

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

**JULIA MANAYRA DA SILVA FERREIRA**

**CLASSIFICAÇÃO DOS ESTÁGIOS DO SONO UTILIZANDO ANÁLISE  
ESPECTRAL E REDES NEURAIIS CONVOLUTIVAS**

São Luís  
2018

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

Manayra da Silva Ferreira, Julia.

CLASSIFICAÇÃO DOS ESTÁGIOS DO SONO UTILIZANDO ANÁLISE  
ESPECTRAL E REDES NEURAIIS CONVOLUTIVAS / Julia Manayra da  
Silva Ferreira. - 2018.

64 f.

Orientador(a): Luciano Reis Coutinho.

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

1. Classificação do Sono. 2. Estagiamento Automático  
do Sono. 3. Multitaper. 4. Redes Neurais Convolutivas.  
I. Reis Coutinho, Luciano. II. Título.

**JULIA MANAYRA DA SILVA FERREIRA**

**CLASSIFICAÇÃO DOS ESTÁGIOS DO SONO UTILIZANDO ANÁLISE  
ESPECTRAL E REDES NEURAIAS CONVOLUTIVAS**

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. Luciano Reis Coutinho

São Luís

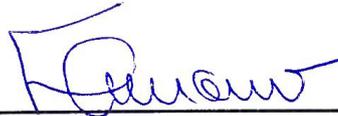
2018

**JULIA MANAYRA DA SILVA FERREIRA**

**CLASSIFICAÇÃO DOS ESTÁGIOS DO SONO UTILIZANDO ANÁLISE  
ESPECTRAL E REDES NEURAS CONVOLUTIVAS**

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. Luciano Reis Coutinho

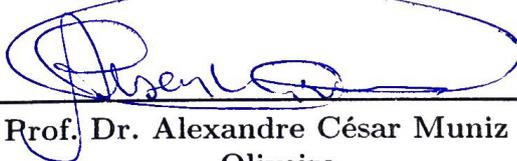
Aprovada em 17/12/2018



---

**Prof. Dr. Luciano Reis Coutinho**  
(Orientador)

Universidade Federal do Maranhão



---

**Prof. Dr. Alexandre César Muniz de  
Oliveira**  
Examinador 1



---

**Prof. Dr. Geraldo Braz Júnior**  
Examinador 2

São Luís

2018

# Agradecimentos

Agradeço a Deus, que me possibilitou vivenciar toda experiência maravilhosa e emocionante de fazer algo que amo, de me proporcionar momentos de alegria, tristeza e principalmente conquistas que pude desfrutar durante o andamento do curso. Por colocar em minha vida as pessoas certas para me motivar nos momentos que me senti para baixo, agradeço por sempre por me guiar e cuidar de mim.

À Universidade Federal do Maranhão (UFMA), que me proporcionou o desenvolvimento necessário para este momento, com profissionais dispostos a ensinar o caminho para o bom profissional da área de ciência da computação e, a oportunidades de participar do Programa de Educação Tutorial entre os anos de 2013 a 2015, e de ter sido eleita Presidente do Diretório Acadêmico de Ciência da Computação no ano de 2014. Ao Laboratório de Sistemas Inteligentes que proporcionou o equipamento necessário para a realização dos experimentos deste trabalho.

Ao meu orientador, Prof. Dr. Luciano Reis Coutinho, pela oportunidade de desenvolver este projeto que para mim foi desafiador, por acreditar em mim e me apoiar, direcionar e orientar, por sempre estar disposto a tirar dúvidas e, inspirar a me desenvolver cada vez mais em minha vida profissional. Gostaria de agradecer ao meu amigo Ivan Pereira por sempre estar disposto a me auxiliar nos dias em que precisei consultá-lo e na realização dos experimentos deste projeto.

Aos Programadores de Elite, meus melhores amigos e colegas de curso, Lucas Gabriel, Tércio Almeida, Márcio Franklin, Alexsandro Saraiva, Alysson Cirilo, Ricardo Marques, Marcos Vinícios, André Felipe, Rodrigo Kanehisa e Alexandre Pessoa. Aos meus amigos de curso e trabalho Hugo Gois, Erick Vinicius e Wellington Ferreira. Agradeço pelas noites não dormidas, momentos de alegria e descontração, os momentos de motivação mútua e dedicação que compartilhamos, sou grata por conhecer pessoas tão maravilhosas que me abraçaram como irmã, aprendendo e ensinando juntos.

Aos meus melhores amigos de infância, Diego Cutrim e Jorge Tiago, com os quais passei vários momentos felizes e tristes onde me apoiaram e me fizeram sorrir. Em especial, a Diego que desde que ouviu meu sonho em fazer o curso de ciência da computação não hesitou em sonhar junto comigo; acreditando num sonho que pra mim parecia distante. A minha família, em destaque as duas pessoas que mais me inspiraram, minha mãe Jôsy Silva, que me ensinou a sempre correr atrás de meus sonhos e não desistir das adversidades, sempre me apoiando nos momentos de dificuldade. Agradeço por ter alguém tão especial como minha mãe, em segundo meu tio, Prof. Msc. Josenildo Costa, que é como um pai, professor e amigo, que me inspira, motiva e eleva, e que me apoiou neste trabalho, obrigado

por me guiar neste projeto. Não poderia deixar de agradecer ao meu irmão Luan Jônatas que é também um amigo, e meu padastro Luis Marcelo que sempre acreditaram e confiaram em minhas capacidades.

Ao meu namorado Luiz Carlos, que nunca hesitou em acreditar em mim mesmo quando eu não acreditava, por me motivar e estar ao meu lado nestes últimos 4 anos, por sempre compreender quando precisei me ausentar no desenvolvimento deste projeto, me incentivando sempre a crescer como uma profissional de qualidade, agradeço por acreditar nos meus sonhos e me dar forças para correr atrás deles.

Aos meus chefes Dr. Cícero Matias, Jonathan Montelvane Silva Ferreira e Nilton Carlos, que acreditaram e me apoiaram nos dias que precisei desenvolver este projeto, sou grata à compreensão e incentivo para o meu crescimento profissional e educacional. Aos meus colegas de trabalho Daniel Diniz, Frederico Queiroz e Jamerson da Silva pelo incentivo a realização de mais essa etapa na minha vida.

*"O sucesso é a soma  
de pequenos esforços  
repetidos dia após dia."*

(Robert Collier)

# Resumo

Distúrbios do sono como apneia do sono, insônia e hipersônia idiopática estão associados aos maiores problemas de saúde da sociedade moderna e afetam a saúde e a qualidade de vida das pessoas, ocasionando depressão, estresse, diabetes, déficit de atenção, obesidade, problemas cardiovasculares, entre outros. No entanto, o processo para detecção de distúrbios do sono é um processo moroso e caro, pois há necessidade de profissionais especializados, que tenham capacidade. Através de exames como a polissonografia, é possível identificar sinais que possam indicar uma disfunção na atividade fisiológica do paciente. Este terá de avaliar vários canais captados no exame e identificar os estágios do sono (REM, N1, N2, N3). Desta forma, é capaz de determinar um diagnóstico para um paciente. Por conseguinte, o principal objetivo deste trabalho é contribuir com o estudo da classificação automática dos estágios do sono, a partir de um estudo comparativo entre os trabalhos relacionados a rotulação dos estágios. Nesse trabalho, foi utilizado o método *multitaper* uma vez que ele supera algumas das limitações da análise convencional da transformada de Fourier, ao reduzir o bias de estimação obtendo múltiplas estimativas de uma mesma amostra. Além disso, converter o sinal em imagem e assim utilizá-los como entrada para Redes Neurais Convolutivas que têm se mostrado muito eficazes na classificação de imagens. Neste trabalho foram realizados dois experimentos onde o primeiro utilizou um único sinal EEG o Fpz-Cz e o segundo utilizou um único sinal EEG C4-A1, assim utilizados na geração de imagens e para classificação a rede convolutiva Inception-V3 que no primeiro experimento obteve 0.8726% de acurácia, 0.8736% de precisão, 0.8742% sensibilidade e 0.8684% de F1-score e no segundo obteve 0.8595% de precisão, 0.8604% sensibilidade, acurácia de 86% e 0.8576% de F1-score.

**Palavras-chave:** Classificação do Sono; *Multitaper*; Redes Neurais Convolutivas; Estagiamento Automático do Sono.

# Abstract

Sleep disorders such as sleep apnea, insomnia and idiopathic hypersomnia are associated with the major health problems of modern society and affect people's health and quality of life, leading to depression, stress, diabetes, attention deficit, obesity, cardiovascular problems, among others. However, the process for detecting sleep disorders is a time consuming and costly process as there is a need for skilled professionals who have the capacity. Through tests such as polysomnography, it is possible to identify signs that may indicate a dysfunction in the patient's physiological activity. This will have to evaluate several channels captured in the exam and identify the stages of sleep (REM, N1, N2, N3). In this way, it is able to determine a diagnosis for a patient. Therefore, the main objective of this work is to contribute to the study of the automatic classification of the sleep stages, based on a comparative study between the works on automatic sleep staging approach. In this work, the textit multitaper method was used since it overcomes some of the limitations of conventional Fourier transform analysis. *Multitaper* reduces the estimation bias via multiple estimates of the same sample. It also converts the signal into an image, which is used as input for a Convolution Neural Networks. In this work two experiments were performed using a single EEG signal to generate the images. In the first one we used the Fpz-Cz as input and the second one we used C4-A1. In both experiments settings we applied the convolutional network Inception-V3, obtaining 0.8726 % accuracy, 0.8736 % sensitivity, and 0.8684 % F1-score in the first experiment and obtaining 0.8595 % accuracy, 0.8604 % sensitivity, 86 % accuracy and 0.8576 % F1 -score on the second experiment.

**Keywords:** Sleep Classification; Multitaper; Convolutional Neural Networks; Automatic Sleep Staging.

# Lista de ilustrações

Figura 1 – Trabalhos realizados entre 1999 e 2018 . . . . .	20
Figura 2 – Exame de Polissonografia . . . . .	23
Figura 3 – Posicionamento dos eletrodos . . . . .	24
Figura 4 – Sinais de exemplo . . . . .	25
Figura 5 – Representação do Sistema Internacional . . . . .	26
Figura 6 – Canais EEG . . . . .	27
Figura 7 – Comparação entre periodograma e <i>multitaper</i> . . . . .	30
Figura 8 – Neurônio artificial por McCulloch-Pitts . . . . .	33
Figura 9 – Modelo de Rede Neural Artificial . . . . .	33
Figura 10 – Rede Neural Artificial de 4 Camadas . . . . .	34
Figura 11 – Rede Neural LeNet . . . . .	35
Figura 12 – Convolução especificado em LeNet . . . . .	36
Figura 13 – Pooling especificado em LeNet . . . . .	39
Figura 14 – Camada completamente conectada, especificada em LeNet . . . . .	39
Figura 15 – Rede Neural Inception-V3 . . . . .	40
Figura 16 – Módulo de uma inception . . . . .	41
Figura 17 – Mini-rede representando convolução 5x5 . . . . .	42
Figura 18 – Metodologia . . . . .	43
Figura 19 – Representação do Chronux . . . . .	46
Figura 20 – <i>Multitaper</i> gerado pelo Chronux . . . . .	47

# Lista de tabelas

Tabela 1 – Divisão de faixas de frequência . . . . .	27
Tabela 2 – Estágios do Sono . . . . .	29
Tabela 3 – Resultados da Metodologia . . . . .	49
Tabela 4 – Resultados da Metodologia . . . . .	49
Tabela 5 – Comparação dos resultados com VGG-FT . . . . .	49
Tabela 6 – Comparação dos resultados com VGG-FT . . . . .	50
Tabela 7 – Comparação dos resultados obtidos com trabalhos relacionados . . . . .	51

# Lista de abreviaturas e siglas

ANN	<i>Artificial Neural Network</i>
CNN	<i>Convolutional Neural Network</i>
EOG	Eletrooculograma
EMG	Eletromiograma
EEG	Eletroencefalograma
ECC	Eletrocardiograma
N1	Estágio do sono Não-REM 1
N2	Estágio do sono Não-REM 2
N3	Estágio do sono Não-REM 3
MLP	<i>Multilayer Perceptron</i>
REM	<i>Estágio do sono REM, Rapid Movement Eye</i>
UFMA	Universidade Federal do Maranhão

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	Objetivos	16
1.2	Trabalhos Relacionados	17
1.3	Estrutura do Trabalho	19
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>21</b>
2.1	Sono	21
2.2	Polissonografia	23
2.2.0.1	EEG (Eletroencefalograma)	25
2.2.1	Estágios do Sono	28
2.3	<i>Análise Espectral</i>	29
2.3.1	O Método <i>Multitaper</i>	30
2.4	Redes Neurais	31
2.4.1	Redes Neurais Convolutivas	35
2.4.2	Inception V3	39
<b>3</b>	<b>METODOLOGIA</b>	<b>43</b>
3.1	Dados PhysioNet	44
3.2	Dados SHHS-1	44
3.3	Pré-processamento	45
3.4	Experimentos	46
<b>4</b>	<b>RESULTADOS</b>	<b>48</b>
4.1	Resultados da Metodologia	48
<b>5</b>	<b>CONCLUSÃO</b>	<b>53</b>
5.1	Trabalhos Futuros	53
	<b>REFERÊNCIAS</b>	<b>55</b>

# 1 INTRODUÇÃO

O sono é uma necessidade básica, e tão intimamente ligada a nossa rotina que, muitas vezes, se torna algo facilmente negligenciado. Comumente, não damos a devida importância à sua regularidade. Trata-se de um fenômeno ativo, no qual o organismo está em um estado de repouso e também presente na fisiologia da maioria dos seres vivos. Este, por sua vez, é responsável pela liberação de diversas substâncias e reações químicas (POYARES; ANDRÉ; PALOMBINI, 2018) que mantêm o equilíbrio do organismo. Em seres humanos, é responsável pela fixação da memória, restauração do metabolismo cerebral (FERRARA; GENNARO, 2001), termorregulação do corpo, restauração da energia (REIMÃO, 1996) e, em crianças, é o momento da liberação do hormônio do crescimento.

Em Al-Shaikh (2016), é levantada a dimensão da qualidade do sono e seus efeitos na saúde. Um estudo internacional realizado por Liu et al. (2013) nos EUA, mostrou que 69,4% de uma amostra total de 375,653 adultos sofrem de algum tipo de distúrbio do sono, e um estudo realizado na Coreia por Ryu, Kim e Han (2011), mostrou que cerca de 37,2% de uma amostra total de 4.411 adultos tiveram problemas com o sono.

No Brasil, em um estudo realizado por Zanuto et al. (2015), foi analisado os distúrbios do sono em adultos na cidade de São Paulo, entre pessoas com idade média de 17,3 e 49,9 anos. Neste estudo, foram observados distúrbios relacionados ao sono em 46,7% dos entrevistados de uma amostra total de 743 adultos. Diante disso, Al-Shaikh (2016) demonstra que a não regularidade e a falta de manutenção no sono, trazem sérios riscos ao equilíbrio fisiológico do organismo, bem como à saúde. Ou seja, a falta de repouso afeta o equilíbrio, a concentração, o bem-estar, lucidez e aumentam o nível de stress, interferindo fortemente de forma negativa no desempenho profissional, familiar, social e escolar, de modo que, desenvolver tarefas simples se tornam muito complicadas (MÜLLER; GUIMARÃES, 2007).

Dentre os distúrbios mais comuns, relacionados ao sono, estão a insônia, a apneia do sono (OHAYON; ROTH, 2002) e a excessiva sonolência diurna (REIMÃO, 1996) entre outros. Além de outras disfunções como a depressão, diabetes, obesidade e colesterol alto. Assim, pessoas com estes distúrbios tendem a consumir mais tabaco e álcool (JANSON et al., 2001), o que os pode torná-los dependentes, desencadeando mais problemas à saúde.

Nessa conjuntura, Em Togeiro e Smith (2005), é apresentada as três técnicas mais utilizadas para a detecção dos distúrbios do sono: Os questionários que consistem em realizar uma série de perguntas sobre a higiene do sono, e os hábitos do paciente quando dorme. Para tanto, usa-se a actigrafia, que trata-se de uma técnica de avaliação do ciclo

sono-vigília, que permite o registro da atividade motora, com o auxílio de um aparelho colocado no pulso do paciente. Dessa forma, tal dispositivo monitora os movimentos dos membros do paciente durante 24 horas. Desse modo, a polissonografia, técnica que é considerada o padrão ouro na detecção de distúrbios do sono, pois através dela é possível ter uma visão de diversas atividades do corpo em um só exame. Sendo possível a realização do monitoramento da atividade cerebral, do movimento dos olhos, movimento muscular e respiratório, que possui em média 7 dispositivos monitorando os sinais vitais do organismo.

Os especialistas do sono classificam o sono, como proposto por Rechtschaffen (1968), onde este é dividido em sono REM (*Rapid Eye Movements*) e Não-REM que é formado pelos estágios N1, N2 e N3, onde o momento em que o paciente se encontra acordado é chamado de Vigília. Silva (1996), descreve o padrão do sono normal, que é constituído de ciclos de sono-vigília que variam entre o sono N-REM até o sono REM, que se repetem de 4 a 6 vezes durante o sono. No entanto, a noite de sono é alternada entre os estágios do sono e os despertares, estes últimos ocupando cerca de 5% do total do sono, e os estágios N-REM ocupam cerca de 75 a 80% do tempo dormido, destes o estágio N1 ocupa cerca de 2 a 5%, o N2 ocupa cerca de 45 a 55% e os estágios N3 e N4, que hoje compreende-se como um único estágio N3, ocupa cerca de 7 a 18%. Nesse contexto, o sono REM ocupa cerca de 20 a 25% do sono total (CARSKADON; DEMENT et al., 2005).

- Vigília (Acordado): neste estágio é comum a atividade tônica muscular a presença de movimentos rápidos dos olhos.
- N1: começo do sono, aonde é realizada as transições de estágios e presença de movimentos lentos nos olhos.
- N2: sono leve e ausência de movimentos nos olhos.
- N3: ausência de movimentos nos olhos, sono profundo, lento e quieto.
- REM: presença de movimentos rápidos dos olhos, sono profundo, leve e rápido.

Apesar dos distúrbios do sono serem comuns na vida das pessoas, ainda não é uma tarefa simples a detecção e diagnósticos dos mesmos. Nesse sentido, a polissonografia é a técnica mais utilizada pelos especialistas por ser completa. Porém, este é um recurso de alto custo, exigindo total concentração, tempo e atenção técnica, tornando a análise dos sinais dispendiosa.

Para a análise dos exames, o profissional deve fazer uma classificação individual de cada canal captado no exame manualmente, marcando os estágios do sono na série temporal. Tornando esta tarefa enfadonha e massante. À vista disso, estudos relacionados a classificação automática dos estágios do sono, têm ganhado espaço a fim de auxiliar estes profissionais.

Durante a polissonografia, são captados diversos dados do paciente, como seus sinais cerebrais, através do EEG (Eletroencefalograma). O movimento dos seus olhos EOG (Eletrooculograma), o espasmos de seus músculos da face e pernas durante o sono através do EMG (Eletromiograma), entre outros. Neste trabalho, será utilizado, mais especificamente, os dados do EEG (Eletroencefalograma).

