SLP	851	12801
Precisão(%)	97,1	97
Revocação(%)	98,5	93,8

Fonte: Autor.

Para verificar a eficiência do classificador em detectar o estado de sono pelo menos uma época antes do paciente dormir, foi feito um novo treino. Neste reduziu-se a quantidade de épocas para 103.548, sendo que o restante foi reservado para o grupo de teste do classificador. O grupo de teste corresponde ao arquivo de sinais do paciente 00 na segunda noite de gravação. A Tabela 4.2 mostra a matriz de confusão para este grupo, com acurácia de 96.5%.


Tabela 4.2 – Matriz de confusão para a segunda noite do paciente 00.

	Método Proposto	
	W	SLP
W	1791	93
SLP	8	936
Precisão(%)	99,5	91
Revocação(%)	95,06	99,2

Fonte: Autor.

O classificador detectou a sonolência, pelo menos uma época antes, três das quatro vezes que o paciente estava no estado acordado (W) e passou para dormindo (SLP). A figura 4.1 mostra a variância, curtose e assimetria para o ritmo teta. O fundo branco representa as épocas em que o paciente estava acordado e o fundo cinza quando ele estava dormindo.

Figura 4.1 – Variância, curtose e assimetria para a quarta decomposição (banda teta - 4 Hz - 8 Hz) com os momentos de transição de W para SLP destacados. No fundo branco o paciente estava em W e no fundo cinza em SLP.




Fonte: Autor.

Na primeira transição o classificador identificou a sonolência uma época antes do paciente dormir, ou seja, com 30 segundos de antecedência. Nas duas transições seguintes, como se pode ver na figura 4.2 o classificador identificou a sonolência mais de uma época antes da transição (90 segundos antes). No fundo branco o paciente está em W, no fundo cinza claro é onde o classificador começou a detectar sonolência e no fundo cinza escuro é onde o paciente está dormindo.

O fato do sistema conseguir prever o estado de sono para este paciente sugere que informações de mais pacientes sejam analisadas para atestar se a metodologia implementada pode prever na maioria das vezes o estado de sono antes deste acontecer.

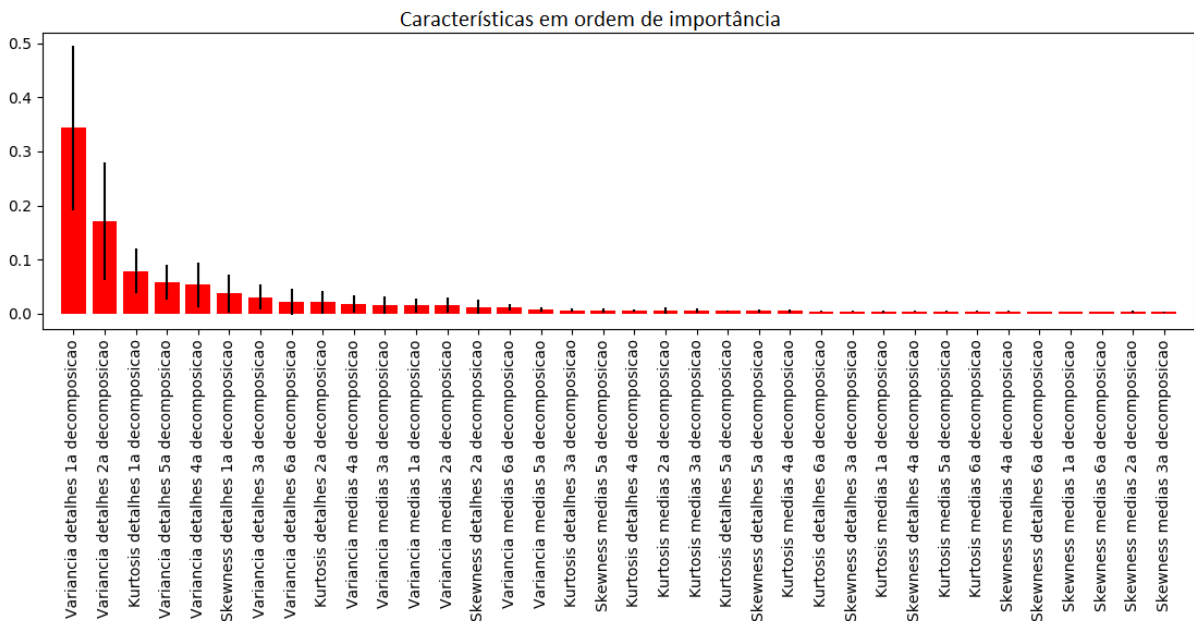
Após o treino do classificador pode-se verificar quais foram as características que mais influenciaram o florestas aleatórias na hora de decidir se a classe era W ou SLP. A figura 4.3 mostra as características por ordem de importância para o treino sem o paciente 00 citado anteriormente. As três mais significativas são: a variância no ritmo baixo-gama, a variância no ritmo beta e a curtose também na banda baixo-gama. Além disso, foi verificada a característica mais significativa para cada um dos arquivos de sinais e em todos os casos a variância é dada como a característica mais relevante para o classificador.

