

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ESTRUTURA COMPETITIVA DE REDES NEURAIIS
AUTOASSOCIATIVAS PARA CLASSIFICAÇÃO DE FADIGA
MENTAL ATRAVÉS DE SINAIS DE ELETROENCEFALOGRAFIA**

MYLENA NAZARÉ MEDEIROS DOS REIS FERREIRA

DM 43 /2018

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MYLENA NAZARÉ MEDEIROS DOS REIS FERREIRA

**ESTRUTURA COMPETITIVA DE REDES NEURAIS
AUTOASSOCIATIVAS PARA CLASSIFICAÇÃO DE FADIGA
MENTAL ATRAVÉS DE SINAIS DE ELETROENCEFALOGRAFIA**

DM 43 /2018

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MYLENA NAZARÉ MEDEIROS DOS REIS FERREIRA

**ESTRUTURA COMPETITIVA DE REDES NEURAIIS
AUTOASSOCIATIVAS PARA CLASSIFICAÇÃO DE FADIGA
MENTAL ATRAVÉS DE SINAIS DE ELETROENCEFALOGRAFIA**

Dissertação submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Pará para obtenção do Grau de Mestre em Engenharia Elétrica na área de Computação Aplicada, elaborada sob a orientação da Profa. Dra. Adriana Rosa Garcez Castro.

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

Dados Internacionais de Catalogação - na – Publicação (CIP) Sistema de Bibliotecas da UFPA

F383e Ferreira, Mylena Nazaré Medeiros dos Reis, 1991-

Estrutura competitiva de redes neurais autoassociativas para classificação de fadiga mental através de sinais de eletroencefalografia / Mylena Nazaré Medeiros dos Reis Ferreira.-2018.

Orientadora: Adriana Rosa Garcez Castro.

Dissertação (Mestrado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2018.

1 Redes neurais (Computação). 2. Fadiga mental – Classificação. 3. Eletroencefalografia – Testes. I. Título.

CDD 23. ed. 006.32

Elaborada por Lucicléa S. de Oliveira – CRB -2/648

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

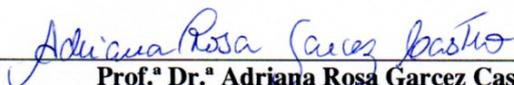
"ESTRUTURA COMPETITIVA DE REDES NEURAIS AUTO-ASSOCIATIVAS PARA CLASSIFICAÇÃO DE FADIGA MENTAL ATRAVÉS DE SINAIS DE ELETROENCEFALOGRAFIA"

AUTORA: MYLENA NAZARÉ MEDEIROS DOS REIS FERREIRA

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRA EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

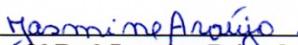
APROVADA EM: 21/12/2018

BANCA EXAMINADORA:



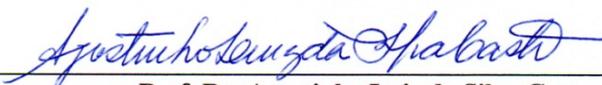
Prof.ª Dr.ª Adriana Rosa Garcez Castro

(Orientador – PPGEE/UFPA)



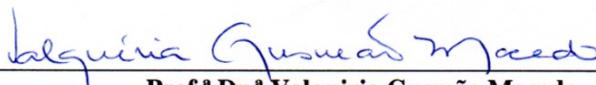
Prof.ª Dr.ª Jasmine Priscyla Leite de Araújo

(Avaliadora Interna – PPGEE/UFPA)



Prof. Dr. Agostinho Luiz da Silva Castro

(Avaliador Externo ao Programa – FCT/UFPA)



Prof.ª Dr.ª Valquiria Gusmão Macedo

(Avaliadora Externa ao Programa – FEEB/UFPA)

VISTO:



Prof.ª Dr.ª Maria Emília de Lima Tostes

(Coordenadora do PPGEE/ITEC/UFPA)

“À minha família, sempre”.

AGRADECIMENTOS

Esta dissertação de mestrado foi fruto de várias mãos segurando a minha. Agradeço a todos que me ajudaram a escrever, pensar, publicar, defender, resolver problemas e conseguir produzir um trabalho acadêmico que até então achava inimaginável.

Agradeço a Deus pela oportunidade de me formar no mestrado, ao Imaculado Coração de Maria, a quem sou devota, Nossa Senhora de Nazaré e todas devoções as quais não vivo sem, e devo dar graças por tudo o que aconteceu e acontecerá na minha vida.

Agradeço ao meu pai Claudio Dos Reis Ferreira, por sempre estar ao meu lado, dando apoio, carinho e amor, ele é uma pessoa incansável, a quem sempre vou ter admiração. Agradeço também meus tios José Martins de Araújo, Maria de Nazaré Ferreira de Araújo, e primos Karina de Nazaré Ferreira de Araújo e Luis Cláudio Ferreira de Araújo, que me fizeram descobrir o significado da família na minha vida.