O EEG (Eletroencefalograma) foi escolhido pois, os sinais bioelétricos da parte central do cérebro têm uma visualização da estrutura do sono melhor definida. Para Silva (1996), os melhores canais de identificação dos estágios do sono é adquirido através do EEG (Eletroencefalograma). Deste modo, é possível identificar as ondas elétricas emitidas à cada estágio. De acordo com o manual padrão do sono (RECHTSCHAFFEN; KALES, 1968), durante este exame é necessário utilizar-se apenas dois eletrodos para o registro das ondas cerebrais na polissonografia, sendo um de backup.

Por sua ótima visualização, Silva (1996) afirma que um único canal do EEG (Eletroencefalograma), é suficiente para detecção dos estágios. Dessa forma, neste trabalho é utilizado um único canal do EEG, com 1 arquitetura de rede convolutiva, utilizando *espectrogramas de frequência*, como entrada para a rede. Dito isso, a categorização dos estágios é realizado pela rede resultando assim em um estudo comparativo com outros trabalhos na literatura, como uma contribuição para o desenvolvimento do estudo nesta área.

Nesse sentido, as bases utilizadas para a implementação destas metodologias foram o *phisoNet*, o banco *sleep edf [extended]* (PHISIONBANK, 2018), amplamente utilizada na literatura e a base *The Sleep Heart Health Study* (SHHS) disponível no repositório online (QUAN et al., 1997) por este possuir um número expressivo de pacientes. A partir destes sinais, é possível extrair características a fim de classificar os estágios do sono. As técnicas mais utilizadas para extração de características são apresentadas em Aboalayon et al. (2016), que divide as técnicas encontradas na literatura em 4 categorias:

- Análise no domínio do Tempo. algumas técnicas mais utilizadas neste domínio são: Estática Padrão como exemplos de trabalhos que usaram essa técnica é possível citar Hassan e Bhuiyan (2016a), Hassan e Bhuiyan (2016b) e Aboalayon e Faezipour (2014), Cruzamento zero alguns trabalhos que usam esta técnica são Correa e Leber (2010), Şen et al. (2014) e Radha et al. (2014) e Parâmetros Hjorth na literatura e possível encontrar trabalhos que utilizaram esta técnica como Khalighi et al. (2013), Radha et al. (2014) e Gudmundsson, Runarsson e Sigurdsson (2005).
- Análise no domínio da Frequência. Algumas técnicas mais utilizadas neste domínio são: Análise Não Paramétrica na literatura encontram-se Huang et al. (2013), Lee, Chen e Chen (2009) e Lan et al. (2015) que usaram esta técnica, Análise Paramétrica utilizada nos trabalhos desenvolvidos por Correa e Leber (2010), Correa, Orosco e

Laciar (2014) e Kayikcioglu, Maleki e Eroglu (2015) e Entropia Espectral explorada em Şen et al. (2014), Radha et al. (2014) e Gudmundsson, Runarsson e Sigurdsson (2005).

- Domínio do tempo-frequência. Algumas técnicas mais utilizadas neste domínio são: Transformada de *Wavelets* utilizada na literatura por Jain et al. (2012), Fraiwan et al. (2010) e Schluter e Conrad (2010), Transformada Rápida de Fourier utilizada em Aboalayon et al. (2016), Decomposição do Modo Empírico desenvolvida em Li et al. (2009), Hassan e Bhuiyan (2016a) e Hassan e Bhuiyan (2016b) e *Multitaper* explorada por Vilamala, Madsen e Hansen (2017).
- Parâmetros Não-lineares e Análise de Complexidade. Algumas técnicas mais utilizadas nestes domínios são: Dimensão Fractal desenvolvida nos trabalhos de Şen et al. (2014), Radha et al. (2014) e Rodríguez-Sotelo et al. (2014), Entropia Aproximada utilizada por Rodríguez-Sotelo et al. (2014), Koley e Dey (2012) e Şen et al. (2014), Autoregressivo explorada por Khalighi et al. (2013), Kuo e Liang (2011) e Khalighi et al. (2011).

Em Vilamala, Madsen e Hansen (2017), é proposto um método para classificação dos estágios do sono. Realizando uma análise no domínio do tempo-frequência, utilizando o *multitaper*, que trata-se de uma das técnicas de transformação do sinal, para assim realizar a transformação em imagens visualmente interpretáveis de padrões do sono que serão discutidos mais a frente no capítulo 2 e na seção 2.3. Dessa forma, estas imagens são postas como entrada para uma rede Neural Convolutiva profunda, a *VggNet* desenvolvida por Simonyan K. e Zisserman (2014). Com base neste trabalho, busca-se realizar um estudo com a rede neural convolutiva profunda *Inception-V3*.

## 1.1 Objetivos

O objetivo deste trabalho é um estudo de classificadores e rede convolutivas, utilizando *multitaper* que será melhor discutido no capítulo 2 e na seção 2.3, para o estagiamento automático do sono. Este estudo será um comparativo com o trabalho realizado por Vilamala, Madsen e Hansen (2017) e Sors et al. (2018), utilizando outra rede para a classificação dos estágios do sono.

Destacam-se como objetivos específicos deste trabalho:

- Apresentar um estudo experimental da performance de redes neurais convolutivas em conjunto com a técnica de pré-processamento baseado em análise espectral multitaper aplicado ao problema do estagiamento do sono.

- Apresentar a análise espectral *multitaper* para melhorar o desempenho de classificação das fases do sono utilizando o sinal EEG.
- Realizar uma comparação com os trabalhos existentes.
- Usar a Rede Neural Convolutiva Profunda *Inception-V3* para extração de características e classificação.

## 1.2 Trabalhos Relacionados

Muitos trabalhos têm sido desenvolvidos para detecção automática dos estágios do sono, como visto em Aboalayon et al. (2016). Nele, foi proposta uma taxonomia das técnicas de processamento para o estagiamento do sono a fim de obter uma visão geral do progresso e os desafios dos métodos baseados em análise dos sinais EEG (Eletroencefalograma) bem como pré-processamento, extração e classificação. Em Farooq e Jain (2017) foi realizado uma revisão trabalhos que utilizaram redes neurais para a classificação dos estágios do sono, Boostani, Karimzadeh e Nami (2017) apresenta uma visão geral sobre dos métodos de pré-processamento, extração de características, seleção de características e classificação para estagiamento do sono, ambos realizados em 2017.

Alguns trabalhos que propuseram uma metodologia para classificação automática dos estágios usando redes neurais. Diante disso, analisando dados obtidos através da polissonografia, que foram encontrados na literatura ou citados no *review* de 2016 são: Şen et al. (2014), Correa, Orosco e Laciari (2014), Tsai et al. (2009), Fraiwan et al. (2011), Charbonnier et al. (2011), (ZOUBEK et al., 2007), Dursun et al. (2012), Huang, Sun e Cheng (2003), Jain et al. (2012), Chen, Wang e Wang (2013), Park, Park e Jeong (2000), Tafner et al. (1999).

Cita-se também, trabalhos que usam apenas um único canal do EEG (eletroencefalograma), como observado nos trabalhos de Hassan e Bhuiyan (2016a), Hassan e Bhuiyan (2016b), Correa e Leber (2010), Hsu et al. (2013), Liu et al. (2010). Destarte, na literatura encontra-se trabalhos que usaram os dados disponíveis no repositório *online* do *Physionet* (PHISIONBANK, 2018). Vistos nos trabalhos de Rodríguez-Sotelo et al. (2014), Ebrahimi et al. (2008), (PEKER, 2016) e o próprio *review* de 2016 (ABOALAYON et al., 2016). Estes foram trabalhos desenvolvidos até o ano de 2016.

A partir de 2017, outros trabalhos foram desenvolvidos para classificação automática dos estágios do sono, utilizando redes neurais. Diante disso, é possível citar Dong et al. (2018), Siddiqui e Chawla (2017) e Chriskos et al. (2017). Neste período, houveram aqueles que utilizaram apenas um canal do EEG (Eletroencefalograma) como Sors et al. (2018) que utilizou o banco *SHHS-1* disponível online em Quan et al. (1997), Garcia-Molina et al. (2017), e trabalhos que utilizaram os dados disponíveis no repositório do *Physionet*,

como PhisionBank (2018), Wei et al. (2017), Vilamala, Madsen e Hansen (2017), Sharma, Pachori e Upadhyay (2017), sendo estes trabalhos desenvolvidos nos últimos anos.

Abaixo serão destacados os trabalhos que propuseram classificadores baseados em redes neurais, e que realizaram sua classificação em 5 classes, utilizando um único canal EEG.

Na investigação feita por Ebrahimi et al. (2008) foram utilizados coeficientes de pacotes *Wavelet* como recurso de entrada para a rede neural. Este, obteve como resultado uma especificidade de aproximadamente 94,4%, uma sensibilidade de aproximadamente 84,2%, uma precisão de aproximadamente 93,0% e uma acurácia de aproximadamente 93%.

Já Peker (2016), realizou um método de aprendizado de máquina híbrida, consistindo de características não-lineares de valor complexo (CVNF) e uma Rede Neural de valor complexo (CVANN), realizando a classificação com a penas um sinal EEG (Eletroencefalograma). Obteve-se então, 9 características não-lineares, assim foram convertidos em um formato numérico de valor complexo usando um método de codificação de fase. Do mesmo modo, os atributos obtidos foram apresentados como entrada para a Rede Neural de valor complexo (CVANN). Obteve-se então, uma precisão de 91,57% e uma precisão de 93%.

Nessa conjuntura, um sistema que decompõe os segmentos do sinal EEG (Eletroencefalograma), de modo empírico (EMD), foi proposto por Hassan e Bhuiyan (2016a), extraindo vários recursos estatísticos baseados em momentos. O próximo passo foi o emprego do *Boosting* Adaptativo e Árvores de Decisão para a classificação.

Por conseguinte, o desempenho da extração de recursos foi analisado a partir de vários classificadores. Desta maneira, realizou a classificação para estagiamento em 2,3,4 e 5 classes de classificação. De modo que, a rede neural adotada em sua pesquisa não teve um bom desempenho comparado ao *AdaBoost*, sendo seu melhor classificador. Alcançou 88,62% para 6 classes, 90,11% para 5 classes, 91,2% para 4 classes, 93,55% para 3 classes e 97,73% para 2 classes de acurácia.

Pela primeira vez foi utilizado a Decomposição do Modo Ensemble Empírica completa, com *Adaptive Noise*(CEEMDAN), corroborada por Hassan e Bhuiyan (2016b). Utilizou também, *Bootstrap Aggregating* (*Bagging*) e árvores de decisão para a classificação dos estágios do sono.

Dessa maneira, o desempenho da extração de recursos foi analisado a partir de vários classificadores. E realizou-se a classificação para estagiamento em 2, 3, 4 e 5 classes de classificação. No entanto, a rede neural adotada em sua pesquisa não obteve um bom desempenho. Não comparado ao *Bagging*, que obteve melhor desempenho com 86,89% para 6 classes, 90,69% para 5 classes, 92,14% para 4 classes, 94,10% para 3 classes e 99,48% para 2 classes de accuracy.

Portanto, uma estratégia que transforma o espectro de tempo-frequência dinâmica, baseado na transformação de Hilbert-Huang e a matriz característica temporal, em dados significativos para as redes neurais convolutivas, foi desenvolvida por Wei et al. (2017), que resultou em acurácia média de 84,5%.

Visto que, a rede neural convolucional com 14 camadas foi desenvolvida por Sors et al. (2018) e, recebe como entrada épocas de 30s. Todavia, não realizou nenhum pré-processamento de sinal ou fase de extração de característica. Conquistando uma precisão de 87% e Cohen e Kappa de 80%.

O trabalho de maior relevância para este estudo foi Vilamala, Madsen e Hansen (2017) realizado em 2017, que gerou *multitapers*, que trata-se de um método de análise espectral de sinal, a fim de tornar os estágios visivelmente distintos entre si, para que a rede neural possa facilmente realizar o estagiamento. Para classificação, utilizou a *VggNet* uma rede neural convolutiva desenvolvida por Simonyan K. e Zisserman (2014) no ano de 2014, alcançando um resultado médio de 86% de acurácia, 93% de precisão, 78% de sensibilidade e 84% de F1-score.

Este trabalho têm como base Vilamala, Madsen e Hansen (2017), propondo um estudo de arquitetura de redes neurais convolutivas, mais precisamente a rede convolutiva Inception-V3 (VANHOUCKE SERGEY IOFFE, 2015). Como entrada para a rede são geradas imagens de *multitapers*, obtidas a partir de um único sinal EEG (Eletroencefalograma). Tal exame este realizado na polissonografia. Para a identificação dos estágios do sono as imagens serão classificadas em 5 classes (vigília, REM, N1,N2,N3).

Na Figura 1, é representado um gráfico dos que se propuseram a classificar os estágios do sono, utilizando redes neurais em suas soluções iniciando em 1999 até o presente momento. Através dele, possivelmente será notável um crescimento em pesquisas relacionadas ao problema proposto neste trabalho.

### 1.3 Estrutura do Trabalho

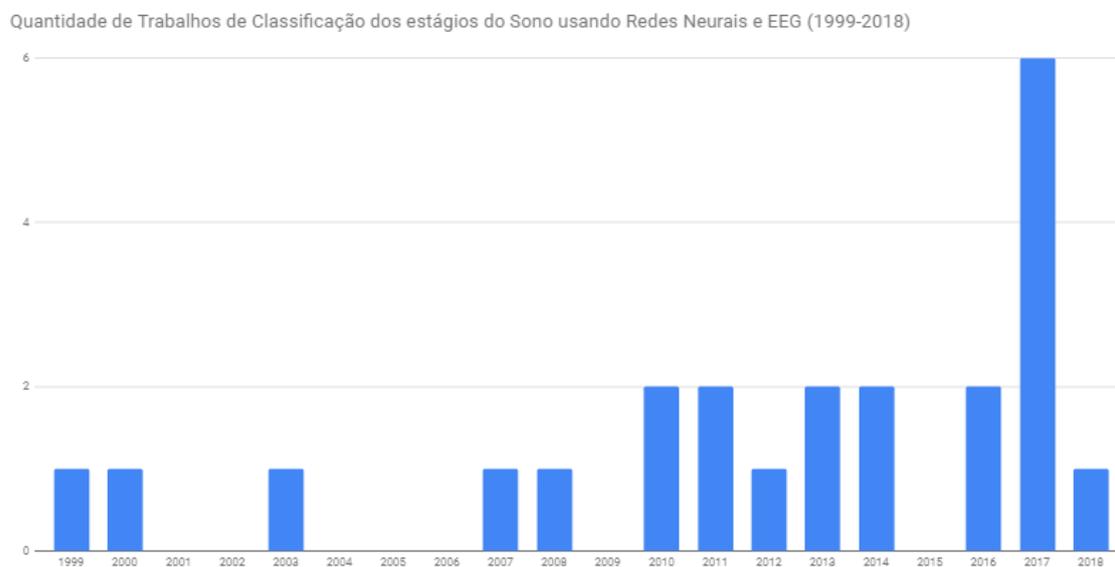
Este trabalho está organizado em cinco capítulos, de forma a apresentar o conteúdo mais claramente, conforme os parágrafos a seguir.

O Capítulo 2, é apresentada a fundamentação teórica necessária para compreensão e embasamento deste estudo.

O Capítulo 3, neste capítulo é descrita a metodologia utilizada neste trabalho, onde foram gerados espectrogramas utilizado o sinal EEG, como entrada para uma rede convolutiva.

O Capítulo 4, neste capítulo serão apresentados e discutidos os Resultados obtidos neste trabalho.

Figura 1 – Trabalhos Realizados entre 1999 e 2018 que se propuseram a realizar a Classificação dos Estágios do sono utilizando Redes Neurais



Fonte: Elaborado pelo Autor.

O Capítulo 5, neste capítulo é apresentada a Conclusão e os trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a fundamentação teórica utilizada no desenvolvimento deste trabalho, essencial para a compreensão das técnicas utilizadas na metodologia proposta para o reconhecimento dos estágios do sono. Desse modo, no decorrer do capítulo, é discutida a base para o desenvolvimento deste estudo, partindo da compreensão do que se trata o sono fisiologicamente e a técnica *multitaper*.

### 2.1 Sono

O sono é um fenômeno que têm despertado a curiosidade do ser humano há muito tempo, muitas lendas e tradições surgiram para tentar explicar e entender o sono. Filósofos conhecidos, como Aristóteles, já se questionavam sobre o funcionamento e a sua importância como discutido em Tufik (2008). Isto se dá por sua característica singular de alteração do nível de consciência do indivíduo.

Diante do interesse sobre o Sono, muitas teorias foram desenvolvidas ao longo tempo. Porém, as pesquisas modernas sobre este fenômeno começaram em meados do século XIX, pois até então não haviam meios, além da observação, dos movimentos do indivíduo. Dessa forma, com o surgimento das ferramentas eletrofisiológicas, pesquisas puderam se desenvolver e realizar descobertas a cerca do comportamento cerebral neste estado tão intrigante. Logo, estes foram essenciais ao estudo de biopotenciais de pequena amplitude de acordo com Martins, Mello e Tufik (2001).

Nesse âmbito, o estado de sonolência ocorre de maneira cíclica em grande parte dos seres vivos, tendo sido observados comportamento hora de repouso, hora de atividade. Deste modo, pode-se dizer que é um ciclo sono-vigília rudimentar, alguns animais aonde este comportamento é natural são os cachorros, gatos, aves e até os insetos. Com o avanço da caracterização do sono, por parâmetros eletrofisiológicos, foi registrado a atividade cerebral em anfíbios, répteis e mamíferos.

Por conseguinte, a tarefa de definir o sono não é fácil e muito menos simples, mesmo sob o ponto de vista fisiológico e baseado na descrição do indivíduo no estado de sonolência de acordo com Fernandes (2006). Pode-se definir o comportamento externo do indivíduo durante o período do sono como um estado de corpo imóvel ou com movimentos limitados, e de natureza involuntária, inconsciente e automática, não tendo um propósito específico para sua realização.

Nesse sentido, a resposta aos estímulos externos como auditivos, visuais, tácteis e dolorosos, são extintos ou reduzidos quando se fala de estado de vigília. Pois, no sono

profundo, é necessário um aumento aos estímulos externos para trazer o indivíduo de volta ao estado de vigília.

No entanto, durante o repouso do indivíduo, ele mantém-se com os olhos fechados ou cerrados não mostrando uma interação produtiva com o ambiente externo, podendo ser comparado ao estado de coma, no tocante da observação externa ao indivíduo, principalmente nos casos em que o coma não é profundo, sem comprometimento das funções cardio-respiratórias. Nessa situação, nota-se que a diferença mais sobressalente entre ambos os estados é a observação do comportamento do indivíduo, onde o sono têm uma característica particular de reversão espontânea ao estado de vigília ou mais ou menos programada, devido ao tempo de sono, respeitando um ciclo de sono-vigília. O que não é o caso do observado em indivíduos em coma, como explanado em Fernandes (2006).

Nesse cenário, o surgimento das ferramentas eletrofisiológicas foi essencial, pois as observações a respeito do sono eram limitadas a observar o comportamento externo do paciente. A partir dos registros da atividade elétrica cerebral realizada por CATON (1975) em 1875, observada em animais, pôde-se ter uma visão nova do sono. Dessa forma, o sono passou a ser visto não como um estado inerte, mas este se tratava de um estado ativo do organismo, e assim mais uma vertente para investigação das atividades cerebrais durante o sono surge (BUZSAKI, 2006), pois estes registros possibilitaram a percepção de padrões cíclicos recorrentes na atividade cerebral durante o sono.