Figura 4.2 – Ampliação da segunda e terceira transição de W para SLP vista na figura 4.1.



Fonte: Autor.

Figura 4.3 – Gráfico de características por importância para o treino do classificador sem o paciente 00 na segunda noite de gravação. As características mais relevantes são respectivamente a variância em baixo-gama, variância em beta e curtose em baixo-gama.

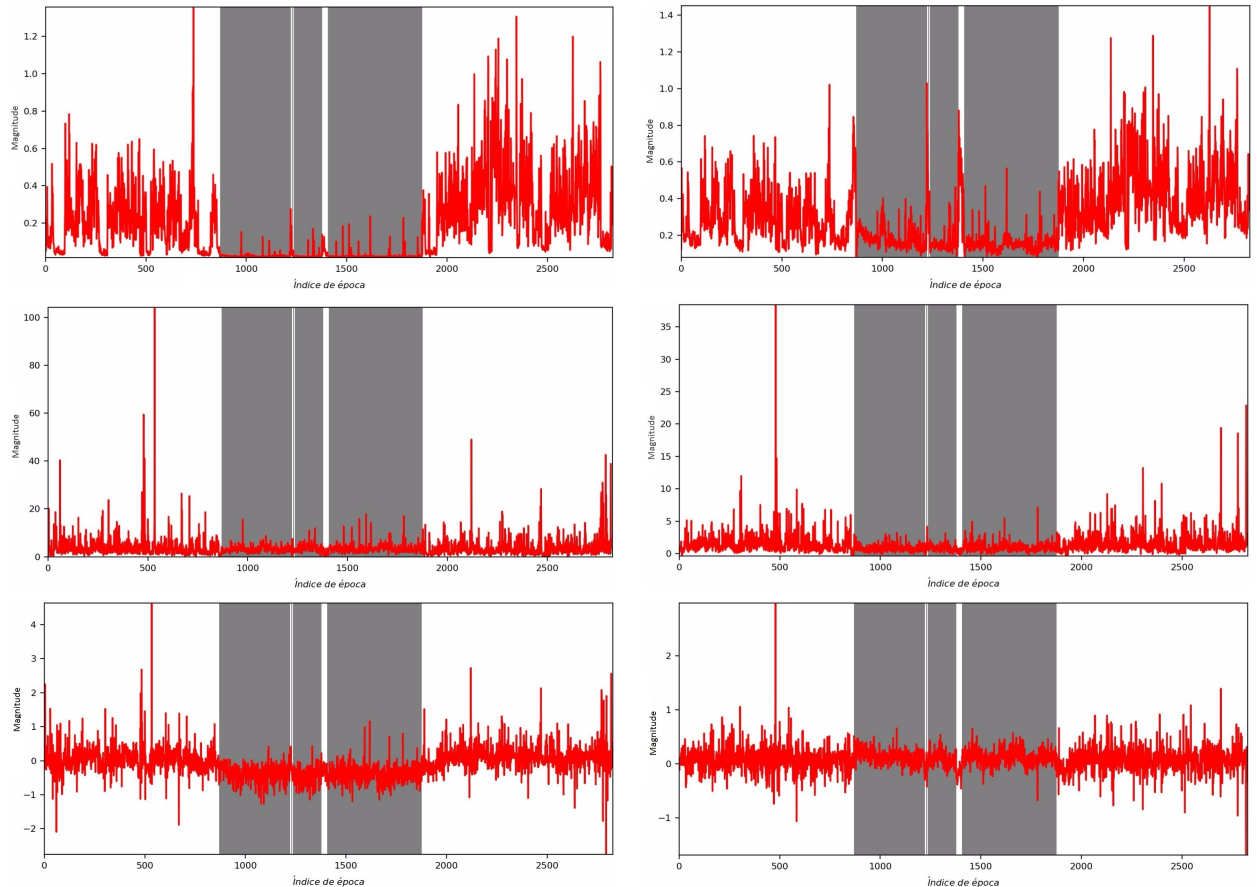


Fonte: Autor.

A variância é a característica mais significativa também para a classificação antecipada do estado SLP. Podemos perceber pela figura 4.4 que esta varia muito, em relação

as outras características, na transição do estado acordado para dormindo e, normalmente a variação começa com pelo menos uma época de antecedência o que permite que o classificador comece a detectar sonolência antes do paciente dormir.

Figura 4.4 – Gráficos da variância, curtose e assimetria respectivamente para os ritmos Baixo-gama e Beta.



Fonte: Autor.

4.1 RESULTADOS PARCIAIS DA IMPLEMENTAÇÃO EM TEMPO REAL


O sistema de classificação implementado na Orange Pi Zero mostrou-se eficiente para um sistema de detecção em tempo real. Isto porque, um arquivo de sinal com 2.829 épocas, por exemplo, obtém o resultados da classificação para todas as épocas em 18,6 minutos, o que nos dá em média 394,5 ms por época.

Ainda, o banco de dados utilizado neste trabalho obteve os sinais de EEG na frequência de 100 Hz. Para comprovarmos que o sistema implementado pode operar eficientemente dentro deste período de amostragem (0,01 segundos) foi feito um teste. Este, consistiu em fazer a leitura dos dados dos arquivos de sinais com um atraso de 0,01

s entre cada sinal lido e, a classificação destes quando uma época completa havia sido lida (3000 pontos). Como já poderíamos inferir pelas informações do parágrafo anterior, o tempo para classificação dos sinais foi bem menor que o tempo de aquisição do dados. A figura 4.5 mostra a variância, curtose e assimetria no ritmo alfa para as primeiras épocas da segunda noite de gravação do paciente 00. Nela podemos ver o tempo gasto desde que o programa começou a leitura de dados até a classificação (linha vertical), para cada uma das 13 primeiras épocas. O tempo gasto pode ser explicado primeiro pelos 30 segundos de atraso inserido entre cada leitura do sinal, segundo pelo tempo médio de 400 ms para processar uma época e terceiro pelo tempo necessário para ler os 72 pontos (0,72 s) da época seguinte que a metodologia implementada exige.

Por fim, o tempo de resposta médio encontrado é considerado bom para um sistema de classificação de sonolência em tempo real. Isto nos diz que a substituição do banco de dados pelo sistema de aquisição de sinais de eletroencefalograma se dará de forma eficiente.

Figura 4.5 – Gráficos da variância, curtose e assimetria com os momentos para a classificação das primeiras 13 épocas da segunda noite de sono do paciente 00, simulando a leitura dos sinais à 100 Hz. A linha vertical indica o fim de uma época com o tempo gasto para executá-la.



Fonte: Autor.

5 CONCLUSÃO

Neste trabalho foi proposta a implementação de uma metodologia de extração e classificação de características para detecção dos estados acordado (W) e dormindo (SLP), a partir de sinais de eletroencefalograma (EEG) oriundos de um banco de dados público, em um sistema embarcado funcionando em tempo real. Estes sinais foram divididos em épocas e em seguida filtrados através da transformada wavelet discreta de Daubechies nas faixas de frequência baixo-gama, beta, alfa, teta e delta. A partir disso foram extraídas as características estatísticas variância, curtose e assimetria e em seguida feita a classificação em W e SLP.

Pela matriz de confusão gerada a partir da classificação das 106.285 épocas contendo mais de 20 horas de gravação, obteve-se uma acurácia de 97,01%, comprovando que a implementação do método em tempo real em um sistema embarcado não resultou em alterações consideráveis na performance da classificação. Além disso, percebeu-se que os dados classificados como SLP e que na verdade eram W podem ser utilizados como um alerta antes mesmo do sujeito entrar no estágio de sonolência, já que o classificador detectou a sonolência com pelo menos uma época de antecedência na maioria das transições de W para SLP para o paciente analisado. Este fato pede que mais pacientes sejam analisados para que se possa determinar a eficiência da metodologia na detecção prévia do estado de sono. Além de que, comprovou-se que a variância é a característica que mais influencia na decisão do classificador, inclusive nos casos de detecção antecipada. Por isso, outras características devem ser estudadas para que se possa melhorar a acurácia nestes casos.