Esta nova perspectiva do sono possibilitou que, mais tarde, em 1987, Loomis, Harvey e Hobart (1937) registrassem os sinais elétricos cerebrais de seres humanos. A partir das observações destes registros, foi possível notar que, durante o sono, os sinais elétricos tinham uma certa alternância de potência e amplitude. Destarte, puderam demonstrar que durante o sono existe uma variação e estágios que aparecem espontaneamente sob a regulação do sistema nervoso central. Logo, descreveram o que seriam as primeiras características observáveis dos estágios do sono, utilizadas até hoje (KLEITMAN, 1963).

Conseqüentemente, os primeiros estágios observáveis foram os que hoje conhecemos como os estágios Não-REM, estes foram categorizados como A, B, C, D e E. Entretanto, somente em 1953, em experimentos realizados por Aserinsky, Kleitman et al. (1953), foi identificado o último estágio do sono o *Rapid Eye Moviment* (REM). Ganhando este nome pois quando este estágio ocorre há uma movimentação rápida nos olhos do paciente. Por sua vez, sua demora deu-se por este ser frequentemente confundido com o estágio N1, se tornando um grande marco na investigação do sono. A partir de então, muitos avanços puderam ser feitos na fisiologia e fisiopatologia do sono, e em 1970, foi estabelecida a especialidade de Medicina dos Distúrbios do Sono (SILVA, 1996).

Para padronizar a terminologia e os critérios de avaliação do sono, um comitê foi formado em 1968. Instaurado-se então, um manual das técnicas e do estagiamento do sono (RECHTSCHAFFEN, 1978). Classificaram-se os estágios do sono como Não-REM e REM,

sendo o Não-REM composto por 4 classes N1, N2, N3 e N4. Depois deste comitê outros manuais foram desenvolvidos. Atualmente, o diagnóstico dos distúrbios é baseado em uma nova classificação como descrita em THORPY (1990), de modo que os estágios N3 e N4 são classificados como um único estágio o N3.

## 2.2 Polissonografia

O termo polissonografia trata-se de uma forma genérica para se referir ao registro simultâneo de algumas variáveis fisiológicas, que ocorrem durante o estado de sono de um organismo, como definido por Silva (1995). Estes registros são importantes para uma análise completa do organismo em seu estado de repouso profundo. Pois, ajudam da detecção de possíveis distúrbios do sono normal. Na Figura 2, disposta abaixo, é ilustrada a realização de um exame a posição dos equipamentos no paciente.

Figura 2 – Exame de Polissonografia.



Fonte: Adaptado de (TOGEIRA; SMITHII, 2005)

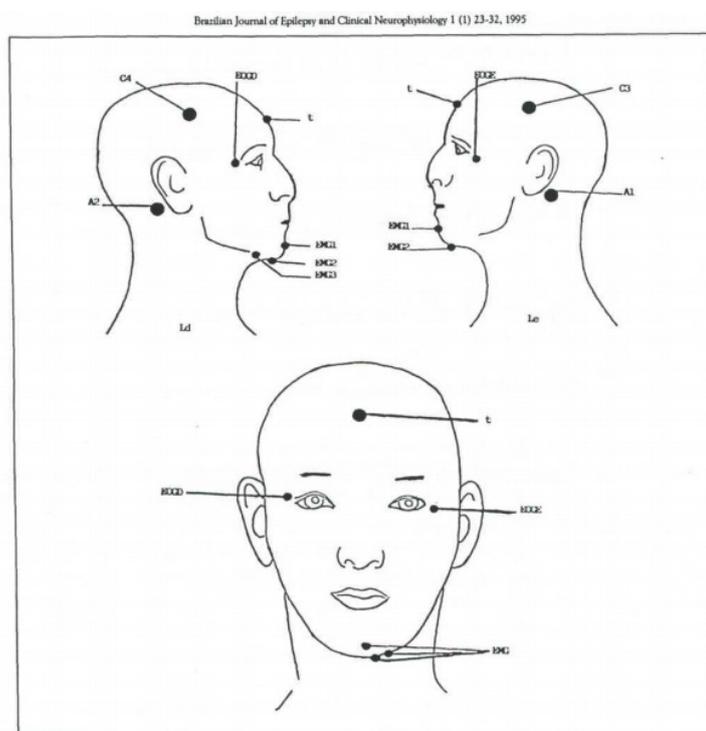
Para tanto, alguns sinais são importantes para a definição melhor deste estado de sono normal e, para a qualificação do sono de um paciente. Desse modo, os sinais

registrados durante a polissonografia são o comportamento dos olhos, músculos, respiração e atividade cerebral. A fim de analisar a atividade dos olhos, é realizado o chamado de Eletrooculograma referido como EOG. Para analisar o sistema nervoso periférico e dos músculos é realizado o Eletromiograma referido como EMG. Já na análise a atividade elétrica do coração é realizado o Eletrocardiograma referido como ECC, para a análise da atividade cerebral é realizado o eletroencefalograma referido como EEG.

Também são analisadas o fluxo aéreo nasal. Ou seja, tanto o nasal quanto oral, o esforço respiratório que trata-se do esforço torácico e abdominal, os gases sanguíneos ou seja a saturação de oxigênio e concentração de dióxido carbônico, a temperatura corporal, a tumescência peniana, entre outros.

A posição dos eletrodos é extremamente importante. Na Figura 3, é possível ver a posição dos eletrodos, pois em cada canal existe um amplificador que faz aumentar a diferença de potencial entre dois pontos, assim reproduzindo um sinal elétrico proporcional ao original. Para representar a oscilação de descargas elétricas geradas pelos eletrodos, um traçado é feito, este representa a amplitude e potência do sinal.

Figura 3 – Posições dos eletrodos para registro polissonográfico.



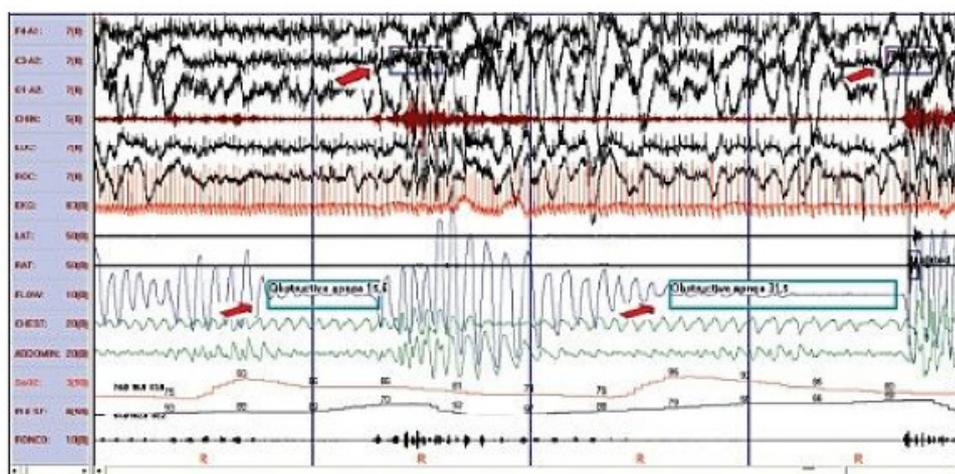
Fonte: Adaptado de (SILVA, 1995)

Nesse contexto, é traçada a representação da diferença de potencial entre os pontos captados pelos eletrodos em função do tempo. Para identificar estes sinais, a serem registrados, são usados os amplificadores de corrente contínua conhecidos como DC, que é

capaz de registrar variações lentas do sinal bioelétrico. É também muito utilizado, por exemplo, para registro da saturação do oxigênio ou os amplificadores de correntes alternadas conhecidos como AC, que é capaz de realizar os registros do Eletroencefalograma (EEG), Eletromiograma (EMG), Eletrooculograma (EOG) e Eletrocardiograma (ECG).

Para a realização dos exames, é necessário que o paciente vá até um ambiente hospitalar. Todavia, em alguns casos específicos e com equipamentos portáteis, é possível realizar o exame em domicílio. Para tanto, os eletrodos são colocados no paciente e um *software* se encarrega de coletar os dados para assim digitalizar os sinais bioelétricos. Na Figura 4, é possível ver uma exemplo dos dados que que o especialista obtém através do *software*, onde este realizam as marcações.

Figura 4 – Exemplo dos sinais registrados por um software durante a polissonografia.



Fonte: Adaptado de (MAAHS; ALMEIDA, 2017)

Uma vez que os dados são coletados e processados pelo *software*, o especialista do sono pode iniciar o processo de estagiamento do sono, que tratasse da identificação visual das ondas elétricas geradas. Este marca manualmente a vigília e os estágios N1,N2,N3 e REM, os eventos musculares, respiratórios e cardiológicos, dessa forma, o *software* pode quantificar os resultados auxiliando o especialista.

Contudo, esta é uma tarefa custosa pois demanda muito tempo, podendo levar de 2 a 4 horas (KHALIGHI et al., 2013), exigindo do profissional uma atenção minuciosa. Visto que, possui alta propensão a erros, além de ser tediosa. Estudos mostram que a taxa de concordância entre os especialista não chega nem a 90% (MORA et al., 2010).

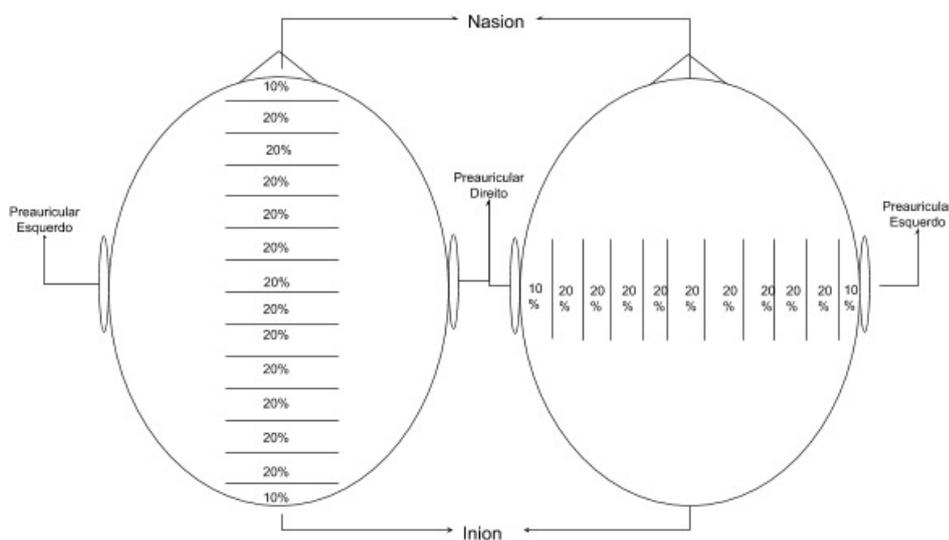
### 2.2.0.1 EEG (Eletroencefalograma)

O EEG é o método mais utilizado em clínicas e laboratórios psicológicos, como afirma Gomes (2015), que é utilizado principalmente no exame da polissonografia. Nesse

cenário, Silva (1995) afirma ser o parâmetro de maior relevância para o exame, como dito anteriormente, pois trata-se de um exame não invasivo que realiza o monitoramento da atividade cerebral. E, baseia-se nas variações de voltagem captados por diferentes eletrodos, são usados amplificadores que armazenam os sinais digitais para serem processados em computadores.

A fim de padronizar o posicionamento dos eletrodos durante o encefalograma, JASPER (1958) em Montreal, propôs um sistema conhecido como Sistema Internacional 10-20 de Colocação de Eletrodos, baseado na medição da total da cabeça em partes simétricas, com intervalos de 10% e 20% da distância, e divididos em 4 pontos: o náсион, o ínion (protuberância occipital externa) e os pontos preauriculares direito e esquerdo. Conseqüentemente, o sistema pode ser observado na Figura 5 a seguir, de modo que seja possível ver a divisão vertical e horizontal do escalpo, sendo as extremidades com medida de 10% e a parte central medida com 20%.

Figura 5 – Imagem ilustrativa representando o Sistema Internacional 10-20 de colocação de eletrodos



Fonte: Elaborado pelo Autor.

Nessa lógica, as variações elétricas são frequências captadas, expressas em ciclos por segundo (c/s) ou Hertz (Hz), podendo variar desde componentes potenciais rápidos até ultra-lentos. Seus potenciais são divididos em faixas de frequências como é apresentado na Tabela 1.

Na Figura 6, é possível ver uma representação das posições dos eletrodos do EEG (Eletroencefalograma), onde as marcações F representam o lobo frontal, T o temporal, C central, P o parietal e O o occipital, e z corresponde a linha média. De acordo com

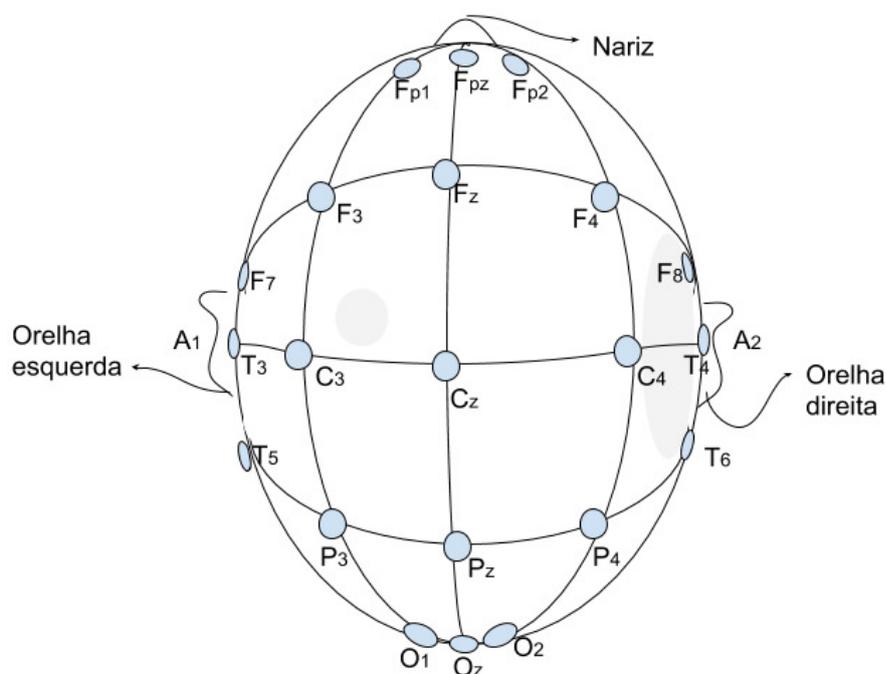
Tabela 1 – Divisão de faixas de frequência.

	Faixas de frequência (Hz)
<b>Delta</b>	abaixo de 3,5(entre 0,1 e 3,5)
<b>Teta</b>	entre 4 e 7,5
<b>Alfa</b>	entre 8 e 13
<b>Beta</b>	acima de 13 (entre 14 e 40)

Fonte: adaptação da representação feita por Silva (1995)

o manual (RECHTSCHAFFEN, 1968), é necessário apenas 2 canais para o exame da polissonografia os C3 e C4, sendo uma para backup.

Figura 6 – Imagem ilustrativa representando os Canais EEG (Eletroencefalograma)



Fonte: Elaborado pelo Autor.

Diante disso, observa-se que os sinais bioelétricos centrais têm uma boa visualização. Silva (1995), afirma que a partir de então é observável os fusos do sono, o complexo k, as ondas do vértex, assim como os sinais que são mais proeminentes no lobo frontal e occipital, como as ondas lentas de alta voltagem dos estágios N3 e/ou N4 e a atividade alpha, respectivamente. Por sua vez, a partir do canal central é possível ter uma visão holística dos estágios do sono, pois este capta ondas que ocorrem tanto na parte frontal como occipital do cérebro. No entanto, em casos mais específicos, os especialistas utilizam nos exames mais canais.

### 2.2.1 Estágios do Sono

Como dito anteriormente, durante o sono ocorrem ciclos, aonde existem despertares aqui referidos como vigília, que se alternam entre o despertar e sono, composto por estágios, de acordo com Rechtschaffen (1968) são 4: NREM-1, NREM-2, NREM-3 e REM.

Os estágios do sono são bem definidos por Silva (1995) e Silva (1996), através de classes para o estagiamento. Nesse contexto, a vigília, também conhecida da literatura por estágio W (*wakefulness*), trata-se do momento em que o indivíduo ainda está acordado. Este é caracterizado no EEG (Eletroencefalograma) por ocorrerem ondas de ritmo alfa que em um adulto normal a frequência está entre 0.9 e 10.2Hz, ondas de baixa amplitude e frequências variadas pela presença de movimentos oculares.

Nesse quadro, os estágios N-REM, ou seja, os estágios que não ocorrem o movimento rápido dos olhos, são divididos em 3. O primeiro é caracterizado por realizar a transição da vigília para o sono, tendo ocorrências do ritmo alfa, das ondas do vértex e movimentos lentos dos olhos, no entanto, realiza a transição dos períodos de baixa voltagem entre 4 e 7,5Hz.

O segundo estágio é caracterizado por possuir frequências bem variadas ocorrendo ondas de baixa voltagem, fusos do sono que são surtos de ondas que variam entre 12 e 14Hz tendo uma duração máxima de 1,5 segundos e mínima de 0,5 segundos ocorrendo com mais frequência nas regiões centrais do cérebro, e complexos-k. Que consiste em um componente inicial agudo negativo, que é imediatamente seguido por um positivo, podendo ser sobreposto por ondas de fusos, por fim tendo no máximo 20% de ondas delta.

Já o terceiro estágio, que hoje é entendido como o terceiro e quarto estágios, é caracterizado pela ocorrência mais proeminente na região occipital do cérebro, por ondas delta com presença mínima 20% e no máximo de 50%, fusos do sono e complexos k, porém menos frequentes quanto os observados no estágio N2 e a falta de presença de movimentos nos olhos. Com a união entre os dois estágios, conhecido como o estágio profundo de sono, tendo pouca resposta a estímulo tátil e auditivo.

Por conseguinte, o ultimo estágio, conhecido como REM, é caracterizado por movimentos rápidos dos olhos que ocorre com forma e densidade irregular, supressão da atividade do EMG, tendo a presença de potenciais de frequências variadas e de baixa voltagem, as ondas em dente de serra que possuem forma triangular com frequência entre 2 e 6Hz. Neste estágio, a presença de ritmos alfa e de 1 a 2Hz e, há uma inibição dos movimentos musculares e reflexos.

Na Tabela 2, é apresentado um resumo das características dos estágios em relação ao EEG (Eletroencefalograma) e o EOG (Eletrooculograma).

Tabela 2 – Estágios do Sono.

	EEG	EOG
Vigília	Presença do ritmo alfa	presença de movimentos oculares
N1	Presença de ritmo alfa em menos de 50%	presença de movimentos rápidos dos olhos
N2	Presença de fusos do sono, complexos-k e ondas delta com maximo de 20%	sem movimentação ocular
N3	Presença de ondas Delta maior que 20% e menor que 50%	sem movimentação ocular
REM	Presença de ondas em dente de serra, ondas alfas de baixa frequência.	presença de movimentos rápidos e abalos

Fonte: adaptação da representação apresentada em Silva (1996)

## 2.3 Análise Espectral

A análise de sinais é normalmente feita em dois domínios, o domínio do tempo e o domínio da frequência. Nesse caso, métodos de análise do domínio do tempo são caracterizados pela manipulação dos sinais sempre no domínio do tempo. Não importa qual operação intermediária possa ser realizada, o resultado sempre serão nos mesmo domínios, nestes são utilizados filtros, como a filtragem digital.