Os resultados parciais obtidos mostram que a metodologia implementada poderá operar muito bem na aplicação em tempo real, onde o circuito em desenvolvimento que contém o conversor ADS1299-4 fará a aquisição dos sinais de EEG e o processamento é feito pela orange pi zero. Portanto, de forma geral, a implementação desenvolvida obteve um bom desempenho de classificação e possui flexibilidade para mudanças futuras, principalmente na possibilidade de tornar a aquisição e o processamento em tempo real.

5.1 TRABALHOS FUTUROS

A análise dos resultados desta fase da investigação sugere os seguintes temas para continuidade da pesquisa:

- Estudar a possibilidade de redução do tamanho de uma época, ou seja, reduzir o tempo de 30 segundos para um período menor para que se possa ter um melhor

monitoramento de um sujeito;

- Aplicação da técnica em sinais de EEG adquiridos por sensores, em tempo real;
- Investigação dos erros que o classificador obteve, tanto para melhorar a acurácia, quanto para reduzir o número de falsos positivos. Verificar se há alguma relação entre classificações falsas e o estágio de sono do paciente, por exemplo;
- Melhoria na implementação apresentada para que se tenha melhor performance e menor consumo de energia, como o uso da GPU e a utilização de um sistema operacional mais adequado para aplicações em tempo real.

REFERÊNCIAS BIBLIOGRÁFICAS

AGGARWAL, C. C. **DATA CLASSIFICATION: ALGORITHMS AND APPLICATIONS**. 1. ed. [S.I.]: CHAPMAN AND HALL/CRC, 2014. (CHAPMAN E HALL/CRC DATA MINING AND KNOWLEDGE DISCOVERY SERIES). ISBN 978-1-4665-8675-8,978-1-4665-8674-1.

BREIMAN, L. Random forests. **KLUWER ACADEMIC PUBLISHERS. MANUFACTURED IN THE NETHERLANDS.**, v. 45, p. 5–32, 2001.

CURRAN, E.; STOKES, M. Learning to control brain activity: A review of the production and control of eeg components for driving brain–computer interface (bci) systems. **ELSEVIER SCIENCE (USA)**, v. 51, n. 3, p. 326–336, 2003.

DIAZ-URIARTE, R.; ANDRES, S. A. D. Gene selection and classification of microarray data using random forest. **BMC BIOINFORMATICS**, v. 7, n. 1, p. 1–13, 2006.

EOH MIN K. CHUNG, S.-H. K. H. J. Electroencephalographic study of drowsiness in simulated driving with sleep deprivation. **INTERNATIONAL JOURNAL OF INDUSTRIAL ERGONOMICS**, v. 35, n. 4, p. 307–320, 2005.

GOLDBERGER, A. L. Physiobank, physiokit, and physionet: Components of a new research resource for complex physiologic signals. **CIRCULATION**, v. 101, n. 23, p. 215–220, 2000.

GRUNWALD, P. D.; RISSANEN, J. **THE MINIMUM DESCRIPTION LENGTH PRINCIPLE**. [S.I.]: MIT PRESS, 2007. (ADAPTIVE COMPUTATION AND MACHINE LEARNING). ISBN 0262072815,9780262072816,9781429465601.

KAWALA-JANIK, A.; PELC, M.; PODPORA, M. Method for eeg signals pattern recognition in embedded systems. **ELEKTRONIKA IR ELEKTROTECHNIKA**, v. 21, n. 3, p. 3–9, 2015.

KHAN, M. J. et al. Drowsiness detection using fnirs in different time windows for a passive bci. p. 227–231, June 2016.

LIANG, Y. et al. Prediction of drowsiness events in night shift workers during morning driving. **ACCIDENT ANALYSIS AND PREVENTION**, 2017. ISSN 0001-4575. Disponível em: <[HTTP://WWW.SCIENCEDIRECT.COM/SCIENCE/ARTICLE/PII/S0001457517303913](http://www.sciencedirect.com/science/article/pii/S0001457517303913)>.