À vista disso, o domínio da frequência é caracterizado pela transformação do sinal temporal em uma descrição espectral. O espectro é uma representação do seu histograma de frequências. A transformada de Fourier, é comumente utilizada no domínio da frequência para a visualização espectral dos sinais como utilizado em Kohtoh et al. (2008).

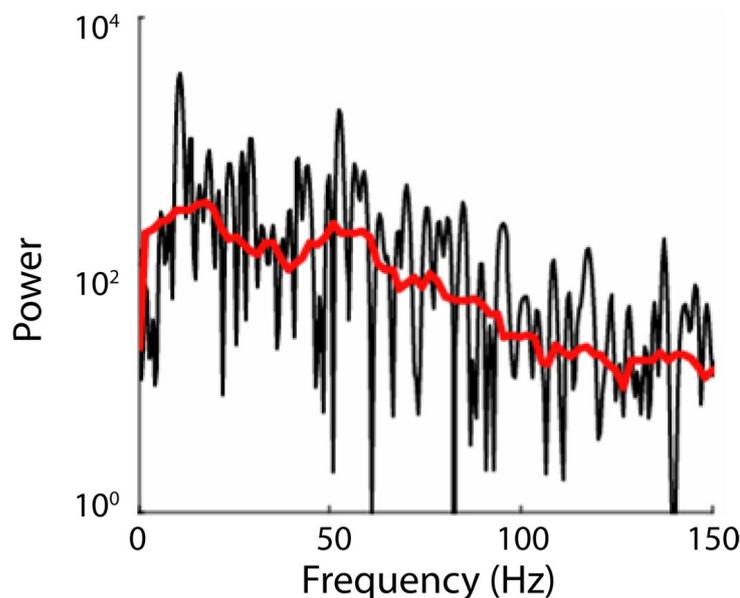
Ao aplicá-la para extrair informação, assume-se que cada coeficiente de Fourier representa a amplitude e a fase relativa da frequência de forma confiável e correspondente ao sinal. Não obstante, nem sempre a afirmação é válida, pois na prática o espectrograma produz estimativas com um limiar muito alto de variação nas frequências, e ainda tornar-se um estimador altamente tendencioso. Assim, em uma tentativa de reduzir este viés, é utilizado as chamadas janelas de afunilamento, antes de realizar as estimativas espectrais como definido em Vilamala, Madsen e Hansen (2017).

Nesse sentido, o método *multitaper* supera algumas das limitações da análise convencional da transformada de Fourier, realizando uma análise no domínio do tempo-frequência assim reduzindo o viés de estimativa obtendo múltiplas estimativas de uma mesma amostra. Para tanto, a teoria do *multitaper* foi desenvolvida por Thomson (1982) em 1982, com o objetivo de abordar as questões sobre os viés de variância da estimativa espectral não paramétrica de maneira otimizada, desde então, outras variantes do método surgiram.

Este método baseia-se no janelamento de uma série temporal. De modo que, calcula-se a Transformada de Fourier nesta janela, assim retira-se a média das estimativas resultantes, e deste modo é possível diminuir o viés de variância como observado na Figura 7.

Tal método, é muito utilizado para a análise de dados multi-canal em experimentos da neurociência e engenharia biomédica, este não se limita as análises de series temporais,

Figura 7 – Imagem ilustrativa representando uma comparação da estimativa de um periodograma representado na figura em preto e o *multitaper* representado na figura em vermelho de uma única medição de potencial de um campo local de um teste, utilizando 9 janelas



Fonte: Adaptado de (BOKIL et al., 2010)

pode ser adaptado a partir de esferas harmônicas para aplicações na cosmologia e geofísica usadas nos trabalhos de Wieczorek e Simons (2007) e Dahlen e Simons (2008).

Através deste, é possível gerar imagens visivelmente interpretáveis das frequências de uma série temporal. Então, é a finalidade deste método para este trabalho, onde será utilizado para gerar imagens distintas entre as classes de classificação dos estágios do sono REM, N1, N2, N3 e a vigília.

### 2.3.1 O Método *Multitaper*

Como discutido na seção 2.3, a análise espectral utilizando múltiplas estimativas da Transformada de Fourier, traz uma redução no viés de variância de um sinal representado em uma série temporal. Para se determinar essa múltiplas estimativas faz-se necessário a definição de uma janela ou seja período no qual a Transformada de Fourier é aplicada, deste modo a soma do resultado de cada aplicação da Transformada nas Janelas, será dividido pela quantidade de janelas usadas em toda a série temporal.

A função que determina a janela, janelamento ou taper observada em uma série temporal é descrita na Equação 2.2, onde é a análise espectral convencional realizada em uma série temporal  $x(t)$  observada em uma janela temporal de duração  $T$  onde é estimado como o quadrado do valor absoluto da Transformada Canônica de Fourier, definida em 2.1,

onde  $h(t)$  corresponde a função de janelamento, como descrita na Equação 2.3 definida em Chronux (2018) desenvolvida abaixo.

$$f(t) = \int x(t)e^{2\pi ift} dt \quad (2.1)$$

$$S_{conv}(f) = |X(f)|^2 \quad (2.2)$$

$$S_{conv}(f) = \left| \int_0^T h(t)x(t)e^{2\pi ift} d\tau \right|^2 \quad (2.3)$$

A função de estimativa *multitaper* do espectro, é dada a partir do cálculo da média das estimativas espectrais resultantes das janelas da Equação 2.2, como representado na Equação 2.4, onde  $K$  é total de janelas e  $u$  é a série temporal de cada janela ou taper analisado assim representado na Equação 2.5.

$$S_{MT} = \frac{1}{K} \sum_{k=1}^K |x_k(f)|^2 \quad (2.4)$$

$$S_{MT} = \frac{1}{K} \sum_{k=1}^K \left| \int_0^T u_k(t)x(t)e^{-2\pi ift} dt \right|^2 \quad (2.5)$$

## 2.4 Redes Neurais

Quando a necessidade de se formalizar uma técnica computacional capaz de adquirir capacidades de aprendizagem e inteligência aparece, com ela surge o esforço de se formalizar o que hoje é conhecido como Inteligência Artificial (IA), em um encontro no *Darhmouth College*, durante os anos 50. Onde foi publicado o livro (SHANNON, 1956), tratando em seu primeiro capítulo das Redes Neurais Artificiais (RNA), que são um paradigma de programação inspirado na Biologia, mais precisamente no funcionamento do cérebro.

A Neuroanatomia começou a ser estudada em 1875 por o Camillo Golgi como descrito em Hubel (1979). Desde então, muitas descobertas foram desenvolvidas, visto que uma das principais inspirações para o desenvolvimento das redes neurais artificiais, são a comunicação entre as células do cérebro, ou seja os neurônios, efetuado pela sinapse.

Nesse sentido, as sinapses têm comportamento essencial na fixação da memória, principalmente as do córtex cerebral e algumas das partes profundas do cérebro. Ondas elétricas são disparadas e percorrem um caminho de neurônios, daí o rastro deste caminho pode ser entendido como a memória, e a capacidade de passar no mesmo caminho na ausência do estímulo que lhe deu origem é conhecido como facilitação sináptica, como definido em T (2018).

Barreto (2002), define a transmissão da informação entre os neurônios, que dependem dos neurotransmissores, para a liberação de moléculas de vários tipos, e da abundância destes no terminal sináptico e da sensibilidade da membrana dendrítica à estímulos. Desta forma, ao manipular a intensidade de um neurônio, este tem influência sobre seus vizinhos podendo inibir ou excitar, agindo de acordo com as características sinápticas. Logo, essas conexões entre os neurônios definem o comportamento da rede neural artificial também conhecido como conexionismo, alterando os valores das conexões entre os neurônios, muda-se o comportamento da mesma.

Conforme Barreto (2002), esta é uma técnica aplicada para solucionar problemas da IA. Seu objetivo não é desenvolver um programa capaz de imitar um comportamento inteligente e, sim construir um modelo capaz de aprender, obtendo uma curva de erro cada vez menor ao longo do tempo.

Apesar da inspiração biológica, as Redes Neurais Artificiais são diferentes das naturais, tendo poucas semelhanças. O primeiro modelo de neurônio proposto foi por McCulloch e Pitts (1943), em 1943, com a intenção de imitar o funcionamento dos neurônios de acordo com a biologia cerebral. Foi proposto um modelo simples que se tornou a base para as redes atuais, todavia, a preocupação da equiparação com o processo cerebral não é mais uma preocupação nas arquiteturas das redes neurais atuais.

Duas vertentes motivam a pesquisa das Redes Neurais Artificiais. Segundo Barreto (2002), a primeira é modelar o sistema nervoso de maneira precisa, a fim de observar seu comportamento crescente a tal ponto de ser semelhante ao comportamento de um ser vivo com capacidades de aprendizado, o segundo, baseia-se na construção de computadores com alto grau de paralelismo.

Na Figura 8 é demonstrada a representação visual do modelo da rede neural artificial proposta por McCulloch e Pitts (1943). Tal representação é um modelo binário, que demonstra funcionamento de um neurônio como um circuito binário.

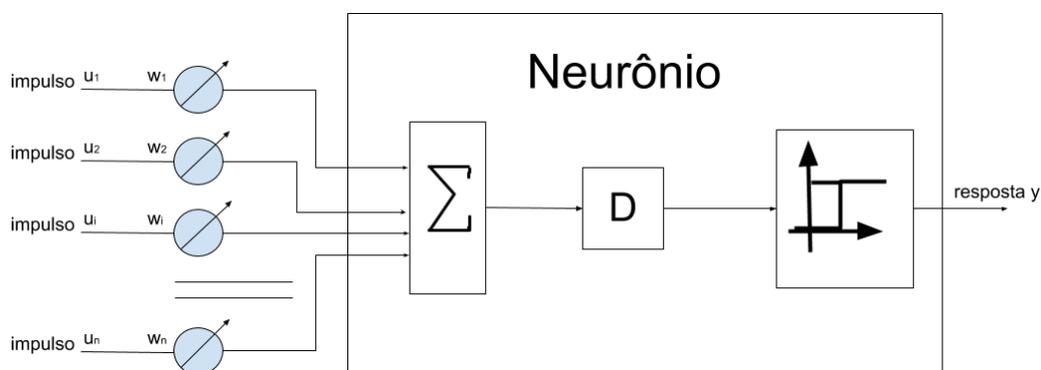
Observa-se que as entradas do neurônio são binárias, dessa forma, dentro do modelo é efetuado um somatório com estas entradas e assim é produzida a entrada efetiva do neurônio como é demonstrado na Equação 2.6:

$$entrada = \sum_n^1 w_i u_i \quad (2.6)$$

O resultado da Equação 2.6 sofre um retardo  $D$ . Em alguns casos, tal retardo pode ser totalmente ignorado e tornar-se estático, pois, este serve de argumento para a função de transferência no caso deste modelo uma saída binária é expressa como saída do neurônio.

Nos anos 60, uma nova perspectiva a cerca das redes neurais surge com os trabalhos de (ROSENBLATT, 1962), inspirados em McCulloch e Pitts (1943), trazendo o conceito

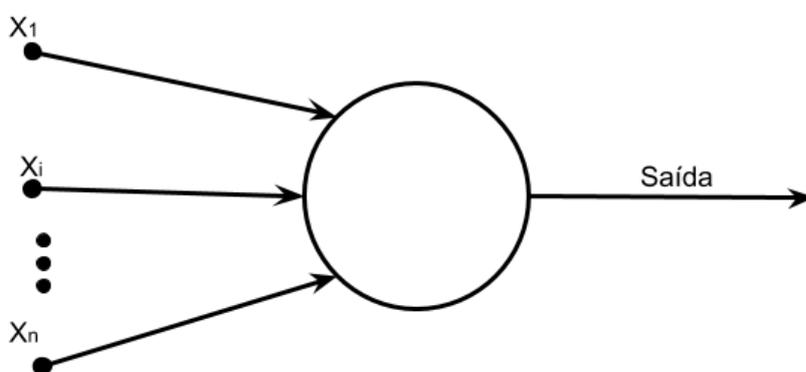
Figura 8 – Imagem ilustrativa representando o modelo da rede neural artificial proposta por McCulloch-Pitts em McCulloch e Pitts (1943)



Fonte: Elaborado pelo Autor.

de *perceptron*. Portanto, este novo modelo introduziu pesos, que são números reais para expressar a importância das entradas neste neurônio, como representado na Figura 9.

Figura 9 – Modelo da rede neural artificial proposta por Frank Rosenblatt em Rosenblatt (1962)



Fonte: Elaborado pelo Autor.

A saída determina se a soma ponderada da Equação 2.6 é menor ou maior que um valor limite estabelecido. Como representado na Equação 2.7, o *perceptron* é um modelo que toma decisões pesando suas evidências:

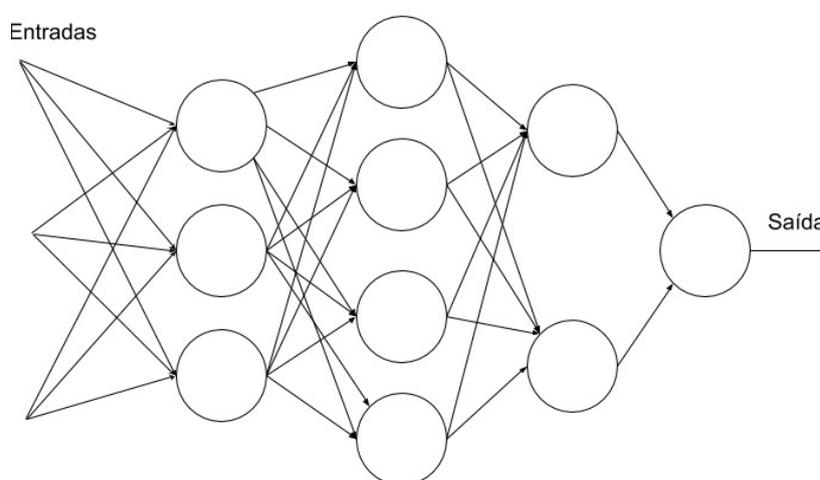
$$saida = \begin{cases} 0 & \text{se } \sum_j w_j x_j \leq \text{limiar} \\ 1 & \text{se } \sum_j w_j x_j > \text{limiar} \end{cases} \quad (2.7)$$

Nessa lógica, uma Rede Neural, pode ser representada como uma grafo direcionado,

onde seus vértices representam as ligações entre os neurônios de uma rede neural. Diante disso, uma rede consiste em um conjunto não vazio com um número finito de vértices, que conectam os neurônios, rotulados pelos arcos por nomes ou rótulos.

Dessa forma, uma Rede Neural Artificial, em outras palavras, um grafo rotulado em cada vértice. Pois, diz-se uma rede completamente conectada é quando todos os neurônios estão conectados entre si. No entanto, as redes que não contém ciclos em sua arquitetura são chamadas de redes diretas (*Feedforward*), esta é representada na Figura 10.

Figura 10 – Imagem ilustrativa representando uma rede neural artificial de 4 camadas completamente conectada



Fonte: Elaborado pelo Autor.

Na representação das redes frequentemente é utilizado o termo camada. As primeiras, ou seja, as que recebem os impulsos, são chamadas camadas de entrada, a [ultima é chamada de camada de saída pois é quem determina o resultado e as camadas internas são chamadas ocultas ou *hidden layers*.

O *perceptron* como definido por Nielsen (2015), é apenas um neurônio que compõe uma rede, podendo ser formada por vários *perceptrons* como representado na Figura 10. Nesta, é representada uma RNA completamente conectada com 4 camadas, com uma camada de entrada, uma camada de saída e duas camadas ocultas. Estas redes com múltiplas camadas são chamadas de redes multicamadas (*Multilayer Perceptron*), as MLP's.

Esta arquitetura é utilizada para resolver diferentes problemas, bastando ter uma quantidade significativa de amostras para realizar o aprendizado. De acordo com Sun et al. (2017), quanto maior o número de amostras mais eficiente é o aprendizado.

Nesse sentido, as Redes Neurais tem se mostrado ótimas soluções para diversos

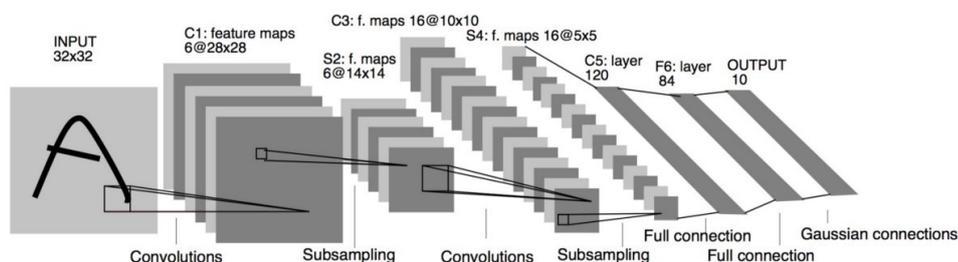
problemas nos campos de reconhecimento de imagens, como visto em Simonyan K. e Zisserman (2014), sons como usado em Lee et al. (2009) e Processamento da Linguagem Natural desenvolvido por Collobert e Weston (2008). Pois, um grande avanço neste paradigma inspirado na Biologia, têm sido as Redes Neurais Convolutivas, que serão discutidas na Seção 2.4.1. Mostrando bons resultados na identificação e classificação de imagens.

### 2.4.1 Redes Neurais Convolutivas

Como apresentado na seção anterior, Redes Neurais podem ter várias camadas e para um aprendizado efetivo é necessário uma base significativamente grande. Esta técnica obtém bons resultados em seus treinamentos, no entanto, treinar uma rede com um número muito alto de camadas e *perceptrons* gera um custo computacional elevado, principalmente em Processamento de Imagens.

Nesse contexto, a fim de impulsionar a utilização das Redes Neurais, surge o conceito das Redes Reurais Convolutivas, inicialmente proposto por LeCun et al. (1998) em 1988, que desenvolveu uma arquitetura denominada LeNet representada na Figura 11, introduzindo o conceito da convolução, para reconhecimento de caracteres, dígitos e etc.

Figura 11 – Imagem ilustrativa representando a rede neural LeNet



Fonte: Adaptado de (LECUN et al., 1998)

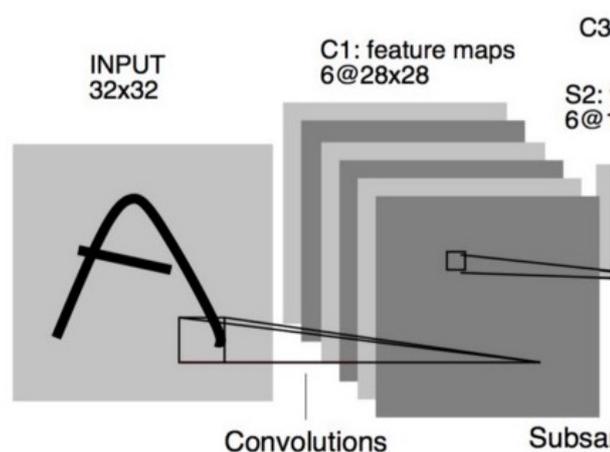
As principais aplicações das Redes Neurais Convolutivas são para processamento de imagens, e suas operações básicas realizadas nas Redes Neurais Convolutivas para o processamento de imagens como descritos em Rocha (2015) são:

- Convolução: Seu principal objetivo é extrair características da imagem de entrada pode ser observado na Figura 12.
- Não linearidade: Tem por objetivo introduzir a não linearidade a rede com uma operação matemática.

- Pooling ou SubAmostragem: Atua a fim de reduzir a dimensionalidade de cada recurso mantendo as informações mais importantes pode ser observado na Figura 13.
- Classificação ou camada completamente conectada: tradicionalmente usa-se a rede multilayer perceptron que utiliza uma função de ativação na camada de saída pode ser observado na Figura 14.

As imagens têm propriedade estacionária, ou seja, as estatísticas adquiridas a partir de uma imagem se constituem nas mesmas, independente do pedaço retirado dela. Nesse contexto, a convolução, demonstrada na Figura 12, preserva o espaço entre os *pixels*, aprendendo as características da imagem a partir de pequenos quadrados da mesma utilizados como entrada.

Figura 12 – Rede neural LeNet, especificando a convolução na representação



Fonte: Adaptado de (LECUN et al., 1998)

Dada uma imagem grande  $r \times c$  representada por  $x_{grande}$ , inicialmente é realizado o treinamento com utilizando *autoencoders*, que são redes neurais treinadas com o objetivo de copiar a entrada para sua saída, a fim de diminuir a dimensionalidade da rede, com pequenos pedaços da imagem grande, esses pedaços são as imagens  $a \times b$  representados por  $x_{pequeno}$ .

Ou seja, suas características são aprendidas a través da extração de  $k$  características, ou seja dos  $k$  pedaços da imagem demonstradas na Equação 2.8, como definido por Rocha (2015). Onde  $\sigma$  representa uma função de ativação,  $W^{(k)}$  que representa os filtros do recurso convolutivo  $k$ .

$$f = \sigma(W^{(k)} \times x_{pequeno}) \quad (2.8)$$

Para cada pedaço de imagem  $a \times b$  representado por  $x_p$ , contido na imagem grande, é calculado as características representada pela Equação 2.9. Dessa formam, temos um *array* de características convolutivas representada na Equação 2.10, onde  $k$  é o número de pedaços da imagem,  $r$  é a largura da imagem grande,  $a$  é largura da imagem pequena,  $c$  é altura da imagem grande e  $b$  é a largura da imagem pequena.

$$f_p = \sigma(W^{(k)} \times x_p) \quad (2.9)$$

$$f_{conv} = k \times (r - a + 1) \times (c - b + 1) \quad (2.10)$$

Observamos que a imagem grande trata-se de uma matriz onde vamos representá-la como matriz  $g$  e multiplicada por um filtro aplicado em seus pedaços. Trata-se de uma matriz menor que aqui vamos representá-la como matriz  $f$ , formando uma nova matriz de características que aqui vamos representa-la como matriz  $c$ .

Comumente, a matriz  $f$  é chamada de filtro (*filter*), detector de características (*feature detector*) ou núcleo (*kernel*), pois estes extraem informação da imagem original ou seja a matriz  $g$  e a matriz  $c$  é chamada de recurso convolutivo (*Convolved Feature*) ou Ativação Mapa (*Activation Map*).

Logo, o recurso convolutivo possui 3 parâmetros, estes precisam ser decididos antes de executar a convolução, estes são descritos abaixo: A profundidade, ou seja o número de filtros que serão utilizados, a quantidade de filtros escolhida é proporcional a quantidade de recurso convolutivos que serão gerados assim como a dimensão desta matriz, ou seja 1 filtro a sua profundidade é 1, 2 filtros sua profundidade é 2 e assim sucessivamente.

Nesse sentido, *stride* que é o número de *pixels* que define o deslizamento da matriz  $f$ , na matriz  $g$ , ou seja quando este é definido como 1 a matriz  $f$  move-se um *pixel* por vez, quando é definido com 2 a matriz  $f$  move-se 2 *pixels* por vez e assim sucessivamente. Pois, o preenchimento zero, por vezes é conveniente preencher as bordas da matriz com zeros, com o propósito de aplicar o filtro nos elementos vizinhos da matriz  $g$ , este recurso permite permite controlar o tamanho do recurso convolutivo.

Já no processo de aprendizagem, é necessário realizar ajustes em seus pesos, a fim de ter um controle sobre as mudanças realizadas, estas são feitas com pequenas mudanças ativadas por componentes matemáticos, chamados de funções de ativação, através dessas mudanças será possível a aquisição de conhecimento.

A Não Linearidade (*Non Linearity*), é a função de ativação que determina se um determinado neurônio será ativo ou não durante o treinamento. Isto é necessário pois os dados no mundo real não são lineares, tornando a rede capaz de adquirir conhecimento e efetivar o aprendizado, quando não há uma função de ativação em uma rede, geralmente

se utiliza a transformação linear, esta é simples porem limitada na resolução de problemas mais complexos.

Alguns exemplos de funções de ativação são as funções lineares, a Sigmoidal (Sigmoid), a Tangente Hiperbólica (Tanh), a ReLu, *Softmax* entre outras. A ReLu (*Rectified Linear Units*), definida como  $f(x) = \max(0, x)$  que significa unidade linear retificada, substitui todos os valores de pixels negativos no recurso convolutivo por zero, a sigmoid definida como  $f(x) = \frac{1}{1+e^{-x}}$ . Que trata-se de uma função não linear capaz de realizar a variação dos pesos entre 0 e 1, ou seja, esta se dá bem em classificações de duas classes.

A função definida como  $Tanh(x) = \frac{e^{2x}-1}{e^{2x}+1}$ , retornando valores entre -1 e 1, a função *Softmax*, tem um comportamento parecido com o da função sigmoide, muito útil em problemas de classificação sua diferença é que sua saída é capaz de retornar valores para mais que duas classes retornando valores entre 0 e 1. Dividindo pela soma das saídas definida como  $\sigma(z)_j = \frac{e^{-z_j}}{\sum_{i=1}^K e^{-z_i}}$  onde j varia de 1 até K e a função linear que retorna valores lineares a derivada desta função é constante. Ou seja, na realização do *Backpropagation* o gradiente sempre é o mesmo, e assim a rede não tem uma melhora no aprendizado apenas se mantendo constante em tarefas complexas, esta função é interessante para tarefas simples onde a constância é desejada, assim esta é definida como  $f(x) = ax$ .

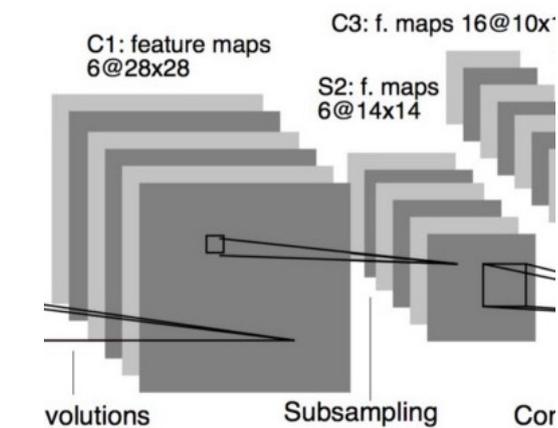
O *pooling* na Figura 13 também conhecido como subamostragem *subsampling* ou diminuição da resolução *downsampling*, objetiva reduzir a dimensionalidade de cada mapa de recursos, guardando as informações importantes. Podendo ser de vários tipos: o máximo, que define uma vizinhança espacial ou seja uma matriz, para verificar o maior valor do recurso convolutivo, esse valor é colocado na vizinhança espacial. O médio, retira a média dos valores que resultam do recurso convolutivo, e é colocado na matriz de vizinhança espacial. Além da soma, onde os valores do recurso convolutivo são somados e colocados na matriz de vizinhança espacial.

Desse modo, o *pooling* diminui a dimensionalidade da entrada, tornando-a gerenciável, e reduz o número de parâmetros e cálculos dentro da rede, controlando *overfitting*. Visto que, quando os resultados são super ajustados a uma base, impossibilitando a rede de aprender coisas novas ou de identificar coisas com padrões diferentes do treinamento, torna a rede invariante a pequenas transformações, auxiliando a um resultado de uma representação equivalente a imagem de entrada, auxiliando na detecção de objetos dentro da imagem, independente da posição desta na foto.

Na camada completamente conectada, tradicionalmente são utilizados algoritmos de classificação, como a rede *multilayer perceptron*, *random-forest*, knn, entre outros. Esta é uma forma menos custosa de aprender combinações não lineares dos recursos, como demonstrado na Figura 14.

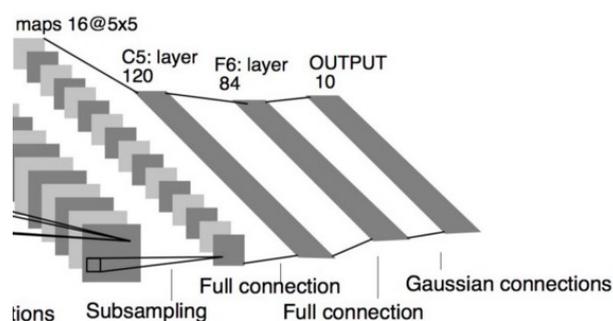
Com isso, as camadas de convolução e de *pooling* atuam como extratores de

Figura 13 – Imagem recortada da representação da rede neural LeNet, especificando o pooling



Fonte: Adaptado de (LECUN et al., 1998)

Figura 14 – Imagem recortada da representação da rede neural LeNet, especificando a camada de classificação ou camada completamente conectada



Fonte: Adaptado de (LECUN et al., 1998)

características enquanto que a camada completamente conectada atua como classificador.

No geral, a rede pode ter várias combinações de convoluções e *pooling*, isto dará uma arquitetura diferente para cada combinação da rede. Fornecendo capacidades diferentes de reconhecimento ou classificação, quanto maior o número de combinações maior a complexidade da rede e assim mais variabilidade na extração de recursos para o aprendizado.

### 2.4.2 Inception V3

A *Inception V3* é uma rede convolutiva profunda, lançada pelo Google <sup>1</sup> em 2015 desenvolvida por Vanhoucke Sergey Ioffe (2015), esta venceu o desafio *ImageNet Large*

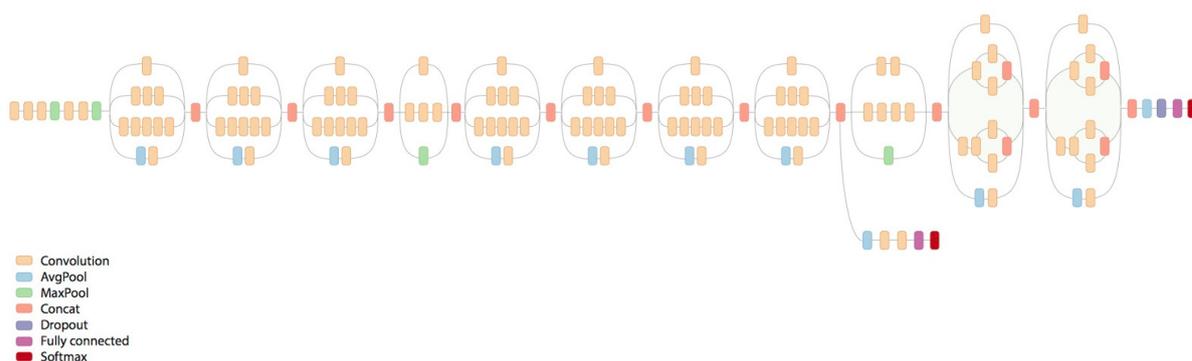
<sup>1</sup> Google LLC é uma empresa multinacional de serviços online e software dos Estados Unidos.

*Scale Visual Recognition Challenge* (ILSVRC), que realizou um treinamento com uma enorme quantidade de imagens, divididas em um total de 1000 classes.

Esta é uma arquitetura de rede convolutiva diferente das redes convolutivas tradicionais. Pois, os neurônios são organizados em camadas, e cada camada executa diferentes transformações dos dados de entrada, ela é formada por mini-modelos de redes. É possível comparar esta arquitetura a várias peças de lego diferentes que montadas podem formar por exemplo um castelo, nesta analogia as peças seriam módulos pequenos, e o castelo seria a *Inception V3* (Figura 15).

A ideia por de trás desses mini-modelos, ou inceptions é fazer com que estes combinados diminuam a quantidade de parâmetros para a rede, deste modo Vanhoucke Sergey Ioffe (2015) demonstrou que a utilização dessas inceptions tornam a rede com menos parâmetros porém sem perder a capacidade de classificação.

Figura 15 – Imagem representando a rede neural inception-V3

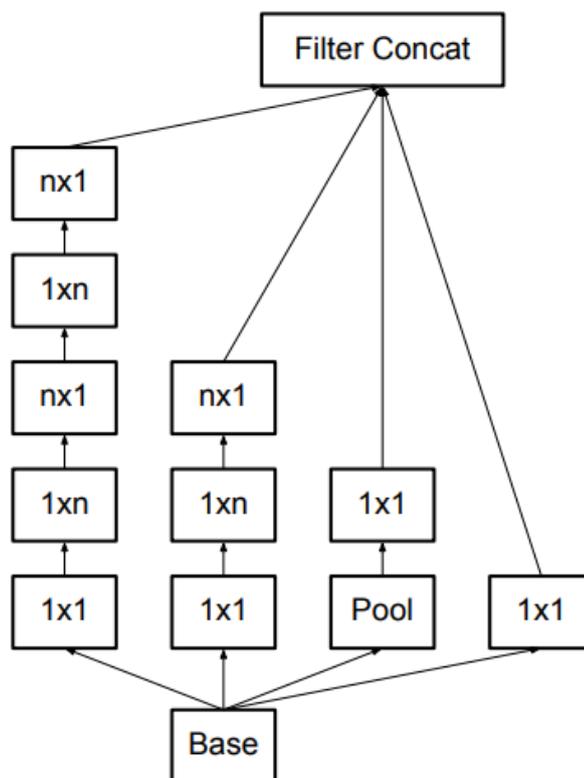


Fonte: Adaptado de (MULC, 2018)

Como discutido na seção 2.4.1, as convoluções são estratégias utilizadas para a extração de características, no entanto os filtros utilizados para a extração devem ser previamente determinados. Nesse sentido, a ideia por trás deste modelo baseado em módulos, é que cada módulo seja independente entre si e responsável por determinar os filtros utilizados em suas convoluções, ou seja, o filtro utilizado durante a convolução ajusta-se conforme a aprendizagem é realizada. E o aprendizado adquirido nestes módulos (Figura 16) são transferidos para os próximos módulos.

Tradicionalmente, a Aprendizagem de Máquina realiza previsões sobre dados futuros, usando modelos matemáticos treinados a partir de dados rotulados e coletados previamente, partindo do princípio de poder aproveitar este aprendizado para outros problemas. A ideia de transferência de aprendizado surgiu como discutido em Lu et al.

Figura 16 – Imagem representando um módulo ou uma inception da inception-V3



Fonte: Adaptado de (MULC, 2018)

(2015), ou seja, aproveitar o treinamento utilizado para a identificação de maçãs, em um problema de identificação de laranjas por exemplo.

A primeira vez que se falou em transferência de aprendizagem foi em 1993 por Pratt (1993), onde desenvolveu-se um algoritmo de transferência de aprendizagem baseada em discriminação *Discriminability-Based Transfer* (DBT). Esta técnica propõe o armazenamento do conhecimento de um domínio adquirido ao solucionar um problema e aplicá-lo a um domínio de destino de um problema diferente. Este considera que os domínios podem ser diferentes entre si.

Nesse quadro, este modelo utiliza a técnica conhecida como Transferência de Aprendizado (*Transfer Learning*), pois foi treinado a partir de um grande número de imagens do ImageNet, no total foram aproximadamente 1.000.000 de imagens, com os dados de 2015, onde é possível aplicar o modelo em outros problemas.

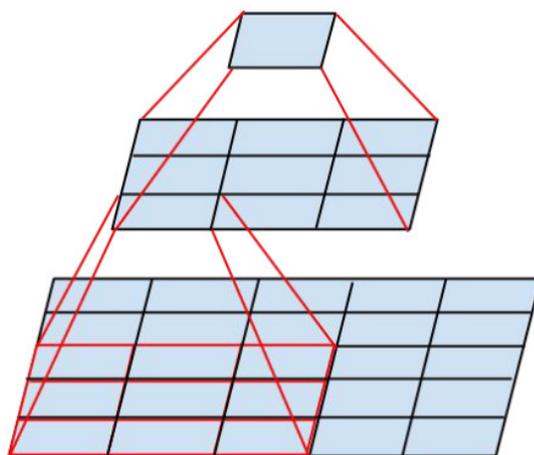
Os módulos de iniciação são denominados *inception*, que podem ser observados na Figura 15. Eles funcionam como mini-redes convolutivas assim as operações discutidas na seção 2.4.1 serão realizadas nestas *inceptions*, *poolings*, convoluções, o ReLu e/ou o *Softmax*, que é uma função logística.

Ao aplicar a modularização das tarefas de extração de características através das *inceptions*, que conectam as camadas convolutivas com camadas *multilayerperceptrons* capazes de aprender através das funções não-lineares, foi verificado que os *perceptrons* são matematicamente equivalentes a convoluções de filtro 1x1. Encaixando-se perfeitamente em redes convolutivas e assim o maior poder de abstração das camadas convolutivas pode ser menor, diminuindo a necessidade de camadas completamente conectadas. Pois, é calculada a medida espacial do recurso convolutivo na camada final e assim alimentam diretamente os vetores para o classificador *softmax*.

Desse modo, se reduz o número de parâmetros por consequência se reduz o risco de *overfitting* e carga computacional. Em Vanhoucke Sergey Ioffe (2015), esta ação é chamada de *pooling* global médio *global average pooling* ou somente avgPool, afirmando ainda que torna a rede mais robusta redução de dimensionalidade.

Para melhorar o desempenho da convergência da rede, foram adicionadas perdas adicionais vinculadas ao erro de classificação nas camadas intermediárias, que é utilizado no treinamento e descartado na saída durante a inferência. Portanto, Vanhoucke Sergey Ioffe (2015) demonstrou que qualquer convolução cujo filtro é maior que 3x3 pode ser expressa de forma eficiente, com várias convoluções menores, sugerindo a substituição de filtros grandes 7x7 por um par de camadas convolutivas de 1x7, como observado na Figura 17 que representa duas convoluções 3x3 substituindo uma 5x5.