LIN, C. T. et al. **DEVELOPMENT OF WIRELESS BRAIN COMPUTER INTERFACE WITH EMBEDDED MULTITASK SCHEDULING AND ITS APPLICATION ON REAL-TIME DRIVER'S DROWSINESS DETECTION AND WARNING**. 2008. 1582-1591 p.

LIN FELLOW, I. R.-C. W. S.-F. L. W.-H. C. Y.-J. C. C.-T.; JUNG, T.-P. Eeg-based drowsiness estimation for safety driving using independent component analysis. **IEEE TRANSACTIONS ON CIRCUITS AND SYSTEMS**, v. 42, n. 12, p. 2726 – 2738, 2005.

ORANGEPIZERO. **ORANGE PI ZERO**. ONLINE, 2016. ACESSO EM 06 JUL. 2017. Disponível em: <[HTTP://WWW.ORANGEPI.ORG/ORANGEPIZERO/](http://www.orange-pi.org/orangepi-zero/)>.

PHYSIONET. **THE SLEEP-EDF-X DATABASE**. 2013. ACESSADO EM 10 JUN 2017. Disponível em: <[HTTP://WWW.PHYSIONET.ORG/PHYSIOBANK/DATABASE/SLEEP-EDFX.](http://www.physionet.org/physiobank/database/sleep-edfx/)>

SAHAYADHAS, K. S. A.; MURUGAPPAN, M. Detecting driver drowsiness based on sensors: A review. **DOI:10.3390/S121216937**, v. 12, n. 12, p. 16937–16953, 2012.

SANEI, S.; CHAMBERS, J. A. **EEG SIGNAL PROCESSING**. [S.l.]: JOHN WILEY E SONS, 2007. ISBN 0470025816,9780470025819.

SCIKIT-LEARN DEVELOPERS. **SKLEARN.ENSEMBLE.RANDOMFORESTCLASSIFIER**. 2017. ACESSADO EM 06 NOV 2017. Disponível em: <[HTTP://SCIKIT-LEARN.ORG/STABLE/MODULES/GENERATED/SKLEARN.ENSEMBLE.RANDOMFORESTCLASSIFIER.HTML](http://scikit-learn.org/stable/modules/generated/sklearn.ensemble.randomforestclassifier.html)>.

SENTHILKUMAR, G.; GOPALAKRISHNAN, K.; KUMAR, V. S. Embedded image capturing system using raspberry pi system. **INTERNATIONAL JOURNAL OF EMERGING TRENDS AND TECHNOLOGY IN COMPUTER SCIENCE**, v. 3, n. 2, p. 213–215, 2014.

SHELTON, J.; KUMAR, G. P. **COMPARISON BETWEEN AUDITORY AND VISUAL SIMPLE REACTION TIMES**. 2010. 30-32 p.

SHIN, K.; RAMANATHAN, P. Real-time computing: A new discipline of computer science and engineering. **CIRCULATION**, v. 82, n. 1, p. 6–24, 1994.

SILVEIRA, P. R. **O ELETROENCEFALOGRAMA SIMPLES (EEG)**. 2009. ACESSADO EM 03 DEZ 2017. Disponível em: <<http://www.recantodasletras.com.br/artigos/1616421>>

SILVEIRA, T. L. T. D. **CLASSIFICAÇÃO DE ESTÁGIOS DE SONO ATRAVÉS DA APLICAÇÃO DE TRANSFORMADA WAVELET DISCRETA SOBRE UM ÚNICO CANAL DE ELETROENCEFALOGRAMA**. 2016. 92 F. Monografia (DISSERTAÇÃO DE MESTRADO) — CURSO DE MESTRADO PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA (PPGI), UNIVERSIDADE FEDERAL DE SANTA MARIA, SANTA MARIA, 2016.

VIDAKOVIC, B.; MUELLER, P. Wavelets for kids: A tutorial introduction. **DUKE UNIVERSITY**, 1994.

ZHU, Y. L. G.; WEN, P. P. Analysis and classification of sleep stages based on difference visibility graphs from a single-channel eeg signal. **IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS**, v. 18, n. 6, p. 1813–1821, 2014.