Figura 17 – Mini-rede representando convolução 5x5



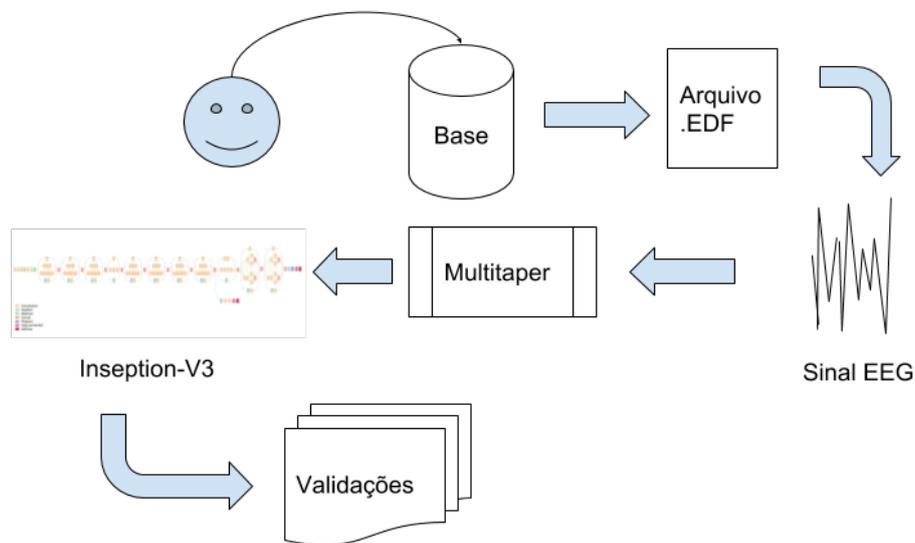
Fonte: Adaptado de (VANHOUCKE SERGEY IOFFE, 2015)

Na Figura 16 foi apresentada uma *Inception* dentro da arquitetura da rede Inception-V3 esta é primeira *Inception* observada.

### 3 METODOLOGIA

Neste capítulo é descrita a metodologia adotada para a realização deste trabalho, onde utilizou-se a Redes Neural Convolutiva profunda *Inception-V3*. Destarte, o fluxo da metodologia pode ser visto na Figura 18, onde no fluxo demonstra o processo de aquisição dos dados em um exame polissonográfico, a disponibilização em um repositório online, para a experimentação foram utilizadas duas bases, (PHISIONBANK, 2018) e (QUAN et al., 1997) disponíveis através de repositórios online também utilizadas na literatura, e gravados em arquivos do tipo *.edf*, destes são extraídos o sinal, para realizar o pré-processamento com o método *multitaper* discutido na seção 2.3, utilizada como entrada para a Rede convolutiva profunda *Inception-V3* discutida na seção 2.4.2, e em seguida aplicada aos métodos de avaliação da metodologia.

Figura 18 – Imagem representando a metodologia adotada neste trabalho.



Fonte: Elaborado pelo Autor.

### 3.1 Dados PhysioNet

Trata-se de dados de exames polissonográficos, adquiridos através do repositório *online physioNet*, disponível em PhisionBank (2018), muito utilizado na literatura como pode ser observados nos trabalhos de Hassan e Bhuiyan (2016a), Hassan e Bhuiyan (2016b), Rodríguez-Sotelo et al. (2014), Hsu et al. (2013), Liu et al. (2010), Wei et al. (2017), Vilamala, Madsen e Hansen (2017), Sharma, Pachori e Upadhyay (2017), Peker (2016) e Aboalayon et al. (2016).

Deste repositório, foram utilizados os dados do banco *Sleep-EDF Database [Expanded]*. Que possui 61 polissonografias com seus respectivos hipnogramas, se constituindo de anotações das fases do sono feitas por especialistas em relação a 42 indivíduos em dois estudos.

O primeiro estudo foi realizado com 20 indivíduos saudáveis, com idade entre 25-34 anos, com duas polissonografias de 20 horas de noite consecutivas para 19 indivíduos, para observar o efeito da idade no sono. No segundo, foi realizado em 22 indivíduos com dificuldade leve em adormecer, porém saudáveis, polissonografias de 9 horas de cada indivíduo com placebo, a fim de observar os efeitos do temazepam sobre o sono.

Para tanto, os dados estão no formato EDF, onde foram gravados exames de polissonografia de uma noite inteira, contendo o EEG (Eletroencefalograma) deste foram gravados os canais Fpz-Cz e Pz-Oz, o EOG (Eletrooculograma) EMG de queixo submentoniano e um marcador de eventos e arquivos contendo as anotações dos padrões dos sons, chamados de hipnogramas. Este contém as marcações dos estágios do sono anotadas por especialistas. Para este estudo, foi utilizado a base com 20 pessoas saudáveis com idade entre 25-34 anos, dela foi utilizado um único canal EEG, dividido em épocas de 150 segundos.

### 3.2 Dados SHHS-1

Trata-se de exames de polissonografia, adquiridos através dos repositórios online SHHS-100 (QUAN et al., 1997), construído a partir de um estudo de saúde do coração e do sono que é um estudo de corte multicêntrico, desenvolvido pelo Instituto Nacional Americano de Coração, Pulmão e Sangue para determinar uma associação entre os distúrbios respiratórios do sono ao risco de doenças cardiovasculares. Utilizado na literatura por possuir um grande número de amostras, tornando-se ideal para a classificação automática do sono.

O Sleep Heart Health Study (SHHS) é um estudo com o intuito de realizar pesquisas a fim de compreender melhor a apneia obstrutiva do sono, que conta com os exames polissonográficos de 5793 pacientes adultos com idade igual ou superior a 40 anos. Este possui dois grupos de exames, neste trabalho foi utilizado a SHHS-1 utilizada em (SORS

et al., 2018) pois inclui quase todos os pacientes do estudo tendo uma mesma taxa de amostragem de 125 Hz, este conjunto de dados contém 5793 registros polissonográficos.

Nos exames realizados Os canais capturados incluem dois canais EEG bipolares (C4-A1 e C3-A2), dois canais EOG, um canal EMG, um canal ECG, um sensor de posição, um oxímetro de pulso, dois canais de pletismografia de indução (torácica e abdominal), sensor de fluxo de ar e um sensor de luz. A base é classificada manualmente por um único especialista ao qual marcou os estágios do sono em épocas de 30-s de acordo com Rechtschaffen e regras de pontuação de Kales, nos estágios: vigília, N1, N2, N3, N4 e REM.

### 3.3 Pré-processamento

Como pré-processamento para a análise do sinal EEG, foi utilizada a plataforma *chronux* disponível em Chronux (2018). Consiste em um pacote de *software* de código aberto desenvolvido para a análise de dados neurológicos. Tal ferramenta implementa o *software* para o processamento de séries temporais neurais, incluindo vários pacotes especializados de regressão e segmentação de áudio e outras tarefas de análise de dados. Desta ferramenta, mais especificamente, foi utilizado a técnica *multitaper*, desenvolvida na seção 2.3. O sinal processado foi o Fpz este pode ser visto na Figura 6. Na Figura 19, é possível ver um exemplo de imagem gerada a partir de processamento de sinal gerado pelo *chronux*.

Para a geração das imagens de *multitaper*, foram utilizados os mesmo parâmetros descritos em Vilamala, Madsen e Hansen (2017). Neste experimento, foi utilizado o método *mtspecgramc* da plataforma (CHRONUX, 2018) para calcular o espectro do *multitaper* em uma janela móvel com largura de tempo ajustável e tamanho de passo em segundos. Esta função recebe como parâmetro os seguintes dados: a janela de deslizamento  $\omega$  em segundos, o passo da janela  $\sigma$  em segundos, a frequência de amostragem  $f$  em Hz geralmente expressa como  $W = \omega f/2$  e o número de tapers, muitas vezes definido com a heurística  $L = \lfloor 2W \rfloor - 1$  onde  $L = \lfloor x \rfloor$ , e é definida como uma função de arredondamento de  $x$  para inteiro.

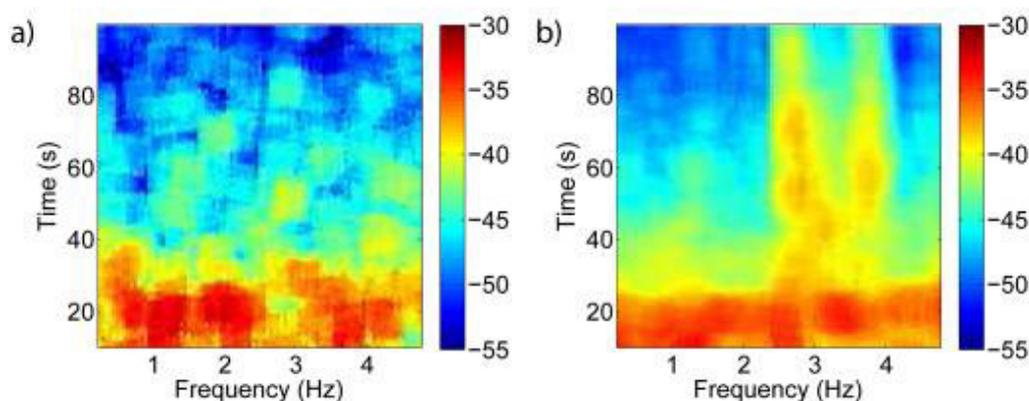
Após de realizar o calculo do espectro, é obtido uma matriz de pontos. Dessa forma, esses valores foram convertidos para a escala logarítmica definida como  $x = \lg(x + 1)$  e assim divididos em caixas de tamanho iguais  $s = 150$  s, chamadas épocas. Feito isto, a matriz gerada de cada época de espectrograma foi convertida em uma matriz de cores RGB, ou seja transformando os valores reais em um intervalo entre  $[0, 1]$  gerando-se assim a imagem.

Os parâmetros utilizados no método *mtspecgramc*, para a realização do cálculo do espectro neste trabalho foram:  $\omega = 3.0s$ ,  $f = 2Hz$  e  $L = 5$  tapers, pois o objetivo é capturar a dinâmica do sono na escala do tempo dos microeventos, mantendo uma

resolução estreita. O tamanho do passo da janela foi definido como  $\sigma = 0.67s$  que corresponde à resolução final da imagem gerada 224 x 224 px, a duração desta janela temporal foi ajustada para  $s = 150$ , que corresponde a época atual, mais duas anteriores e duas posteriores.

Os valores do log do espectograma foram limitados ao intervalo  $[0, 1]$  antes de aplicar o *Colormap Jet*<sup>1</sup> para geração das imagens, ao todo foram geradas 38 mil amostras.

Figura 19 – Imagem representando o *multitaper* gerado pelo Chronux



Fonte: Adaptado de (CHRONUX, 2018)

### 3.4 Experimentos

Para os experimentos, foi realizado o treinamento da rede *Inception-V3* discutida na seção 2.4.2. Ao todo foram realizados 2 experimentos, o primeiro com 20 épocas de treinamento, e levou cerca de 6 horas no aprendizado, treino e testes, neste foi utilizada a base do repositório online disponível em PhisionBank (2018) discutida na seção 3.1, o segundo foi realizado com 4 épocas de treinamento, e levou cerca de 12 horas para convergir, para este foi utilizada a base disponibilizada em Quan et al. (1997) discutida na seção 3.2. Estes foram treinados em uma máquina com 8gb de memória, i7 8600 e placa nvidia gtx 1060.

Como entrada para as redes, foi realizado o pré-processamento de um único sinal do EEG (Eletroencefalograma), o Fpz-Cz foi utilizado no Experimento 1, este trata-se do sinal frontal, durante o Experimento 2 foi utilizado o sinal C4-A1, que trata-se do sinal central, estes são definidos na Figura 6, utilizado o *multitaper*, discutido na seção 2.3,

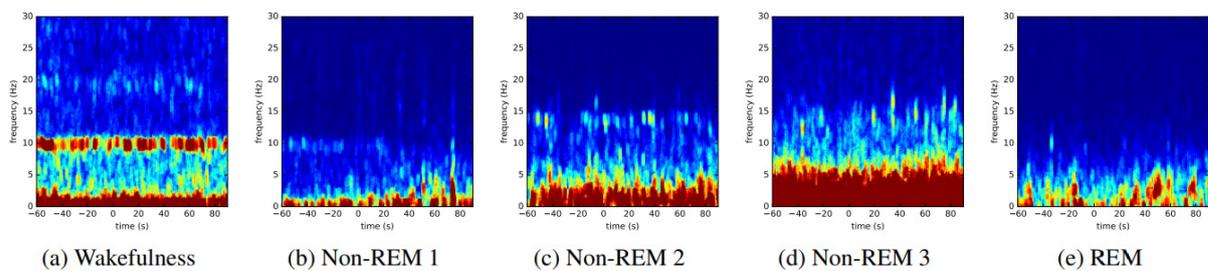
<sup>1</sup> Função que retorna o mapa de cores do jato como uma matriz de três colunas com o mesmo número de linhas que o mapa de cores da figura atual. Se nenhuma figura existir, o número de linhas será igual ao tamanho padrão de 64. Cada linha da matriz contém as intensidades vermelha, verde e azul para uma cor específica. As intensidades estão representadas no intervalo  $[0,1]$  e o esquema de cores é semelhante a Figura 19, a faixa de cor é representada nesta figura no intervalo  $[-55,-30]$ . (MATHWORKS, 2018)

como um gerador de imagens visualmente interpretáveis dos estágios do sono de épocas 150 segundos, aqui referidas como amostras.

No Experimento 1 foram utilizados 38.168 amostras, destas para o treino foram utilizadas 26.710 amostras no total da soma de amostras das 5 classes, para a realização dos testes foram utilizadas 5.727 amostras no total somado de todas as classes. No segundo experimento para a realização do treinamento foram utilizadas 464.874 amostras no total obtido através da soma das amostras de cada classe, para o teste foram utilizados 199.232 amostras no total.

Na validação do primeiro experimento foram utilizadas 5.731 amostras no total, onde foram realizadas variações nos parâmetros, no entanto estes não obtiveram mudança significativa nos resultados. Para o Segundo experimento não foram realizadas validações pois este por ser utilizada uma base muito grande o custo da experimentação extensiva se tornou inviável, assim utilizou-se os parametros normais da rede sem variações. Na Figura 20, são apresentados os estágios do sono, representados pelo *multitaper* gerado pelo *chronux*, apresentados em Vilamala, Madsen e Hansen (2017).

Figura 20 – Imagem representando o *multitaper* gerado pelo Chronux com a distinção entre os estágios do sono. Em (a) é observado a representação do estágio de vigília, em (b) é representado o estágio N1, em (c) é representado o estágio N2, em (d) é representado o estágio N3 e por fim em (e) é representado estágio REM.



Fonte: Adaptado de (VILAMALA; MADSEN; HANSEN, 2017)

A base (PHISIONBANK, 2018) foi dividida em 60% de treino, 20% de validação e 20% de teste, já a base Quan et al. (1997) foi dividida em 70% de treino, 30% de teste desta foram calculados a precisão, sensibilidade, F1-score e acurácia.

## 4 RESULTADOS

Neste capítulo são apresentados os resultados do método de avaliação, obtidos através do cenário apresentado no capítulo 3. Diante disso, a transformação do sinal do EEG em imagens visualmente interpretáveis, aqui representadas através do *multitaper*, se tornam realmente úteis no estagiamento, pois têm uma boa a visualização dos estágios e foi possível realizar o treinamento na rede convolutiva *Inception-v3*, uma vez que os estágios puderam ser distinguíveis entre si.

### 4.1 Resultados da Metodologia

Para a apresentação dos resultados, foi utilizado o cálculo da média ponderada definida em Bonini e Bonini (1972) e representada pela Equação 4.1, onde  $w$  representa o peso, para o problema apresentado neste trabalho o peso refere-se a quantidade de amostras de cada classe e  $m$  o valor obtido no cálculo da métrica em cada classe.

$$MF = \frac{\sum_1^n m_i \times w_i}{\sum_i w_i} \quad (4.1)$$

Durante o treinamento do Experimento 1 foram obtidos 0.8868% de acurácia e durante o teste foram obtidos 0.8726%, já no treinamento do Experimento 2 foram obtidos 0.90% de acurácia, pois foi utilizada a técnica *early stopping*<sup>1</sup> do inglês *parada antecipada*, para se evitar o *overfitting*.

Na Tabela 3 são apresentados os resultados obtidos durante o teste do Experimento 1, e na Tabela 4 são apresentados os resultados obtidos no Experimento 2, nas tabelas as colunas denominadas *Suporte* representam as quantidades de amostras utilizadas de cada estágio, utilizadas como peso no cálculo da média ponderada de cada classe, demonstrada na ultima linha de cada tabela. Como resultado obtidos na validação do primeiro experimento foram obtidos em média 0.8736% de precisão, 0.8742% de sensibilidade, 0.8726% de acurácia e 0.8684% de F1-score e no segundo experimento 0.8595% de precisão, 0.8604% de sensibilidade, 0.86% de acurácia e 0.8576% de F1-score.

Por conseguinte, ao comparar os resultados obtidos com a VggNet (SIMONYAN K. E ZISSERMAN, 2014), no treinamento realizado por Vilamala, Madsen e Hansen (2017) é importante ressaltar que, a avaliação do método realizado foi feito em dois cenários, no primeiro este realizou a extração de características através da rede VggNet definida no

<sup>1</sup> Trata-se de um método para regular o treinamento durante um processamento de algoritmos de aprendizagem de máquina. Este força uma parada do treinamento antes que este se super-ajuste aos dados, levando ao *overfitting*, como demonstrado em Girosi, Jones e Poggio (1995)

Tabela 3 – Resultados da Classificação do Experimento 1.

Classes	Precisão	Sensibilidade	F1-score	Suporte
<b>N1</b>	0.63	0.51	0.56	393
<b>N2</b>	0.91	0.90	0.90	2638
<b>N3</b>	0.81	0.91	0.85	849
<b>Vigília</b>	0.88	0.91	0.89	1131
<b>REM</b>	0.94	0.88	0.91	701
<b>Avg/total</b>	0.8736	0.8742	0.8684	5721

Tabela 4 – Resultados da Classificação do Experimento 2.

Classes	Precisão	Sensibilidade	F1-score	Suporte
<b>N1</b>	0.48	0.37	0.42	7525
<b>N2</b>	0.86	0.89	0.87	83587
<b>N3</b>	0.84	0.79	0.82	25209
<b>Vigília</b>	0.84	0.87	0.85	28137
<b>REM</b>	0.93	0.91	0.92	54774
<b>Avg</b>	0.8595	0.8604	0.8576	199232

trabalho como *feature extractor* (VGG-FE), onde as camadas convolutivas foram mantidas fixas e somente as 3 últimas camadas completamente conectadas foram treinadas do zero com o EEG especificado. No segundo cenário, os pesos foram atualizados e obtiveram uma versão da vggNet sincronizada definida no trabalho como *Fine-tune Network* (VGG-FT).

Na Tabela 5, é apresentada a comparação dos resultados obtidos no Experimento 1, através da metodologia aplicada neste trabalho com a metodologia aplicada em Vilamala, Madsen e Hansen (2017). Através desta comparação o desempenho no treinamento da rede *Inception-V3* obteve a acurácia, F1-score e Sensibilidade superiores atingindo os 87.26%, 86.8% e 87.4% respectivamente aproximadamente em relação a VGG-FT que obteve um valor máximo de 84% de F1-score, 78% de sensibilidade e 86% de acurácia, no entanto a *Inception-V3* obteve pouca precisão obtendo 87.36% quando comparado com VGG-FT que obteve 93% de precisão.

Tabela 5 – Comparação dos resultados obtidos no Experimento 1 e a proposta realizada por Vilamala, Madsen e Hansen (2017).

	Precisão	Sensibilidade	F1-score	acurácia
<b>VGG-FE</b>	91%	73%	81%	83%
<b>VGG-FT</b>	93%	78%	84%	86%
<b>Inception-V3</b>	87.36%	87.42%	86.84%	87.26%

A comparação do segundo experimento com a metodologia aplicada em Vilamala, Madsen e Hansen (2017) e a base utilizada em Sors et al. (2018) é representado na tabela 6. Assim na tabela é possível observar que *Inception-V3* obteve uma precisão atingindo os 0.8595% arredondando-se este valor obtêm-se 0.86% e a rede convolutiva proposta em

(SORS et al., 2018) atingiu os mesmo 86%, deste modo a rede *Inception-V3* utilizando imagens visualmente interpretáveis obteve o estado da arte. A acurácia obtida foi de 86%, assim ao comparar com o resultado da acurácia da média ponderada de Sors et al. (2018) que obteve 87% a *Inception-V3* obteve um resultado inferior. Neste experimento foi utilizado um único canal, utilizar mais canais pode melhorar os resultados obtidos.

Tabela 6 – Comparação dos resultados obtidos no Experimento 2 e a proposta realizada por Sors et al. (2018).

	Precisão	Sensibilidde	Acurácia
<b>CNN</b>	86%	87%	87%
<b>Inception-V3</b>	85.95%	86.04%	86%

Para realizar uma comparação com os trabalhos encontrados na literatura, é importante ressaltar que muitos estudos que realizam o estagiamento automático do sono realizam as suas classificações em diferentes classes.

No entanto, é possível encontrar trabalhos que realizam a classificação em 2, sendo as classes REM e Não-Rem, 3 sendo as classes REM, Não-Rem e Vigília, 4 sendo as classes REM, N-1, ondas lentas e Vigília, 5 sendo as classes REM, N1, N2,N3+N4 e Vigília e 6 sendo as classes REM, N1, N2, N3, N4 e Vigília , além de muitos utilizarem bancos privados que não estão disponíveis para a comunidade.

Foram encontrados também, trabalhos que utilizaram mais de um exame além do EEG, como o EOG e o EMG, associados aos sinais gerados pelo EEG. Existem trabalhos que além de utilizarem vários exames, também utilizaram vários canais do EEG para realizar o estagiamento.

Portanto, na revisão bibliográfica foram definidos os trabalhos que propuseram o estagiamento utilizando a as redes neurais como classificadores, que utilizassem apenas um canal do EEG e realizassem o estagiamento em 5 classes sendo elas o REM, N1,N2,N3+N4 e vigília. Deste modo é possível destacar Ebrahimi et al. (2008), Sors et al. (2018), Peker (2016), Hassan e Bhuiyan (2016a), Hassan e Bhuiyan (2016b), Hsu et al. (2013) e Wei et al. (2017).

Para a comparação com estes trabalhos é importante salientar que os trabalhos de Ebrahimi et al. (2008), Peker (2016) e Hassan e Bhuiyan (2016a), utilizaram a base Sleep-EDF que contém os dados de 8 pacientes, utilizando deste apenas os dados de 4 pacientes em seus experimentos, enquanto Hassan e Bhuiyan (2016b) utilizou a base completa.

Já Sors et al. (2018), utilizou o repositório online *The Sleep Heart Health Study* (SHHS) definida em Quan et al. (1997). A base utilizada foi *Dataset SHHS-1* contendo 5793 pacientes, também utilizada neste trabalho. Em Vilamala, Madsen e Hansen (2017) e Wei et al. (2017), observa-se que este utilizou a base do *Sleep-EDF expanded* que contém 42

pacientes, utilizando desta os dados de 20 pacientes, o mesmo utilizados nos experimentos deste trabalho.

Os canais utilizados nos experimentos foram Fpz-Cz utilizado no Experimento 1 e C4-A1 utilizado no Experimento 2. O canal Fpz-Cz foi utilizado em Hsu et al. (2013), Wei et al. (2017), Vilamala, Madsen e Hansen (2017), o canal Pz-Oz foi utilizado por Ebrahimi et al. (2008), Peker (2016), Hassan e Bhuiyan (2016a) e Hassan e Bhuiyan (2016b), enquanto no trabalho de Sors et al. (2018) foi utilizado o canal C4-A1.

É observável que os trabalhos de Ebrahimi et al. (2008), Hassan e Bhuiyan (2016a), Hassan e Bhuiyan (2016b) utilizaram redes neurais artificiais em suas propostas, e Peker (2016) utilizou uma Rede Neural de valor complexo (CVANN), enquanto Hsu et al. (2013) utilizou uma Rede Neural Probabilística (PNN), redes que não utilizaram transferência de aprendizado sendo treinadas do zero. Já os trabalhos de Sors et al. (2018), Vilamala, Madsen e Hansen (2017) e Wei et al. (2017) utilizaram redes neurais convolutivas.

Para a extração de características, Ebrahimi et al. (2008) utilizou a análise de frequência de tempo (Transformada *Wavelet*), enquanto Hassan e Bhuiyan (2016a) utilizou Entropia aproximada (ApEn), Dimensão de correlação (CD), Maior expoente de Lyapunov (LLE), Dimensão fractal petrosiana (PFD) e a Codificação de fase da entrada. Todavia, Hassan e Bhuiyan (2016b) utilizou a técnica *Complete Ensemble Empirical Mode Decomposition with Adaptive Noise* e Hsu et al. (2013) utilizou seis filtros de passagem de banda de resposta ao impulso finito (FIR) nas ondas alpha, beta, teta, delta, fuso e dente de serra.

Na Tabela 7, é apresentado uma comparação dos trabalhos encontrados na literatura e a metodologia proposta neste trabalho, nela é possível observar que (EBRAHIMI et al., 2008) e (PEKER, 2016) obtiveram as maiores acurácias com 93% e 93.84% respectivamente.

Tabela 7 – Comparação dos resultados obtidos e trabalhos relacionados encontrados na literatura.

	Banco	Pacientes	Canal	Classes	Técnica	Acurácia
(EBRAHIMI et al., 2008)	Sleep-EDF	4	Pz-Oz	5	ANN	93%
(SORS et al., 2018)	SHHS-1	5793	C4-A1	5	CNN	87%
(PEKER, 2016)	Sleep-EDF	4	Pz-Oz	5	CVANN	93.84%
(HASSAN; BHUIYAN, 2016a)	Sleep-EDF	4	Pz-Oz	5	ANN	71.68%
(HASSAN; BHUIYAN, 2016b)	Sleep-EDF	8	Pz-Oz	5	ANN	81.28%
(HSU et al., 2013)	Sleep-EDF	8	Fpz-Cz	5	PNN	81.8%
(WEI et al., 2017)	Sleep-EDF [Ex]	20	Fpz-Cz	5	CNN	84.50%
(VILAMALA; MADSEN; HANSEN, 2017)	Sleep-EDF [Ex]	20	Fpz-Cz	5	CNN - VggNet	86%
Este Trabalho	Sleep-EDF [Ex]	20	Fpz-Cz	5	CNN - Inception-V3	87.26%
Este Trabalho	SHHS-1	5793	C4-A1	5	CNN - Inception-V3	86%

Nos trabalhos de Vilamala, Madsen e Hansen (2017) e Wei et al. (2017), foram utilizados espectrogramas para gerar imagens distintas entre os estágios, no primeiro foi utilizada a rede convolutiva VGGNet e como entrada a técnica *multitaper* para gerar as imagens, enquanto o segundo utilizou a espectrometria de Tempo-Frequência baseado na

transformada de Hilbert-Huang definida em Huang (2014) como entrada para uma rede convolutiva. Este trabalho utilizou a rede convolutiva *Inception-V3*, onde foram utilizados imagens geradas com a técnica *multitaper* para gerar imagens visualmente distintas entre as classes, em contra partida Sors et al. (2018) não utilizou nenhum pré-processamento.

No entanto, vale ressaltar que estes utilizaram uma base menor em sua metodologia e (HASSAN; BHUIYAN, 2016a) obteve a menor acurácia com 71%. Entre os trabalhos que utilizaram uma base maior disponibilizada no repositório online PhisionBank (2018), a maior acurácia foi obtida no Experimento 1 deste trabalho com 87.26%. No Experimento 2 no qual foi utilizada a base *Dataset SHHS-1* e o canal C4-A1 obteve-se uma acurácia de 86% enquanto que (SORS et al., 2018) obteve uma acurácia de 87%.

## 5 CONCLUSÃO

Este trabalho apresentou um estudo para classificação automática dos estágios do sono, utilizando redes neurais convolutivas e a técnica *multitaper* como pré-processamento, cumprindo o objetivo proposto. Nesse cenário, a metodologia proposta utilizou os dados da polissonografia adquiridos através dos bancos de dados *online PhysioNet* e *SHHs-100*, mais precisamente o EEG, utilizou-se um único sinal em dois experimentos distintos, no primeiro foi utilizado o canal Fpz-Oz, sendo o canal frontal localizado no lobo frontal do cérebro, e no segundo o canal C4-A1 sendo o canal central.

Para tanto, os sinais foram transformados em imagens utilizando a técnica de transformação em espectogramas o *multitaper*, colocadas como entradas para a Rede Neural Convolutiva a *Inception-V3*. A classificação foi definida em 5 classes a vigília, N1, N2, N3 e REM.

O desempenho do treinamento utilizando a rede convolutiva *Inception-V3*, obteve valores significativos precisão e F1-Score atingindo aproximadamente 87% e de acurácia 87.26% no Experimento 1, utilizando uma base com 20 pessoas, e no Experimento 2 obteve uma precisão de aproximadamente 86% atingindo o estado da arte e sensibilidade de 86.04 acurácia de 86% utilizando uma base com 5793 pessoas, deste modo é observado que a classificação utilizando imagens geradas a partir de espectros do sinal, tornam a visualização dos estágios mais perceptíveis aos olhos e obtém resultados relevantes quando comparado com outros trabalhos.

Com essas observações, é possível dizer que esta metodologia tem um bom poder discriminatório entre os estágios do sono, e a tarefa de estagiamento pode ser enquadrada como uma tarefa de processamento de imagens, visto que a abordagem visual aumenta a percepção do especialista do sono, fornecendo padrões interpretáveis que mostram os estágios de forma distinta.

Por fim, este trabalho evidenciou que o estagiamento utilizando as redes convolutivas têm um bom desempenho no estagiamento automático do sono, mais necessariamente quando se utilizam imagens como entrada para a rede.

### 5.1 Trabalhos Futuros

A partir da metodologia aplicada, percebe-se que esta se apresenta como promissora e serve de base para o desenvolvimento de novas abordagens. Através da ideia principal de utilizar os *multitapers* como técnica de pré-processamento, e realizar experimentos utilizando outras redes convolutivas e técnicas de classificação, realizar experimentos com

outras configurações *cross-validation* de testes, treinos e validação. Todavia, a aquisição de bases maiores também poderia melhorar o desempenho do classificador.

Realizar o pré-processamento utilizando o *multitaper* para análise de outros canais EEG como o canal occipital e o canal central. Utilizar outros exames adquiridos através da polissonografia associados ao EEG, buscando melhorar o desempenho do classificador, como o EOG, EMG e ECG gerando imagens visualmente distinguíveis entre si, poderiam exercer uma influência positiva durante a classificação.

# Referências

- ABOALAYON, K. A.; FAEZIPOUR, M. Multi-class svm based on sleep stage identification using eeg signal. In: IEEE. *Healthcare Innovation Conference (HIC), 2014 IEEE*. Melbourne, Australia, 2014. p. 181–184. Citado na página 15.
- ABOALAYON, K. A. I.; FAEZIPOUR, M.; ALMUHAMMADI, W. S.; MOSLEHPOUR, S. Sleep stage classification using eeg signal analysis: a comprehensive survey and new investigation. *Entropy*, Multidisciplinary Digital Publishing Institute, v. 18, n. 9, p. 272, 2016. Citado 4 vezes nas páginas 15, 16, 17 e 44.
- AL-SHAIKH, R. Sleep monitoring technology. 2016. Citado na página 13.
- ASERINSKY, E.; KLEITMAN, N. et al. Regularly occurring periods of eye motility, and concomitant phenomena, during sleep. *Science*, v. 118, n. 3062, p. 273–274, 1953. Citado na página 22.
- BARRETO, J. M. Introduçaoas redes neurais artificiais. *V Escola Regional de Informática. Sociedade Brasileira de Computação, Regional Sul, Santa Maria, Florianópolis, Maringá*, p. 5–10, 2002. Citado na página 32.
- BOKIL, H.; ANDREWS, P.; KULKARNI, J. E.; MEHTA, S.; MITRA, P. P. Chronux: a platform for analyzing neural signals. *Journal of neuroscience methods*, Elsevier, v. 192, n. 1, p. 146–151, 2010. Citado na página 30.
- BONINI, E. E.; BONINI, S. E. *Estatística: teoria e exercícios*. [S.l.]: Nobel, 1972. Citado na página 48.
- BOOSTANI, R.; KARIMZADEH, F.; NAMI, M. A comparative review on sleep stage classification methods in patients and healthy individuals. *Computer methods and programs in biomedicine*, Elsevier, v. 140, p. 77–91, 2017. Citado na página 17.
- BUZSAKI, G. *Rhythms of the Brain*. Oxford, United Kingdom: Oxford University Press, 2006. Citado na página 22.
- CARSKADON, M. A.; DEMENT, W. C. et al. Normal human sleep: an overview. *Principles and practice of sleep medicine*, Saunders, v. 4, p. 13–23, 2005. Citado na página 14.
- CATON, R. The eletric currents of the brain. *Br Med J*, 1975. Citado na página 22.
- CHARBONNIER, S.; ZOUBEK, L.; LESECQ, S.; CHAPOTOT, F. Self-evaluated automatic classifier as a decision-support tool for sleep/wake staging. *Computers in Biology and Medicine*, Elsevier, v. 41, n. 6, p. 380–389, 2011. Citado na página 17.
- CHEN, X.; WANG, B.; WANG, X. Automatic sleep stage classification for daytime nap based on hopfield neural network. In: IEEE. *Control and Decision Conference (CCDC), 2013 25th Chinese*. Guiyang, China, 2013. p. 2671–2674. Citado na página 17.

CHRISKOS, P.; KAITALIDOU, D. S.; KARAKASIS, G.; FRANTZIDIS, C.; GKIVOGKLI, P. T.; BAMIDIS, P.; KOURTIDOU-PAPADELI, C. Automatic sleep stage classification applying machine learning algorithms on eeg recordings. In: IEEE. *Computer-Based Medical Systems (CBMS), 2017 IEEE 30th International Symposium on*. Thessaloniki, Greece, 2017. p. 435–439. Citado na página 17.

CHRONUX. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2934871/>. 2018. Citado 3 vezes nas páginas 31, 45 e 46.

COLLOBERT, R.; WESTON, J. A unified architecture for natural language processing: Deep neural networks with multitask learning. In: ACM. *Proceedings of the 25th international conference on Machine learning*. New York, USA, 2008. p. 160–167. Citado na página 35.

CORREA, A. G.; LEBER, E. L. An automatic detector of drowsiness based on spectral analysis and wavelet decomposition of eeg records. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*. Buenos Aires, Argentina, 2010. p. 1405–1408. Citado 2 vezes nas páginas 15 e 17.

CORREA, A. G.; OROSCO, L.; LACIAR, E. Automatic detection of drowsiness in eeg records based on multimodal analysis. *Medical Engineering and Physics*, Elsevier, v. 36, n. 2, p. 244–249, 2014. Citado 2 vezes nas páginas 16 e 17.

DAHLEN, F.; SIMONS, F. J. Spectral estimation on a sphere in geophysics and cosmology. *Geophysical Journal International*, Blackwell Publishing Ltd Oxford, UK, v. 174, n. 3, p. 774–807, 2008. Citado na página 30.

DONG, H.; SUPRATAK, A.; PAN, W.; WU, C.; MATTHEWS, P. M.; GUO, Y. Mixed neural network approach for temporal sleep stage classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 26, n. 2, p. 324–333, 2018. Citado na página 17.

DURSUN, M.; GUNES, S.; OZSEN, S.; YOSUNKAYA, S. Comparison of artificial immune clustering with fuzzy c-means clustering in the sleep stage classification problem. In: IEEE. *Innovations in Intelligent Systems and Applications (INISTA), 2012 International Symposium on*. Trabzon, Turkey, 2012. p. 1–4. Citado na página 17.

EBRAHIMI, F.; MIKAEILI, M.; ESTRADA, E.; NAZERAN, H. Automatic sleep stage classification based on eeg signals by using neural networks and wavelet packet coefficients. In: IEEE. *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*. Vancouver, Canada, 2008. p. 1151–1154. Citado 4 vezes nas páginas 17, 18, 50 e 51.

FAROOQ, H.; JAIN, A. A novel computer assisted automatic sleep scoring system by employing artificial neural network—a review. *International Journal of Sensors and Sensor Networks*, Science Publishing Group, v. 5, n. 3, p. 43, 2017. Citado na página 17.

FERNANDES, R. M. F. O sono normal. *Medicina (Ribeirao Preto. Online)*, v. 39, n. 2, p. 157–168, 2006. Citado 2 vezes nas páginas 21 e 22.

FERRARA, M.; GENNARO, L. D. How much sleep do we need? *Sleep Medicine Reviews*, v. 5, n. 2, p. 155 – 179, 2001. ISSN 1087-0792. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1087079200901382>>. Citado na página 13.

- FRAIWAN, L.; LWEESY, K.; KHASAWNEH, N.; FRAIWAN, M.; WENZ, H.; DICKHAUS, H. Classification of sleep stages using multi-wavelet time frequency entropy and lda. *Methods of information in Medicine*, Schattauer GmbH, v. 49, n. 03, p. 230–237, 2010. Citado na página 16.
- FRAIWAN, L.; LWEESY, K.; KHASAWNEH, N.; FRAIWAN, M.; WENZ, H.; DICKHAUS, H. Time frequency analysis for automated sleep stage identification in fullterm and preterm neonates. *Journal of medical systems*, Springer, v. 35, n. 4, p. 693–702, 2011. Citado na página 17.
- GARCIA-MOLINA, G.; BAEHR, K.; STEELE, B.; TSONEVA, T.; PFUNDTNER, S.; RIEDNER, B.; WHITE, D. P.; TONONI, G. Automatic characterization of sleep need dissipation using a single hidden layer neural network. In: IEEE. *Signal Processing Conference (EUSIPCO), 2017 25th European*. Kos island, Greece, 2017. p. 1305–1308. Citado na página 17.
- GIROSI, F.; JONES, M.; POGGIO, T. Regularization theory and neural networks architectures. *Neural computation*, MIT Press, v. 7, n. 2, p. 219–269, 1995. Citado na página 48.
- GOMES, M. da M. Bases fisiológicas do eletroencefalograma. *Revista Brasileira de Neurologia*, v. 51, n. 1, 2015. Citado na página 25.
- GUDMUNDSSON, S.; RUNARSSON, T. P.; SIGURDSSON, S. Automatic sleep staging using support vector machines with posterior probability estimates. In: IEEE. *Computational Intelligence for Modelling, Control and Automation, 2005 and International Conference on Intelligent Agents, Web Technologies and Internet Commerce, International Conference on*. Vienna, Austria, 2005. v. 2, p. 366–372. Citado 2 vezes nas páginas 15 e 16.
- HASSAN, A. R.; BHUIYAN, M. I. H. Automatic sleep scoring using statistical features in the emd domain and ensemble methods. *Biocybernetics and Biomedical Engineering*, Elsevier, v. 36, n. 1, p. 248–255, 2016. Citado 8 vezes nas páginas 15, 16, 17, 18, 44, 50, 51 e 52.
- HASSAN, A. R.; BHUIYAN, M. I. H. Computer-aided sleep staging using complete ensemble empirical mode decomposition with adaptive noise and bootstrap aggregating. *Biomedical Signal Processing and Control*, Elsevier, v. 24, p. 1–10, 2016. Citado 7 vezes nas páginas 15, 16, 17, 18, 44, 50 e 51.
- HSU, Y.-L.; YANG, Y.-T.; WANG, J.-S.; HSU, C.-Y. Automatic sleep stage recurrent neural classifier using energy features of eeg signals. *Neurocomputing*, Elsevier, v. 104, p. 105–114, 2013. Citado 4 vezes nas páginas 17, 44, 50 e 51.
- HUANG, C.-S.; LIN, C.-L.; KO, L.-W.; LIU, S.-Y.; SUA, T.-P.; LIN, C.-T. A hierarchical classification system for sleep stage scoring via forehead eeg signals. In: IEEE. *Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB), 2013 IEEE Symposium on*. Singapore, 2013. p. 1–5. Citado na página 15.
- HUANG, L.; SUN, Q.; CHENG, J. Novel method of fast automated discrimination of sleep stages. In: IEEE. *Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE*. Cancún, Mexico, 2003. v. 3, p. 2273–2276. Citado na página 17.

- HUANG, N. E. *Hilbert-Huang transform and its applications*. USA: World Scientific, 2014. v. 16. Citado na página 52.
- HUBEL, D. H. *The brain*. USA: Freeman, San Francisco, 1979. 2–14 p. Citado na página 31.
- JAIN, V. P.; MYTRI, V.; SHETE, V.; SHIRAGAPUR, B. Sleep stages classification using wavelet transform & neural network. In: IEEE. *Biomedical and Health Informatics (BHI), 2012 IEEE-EMBS International Conference on*. San Diego, California, 2012. p. 71–74. Citado 2 vezes nas páginas 16 e 17.
- JANSON, C.; LINDBERG, E.; GISLASON, T.; ELMASRY, A.; BOMAN, G. Insomnia in men—a 10-year prospective population based study. *Sleep*, Oxford University Press, v. 24, n. 4, p. 425–430, 2001. Citado na página 13.
- JASPER, H. The ten-twenty electrode system of the international federation. *Electroencephalin Neurophysiol*, v. 10, p. 367–380, 1958. Citado na página 26.
- KAYIKCIOGLU, T.; MALEKI, M.; EROGLU, K. Fast and accurate pls-based classification of eeg sleep using single channel data. *Expert Systems with Applications*, Elsevier, v. 42, n. 21, p. 7825–7830, 2015. Citado na página 16.
- KHALIGHI, S.; SOUSA, T.; OLIVEIRA, D.; PIRES, G.; NUNES, U. Efficient feature selection for sleep staging based on maximal overlap discrete wavelet transform and svm. In: IEEE. *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*. San Diego, California, 2011. p. 3306–3309. Citado na página 16.
- KHALIGHI, S.; SOUSA, T.; PIRES, G.; NUNES, U. Automatic sleep staging: a computer assisted approach for optimal combination of features and polysomnographic channels. *Expert Systems with Applications*, Elsevier, v. 40, n. 17, p. 7046–7059, 2013. Citado 3 vezes nas páginas 15, 16 e 25.
- KLEITMAN, N. *Sleep and wakefulness*. Chicago, Illinois: University of Chicago Press, 1963. Citado na página 22.
- KOHTOH, S.; TAGUCHI, Y.; MATSUMOTO, N.; WADA, M.; HUANG, Z.-L.; URADE, Y. Algorithm for sleep scoring in experimental animals based on fast fourier transform power spectrum analysis of the electroencephalogram. *Sleep and Biological Rhythms*, Springer, v. 6, n. 3, p. 163–171, 2008. Citado na página 29.
- KOLEY, B.; DEY, D. An ensemble system for automatic sleep stage classification using single channel eeg signal. *Computers in biology and medicine*, Elsevier, v. 42, n. 12, p. 1186–1195, 2012. Citado na página 16.
- KUO, C.-E.; LIANG, S.-F. Automatic stage scoring of single-channel sleep eeg based on multiscale permutation entropy. In: IEEE. *Biomedical Circuits and Systems Conference (BioCAS), 2011 IEEE*. San Diego, USA, 2011. p. 448–451. Citado na página 16.
- LAN, K.-C.; CHANG, D.-W.; KUO, C.-E.; WEI, M.-Z.; LI, Y.-H.; SHAW, F.-Z.; LIANG, S.-F. Using off-the-shelf lossy compression for wireless home sleep staging. *Journal of neuroscience methods*, Elsevier, v. 246, p. 142–152, 2015. Citado na página 15.

- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2324, 1998. Citado 3 vezes nas páginas 35, 36 e 39.
- LEE, H.; PHAM, P.; LARGMAN, Y.; NG, A. Y. Unsupervised feature learning for audio classification using convolutional deep belief networks. In: *Advances in neural information processing systems*. Vancouver, B.C., Canada: NIPS, 2009. p. 1096–1104. Citado na página 35.
- LEE, Y.-H.; CHEN, Y.-S.; CHEN, L.-F. Automated sleep staging using single eeg channel for rem sleep deprivation. In: IEEE. *Bioinformatics and BioEngineering, 2009. BIBE'09. Ninth IEEE International Conference on*. Taichung, Taiwan, 2009. p. 439–442. Citado na página 15.
- LI, Y.; YINGLE, F.; GU, L.; QINYE, T. Sleep stage classification based on eeg hilbert-huang transform. In: IEEE. *Industrial Electronics and Applications, 2009. ICIEA 2009. 4th IEEE Conference on*. Xi'an, China, 2009. p. 3676–3681. Citado na página 16.
- LIU, Y.; CROFT, J. B.; WHEATON, A. G.; PERRY, G. S.; CHAPMAN, D. P.; STRINE, T. W.; MCKNIGHT-EILY, L. R.; PRESLEY-CANTRELL, L. Association between perceived insufficient sleep, frequent mental distress, obesity and chronic diseases among us adults, 2009 behavioral risk factor surveillance system. *BMC public health*, BioMed Central, v. 13, n. 1, p. 84, 2013. Citado na página 13.
- LIU, Y.; YAN, L.; ZENG, B.; WANG, W. Automatic sleep stage scoring using hilbert-huang transform with bp neural network. In: IEEE. *Bioinformatics and Biomedical Engineering (iCBBE), 2010 4th International Conference on*. Chengdu, China, 2010. p. 1–4. Citado 2 vezes nas páginas 17 e 44.
- LOOMIS, A. L.; HARVEY, E. N.; HOBART, G. A. Cerebral states during sleep, as studied by human brain potentials. *Journal of experimental psychology*, Psychological Review Company, v. 21, n. 2, p. 127, 1937. Citado na página 22.
- LU, J.; BEHBOOD, V.; HAO, P.; ZUO, H.; XUE, S.; ZHANG, G. Transfer learning using computational intelligence: a survey. *Knowledge-Based Systems*, Elsevier, v. 80, p. 14–23, 2015. Citado na página 41.
- MAAHS, M. A. P.; ALMEIDA, S. T. *Respiração oral e apneia obstrutiva do sono: Integração no diagnóstico e tratamento*. Rio de Janeiro, RJ: Thieme Revinter Publicações LTDA, 2017. Citado na página 25.
- MARTINS, P. J. F.; MELLO, M. T. d.; TUFIK, S. Exercício e sono. *Revista Brasileira de Medicina do Esporte*, SciELO Brasil, v. 7, n. 1, p. 28–36, 2001. Citado na página 21.
- MATHWORKS. <https://www.mathworks.com/help/matlab/ref/jet.html>. 2018. Citado na página 46.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado 2 vezes nas páginas 32 e 33.

- MORA, A. M.; FERNANDES, C. M.; HERRERA, L. J.; CASTILLO, P. A.; MERELO, J.; ROJAS, F.; ROSA, A. C. Sleeping with ants, svms, multilayer perceptrons and soms. In: IEEE. *Intelligent Systems Design and Applications (ISDA), 2010 10th International Conference on*. Cairo, Egypt, 2010. p. 126–131. Citado na página 25.
- MULC, T. Disponível em: <https://hacktilldawn.com/2016/09/25/inception-modules-explained-and-implemented/>. 2018. Citado 2 vezes nas páginas 40 e 41.
- MÜLLER, M. R.; GUIMARÃES, S. S. Impacto dos transtornos do sono sobre o funcionamento diário e a qualidade de vida. *Estudos de psicologia*, Pontifícia Universidade Católica de Campinas, v. 24, n. 4, p. 519–528, 2007. Citado na página 13.
- NIELSEN, M. A. *Neural networks and deep learning*. <http://neuralnetworksanddeeplearning.com>: Determination Press, 2015. Citado na página 34.
- OHAYON, M. M.; ROTH, T. Prevalence of restless legs syndrome and periodic limb movement disorder in the general population. *Journal of psychosomatic research*, Elsevier, v. 53, n. 1, p. 547–554, 2002. Citado na página 13.
- PARK, H.; PARK, K.; JEONG, D.-U. Hybrid neural-network and rule-based expert system for automatic sleep stage scoring. In: IEEE. *Engineering in Medicine and Biology Society, 2000. Proceedings of the 22nd Annual International Conference of the IEEE*. [S.l.], 2000. v. 2, p. 1316–1319. Citado na página 17.
- PEKER, M. An efficient sleep scoring system based on eeg signal using complex-valued machine learning algorithms. *Neurocomputing*, Elsevier, v. 207, p. 165–177, 2016. Citado 5 vezes nas páginas 17, 18, 44, 50 e 51.
- PHISIONBANK. Disponível em: <https://www.physionet.org/physiobank/database/>. 2018. Citado 8 vezes nas páginas 15, 17, 18, 43, 44, 46, 47 e 52.
- POYARES, D.; ANDRÉ, W. d. S.; PALOMBINI, L. *Farmacologia do Sono*. 2018. Disponível em: <[http://www.psiquiatrianet.com.br/sono/farma\\_sono.htm](http://www.psiquiatrianet.com.br/sono/farma_sono.htm)>. Citado na página 13.
- PRATT, L. Y. Discriminability-based transfer between neural networks. In: *Advances in neural information processing systems*. Cambridge, Massachusetts: The MIT Press, 1993. p. 204–211. Citado na página 41.
- QUAN, S. F.; HOWARD, B. V.; IBER, C.; KILEY, J. P.; NIETO, F. J.; O’CONNOR, G. T.; RAPOPORT, D. M.; REDLINE, S.; ROBBINS, J.; SAMET, J. M. et al. The sleep heart health study: design, rationale, and methods. *Sleep*, Oxford University Press, v. 20, n. 12, p. 1077–1085, 1997. Citado 7 vezes nas páginas 15, 17, 43, 44, 46, 47 e 50.
- RADHA, M.; GARCIA-MOLINA, G.; POEL, M.; TONONI, G. Comparison of feature and classifier algorithms for online automatic sleep staging based on a single eeg signal. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2014 36th Annual International Conference of the IEEE*. Chicago, Illinois, 2014. p. 1876–1880. Citado 2 vezes nas páginas 15 e 16.
- RECHTSCHAFFEN, A. A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. *Public health service*, Government printing office, 1968. Citado 3 vezes nas páginas 14, 27 e 28.

- RECHTSCHAFFEN, A. Techniques and scoring systems for sleep stages of human subjects. *A Manual of Standardized Terminology*, UCLA Brain Information Service/Brain Research Institute, 1978. Citado na página 22.
- RECHTSCHAFFEN, A.; KALES, A. Techniques, and scoring system for sleep stages of human subjects: a manual of standardised terminology. *Los Angeles: UCLA Brain Information Service*, 1968. Citado na página 15.
- REIMÃO, R. Sono: estudo abrangente. *São Paulo: Atheneu*, 1996. Citado na página 13.
- ROCHA, R. H. S. *Reconhecimento de Objetos por Redes Neurais Convolutivas*. Tese (Doutorado) — PUC–Rio, 2015. Citado 2 vezes nas páginas 35 e 36.
- RODRÍGUEZ-SOTELO, J. L.; OSORIO-FORERO, A.; JIMÉNEZ-RODRÍGUEZ, A.; CUESTA-FRAU, D.; CIRUGEDA-ROLDÁN, E.; PELUFFO, D. Automatic sleep stages classification using eeg entropy features and unsupervised pattern analysis techniques. *Entropy*, Multidisciplinary Digital Publishing Institute, v. 16, n. 12, p. 6573–6589, 2014. Citado 3 vezes nas páginas 16, 17 e 44.
- ROSENBLATT, F. Principles of neurodynamics: Perceptrons and the theory of brain mechanisms. *Washington DC: Spartan*, 1962. Citado 2 vezes nas páginas 32 e 33.
- RYU, S. Y.; KIM, K. S.; HAN, M. A. Factors associated with sleep duration in korean adults: results of a 2008 community health survey in gwangju metropolitan city, korea. *Journal of Korean medical science*, v. 26, n. 9, p. 1124–1131, 2011. Citado na página 13.
- SCHLUTER, T.; CONRAD, S. An approach for automatic sleep stage scoring and apnea-hypopnea detection. In: IEEE. *Data Mining (ICDM), 2010 IEEE 10th International Conference on*. IMT Ghaziabad, India, 2010. p. 1007–1012. Citado na página 16.
- ŞEN, B.; PEKER, M.; ÇAVUŞOĞLU, A.; ÇELEBI, F. V. A comparative study on classification of sleep stage based on eeg signals using feature selection and classification algorithms. *Journal of medical systems*, Springer, v. 38, n. 3, p. 18, 2014. Citado 3 vezes nas páginas 15, 16 e 17.
- SHANNON, C. A universal Turing machine with two internal states automata studies, princeton u. *Press, Princeton, NJ*, 1956. Citado na página 31.
- SHARMA, R.; PACHORI, R. B.; UPADHYAY, A. Automatic sleep stages classification based on iterative filtering of electroencephalogram signals. *Neural Computing and Applications*, Springer, v. 28, n. 10, p. 2959–2978, 2017. Citado 2 vezes nas páginas 18 e 44.
- SIDDIQUI, F.; CHAWLA, M. Feature extraction and classification of eeg signals using neural network based techniques. *Journal of Instrumentation and Innovation Sciences*, v. 2, n. 1, 2, p. 1–10, 2017. Citado na página 17.
- SILVA, R. S. D. Introdução ao estagiamento do sono humano. *Braz J Epilepsy Clin Neurophysiol*, v. 3, n. 2, p. 187–199, 1996. Citado 5 vezes nas páginas 14, 15, 22, 28 e 29.
- SILVA, R. S. da. Introdução ao a tecnica de polissonografia. *Brazilian Journal of Epilepsy and Clinical Neurophysiology*, v. 1, n. 1, p. 23–32, 1995. Citado 5 vezes nas páginas 23, 24, 26, 27 e 28.

- SIMONYAN K. E ZISSERMAN, A. Deep convolutional neural networks for interpretable analysis of eeg sleep stage scoring. CVPR14, 2014. Citado 4 vezes nas páginas 16, 19, 35 e 48.
- SORS, A.; BONNET, S.; MIREK, S.; VERCUEIL, L.; PAYEN, J.-F. A convolutional neural network for sleep stage scoring from raw single-channel eeg. *Biomedical Signal Processing and Control*, Elsevier, v. 42, p. 107–114, 2018. Citado 8 vezes nas páginas 16, 17, 19, 45, 49, 50, 51 e 52.
- SUN, C.; SHRIVASTAVA, A.; SINGH, S.; GUPTA, A. Revisiting unreasonable effectiveness of data in deep learning era. In: IEEE. *Computer Vision (ICCV), 2017 IEEE International Conference on*. Venice, Italy, 2017. p. 843–852. Citado na página 34.
- T, L. Disponível em: <http://www.leandroteles.com.br/blog/2015/11/09/memoria-saiba-mais-sobre-essa-funcao-cerebral/>. 2018. Citado na página 31.
- TAFNER, M. A. et al. Estagiamento automático do sono utilizando um canal de eeg e uma rede neural artificial com alta representação cortical. Florianópolis, SC, 1999. Citado na página 17.
- THOMSON, D. J. Spectrum estimation and harmonic analysis. *Proceedings of the IEEE*, IEEE, v. 70, n. 9, p. 1055–1096, 1982. Citado na página 29.
- THORPY, M. J. International classification of sleep disorders: diagnostic and coding manual. diagnostic classification committee. ASDA, Rochester, Minnesota, 1990. Citado na página 23.
- TOGEIRA, S. M. G. P.; SMITH, A. K. *Revista Brasileira de Psiquiatria (RBP)*. São Paulo, SP: scielo, 2005. vol.27. p.8-15 p. Citado na página 23.
- TOGEIRO, S. M.; SMITH, A. K. Métodos diagnósticos nos distúrbios do sono. *Revista Brasileira de Psiquiatria*, SciELO Brasil, 2005. Citado na página 13.
- TSAI, P.-Y.; HU, W.; KUO, T. B.; SHYU, L.-Y. A portable device for real time drowsiness detection using novel active dry electrode system. In: IEEE. *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE*. Minneapolis/St. Paul, Minnesota, 2009. p. 3775–3778. Citado na página 17.
- TUFIK, S. *Medicina e biologia do sono*. Barueri, SP: Editora Manole Ltda, 2008. Citado na página 21.
- VANHOUCKE SERGEY IOFFE, J. S. Christian Szegedy e V. Rethinking the inception architecture for computer vision. p. 770–778, 2015. Citado 4 vezes nas páginas 19, 39, 40 e 42.
- VILAMALA, A.; MADSEN, K. H.; HANSEN, L. K. Deep convolutional neural networks for interpretable analysis of eeg sleep stage scoring. *arXiv preprint arXiv:1710.00633*, 10 2017. Citado 11 vezes nas páginas 16, 18, 19, 29, 44, 45, 47, 48, 49, 50 e 51.
- WEI, L.; LIN, Y.; WANG, J.; MA, Y. Time-frequency convolutional neural network for automatic sleep stage classification based on single-channel eeg. In: IEEE. *Tools with Artificial Intelligence (ICTAI), 2017 IEEE 29th International Conference on*. Boston, USA, 2017. p. 88–95. Citado 5 vezes nas páginas 18, 19, 44, 50 e 51.

WIECZOREK, M. A.; SIMONS, F. J. Minimum-variance multitaper spectral estimation on the sphere. *Journal of Fourier Analysis and Applications*, Springer, v. 13, n. 6, p. 665–692, 2007. Citado na página 30.

ZANUTO, E. A. C.; LIMA, M. C. S. d.; ARAÚJO, R. G. d.; SILVA, E. P. d.; ANZOLIN, C. C.; ARAUJO, M. Y. C.; CODOGNO, J. S.; CHRISTOFARO, D. G. D.; FERNANDES, R. A. Distúrbios do sono em adultos de uma cidade do estado de são paulo. *Revista Brasileira de Epidemiologia*, SciELO Public Health, v. 18, p. 42–53, 2015. Citado na página 13.

ZOUBEK, L.; CHARBONNIER, S.; LESECQ, S.; BUGUET, A.; CHAPOTOT, F. Feature selection for sleep/wake stages classification using data driven methods. *Biomedical Signal Processing and Control*, Elsevier, v. 2, n. 3, p. 171–179, 2007. Citado na página 17.