Agradeço também à minha orientadora Adriana Castro, pela atenção, tempo e disponibilidade em me ajudar neste trabalho.

Toda a equipe de trabalho do Instituto Tecnológico Vale (ITV) e Instituto Senai de Inovação (ISI), em especial Ana Carolina Quintão, Iraquitan Filho, Eduardo Carvalho, Bruno Ferreira, Guilherme Cruz, Bruno Gomes e Schubert Carvalho que me apoiaram e deram sugestões no trabalho e apoio em geral, têm meus agradecimentos.

SUMÁRIO

LISTA DE ILUSTRAÇÕES.....	IX
LISTA DE TABELAS	XI
RESUMO	XII
ABSTRACT	XIII
1 INTRODUÇÃO.....	1
1.1 OBJETIVOS GERAL E ESPECÍFICO	3
1.2 ESTRUTURA DO TRABALHO	4
2 FUNDAMENTOS SOBRE COGNIÇÃO E FADIGA.....	6
2.1 COGNIÇÃO.....	6
2.1.1 ÁREAS CORTICAIS.....	6
2.2 ELETROENCEFALOGRAFIA (EEG).....	8
2.2.1 CARACTERÍSTICAS DO SINAL EEG.....	9
2.3 RITMOS CEREBRAIS.....	11
2.4 PRÉ-PROCESSAMENTO DOS SINAIS EEG	12
2.4.1 FILTRAGEM.....	13
2.4.2 SEGMENTAÇÃO DO SINAL.....	14
2.4.3 ANÁLISE DE COMPONENTES INDEPENDENTES.....	16
2.5 FADIGA MENTAL	17
2.5.1 RITMOS E MÉTRICAS DE FADIGA.....	18
2.5.2 ANÁLISE ESPECTRAL.....	20
3 REDES NEURAS AUTOASSOCIATIVAS.....	23
3.1 O PERCEPTRON.....	23
3.2 REDES MULTILAYER PERCEPTRON	25

3.3	IMPLEMENTAÇÃO E APRENDIZAGEM DAS REDES NEURAIAS	26
3.4	REDES NEURAIAS AUTOASSOCIATIVAS.....	27
4	REDES NEURAIAS AUTOASSOCIATIVAS APLICADAS À CLASSIFICAÇÃO DE FADIGA MENTAL.....	30
4.1	INTRODUÇÃO	30
4.2	BASE DE DADOS.....	32
4.3	PRÉ-PROCESSAMENTO.....	33
4.4	DENSIDADE ESPECTRAL DE POTÊNCIA	35
4.5	VETOR DE CARACTERÍSTICAS	36
4.6	NORMALIZAÇÃO DO SINAL	38
4.7	MODELO DE CLASSIFICAÇÃO.....	38
4.7.1	TREINAMENTO E VALIDAÇÃO DAS RNAAS	39
4.7.2	ESTRUTURA COMPETITIVA DE RNAAS PARA CLASSIFICAÇÃO DE FADIGA MENTAL	43
5	CONCLUSÃO.....	47
6	REFERÊNCIAS BIBLIOGRÁFICAS	49

LISTA DE ILUSTRAÇÕES

- Figura 1** Versão simplificada do mapa de Brodmann, evidenciando a organização das quatro principais regiões cerebrais do córtex, nas perspectivas lateral e superior em a) e b) respectivamente. Tomadas de decisão envolvem predominantemente as regiões anteriores (próximas à face) como as regiões frontais, parte inicial do temporal e parietal. Diferentes hemisférios podem determinar diferenças no comportamento de mesmas regiões e podem definir padrões de comportamento. Fonte: Adaptado de Bradbury (1998) 7
- Figura 2** Configuração de uma coleta de sinais cerebrais não invasiva. A dispersão dos eletrodos ao longo do escalpo define a resolução espacial da detecção de atividades elétricas significativas em determinadas regiões cerebrais. Fonte: Adaptada de <http://www.olavkrigolson.com/> 9
- Figura 3** Sensores utilizados na coleta de sinal EEG. a) Detalhe de eletrodo de cúpula de ouro normalmente aplicado em um no couro cabeludo e face do paciente. b) Touca elástica NeXus EEG Cap com 21 eletrodos embutidos. 10
- Figura 4** Visão lateral e superior da configuração da distribuição dos eletrodos no escalpo de um indivíduo, segundo o sistema EEG 10-20. As etiquetas dos eletrodos no esquemático à direita são definidas de acordo com a região cortical na qual o sensor está posicionado. Fonte: Adaptada de <http://www.olavkrigolson.com/> 11
- Figura 5** Representação dos diferentes padrões de sinal em várias faixas de frequência ao longo do tempo. Fonte: Retirado de <https://www.medicine.mcgill.ca> 12
- Figura 6** Esquemático do pré-processamento do dado, desde o estado bruto, filtrado, segmentado e finalmente livre de artefatos. A segmentação com a retirada de *trials* ocasiona perda de dados, como pode-se perceber na última ilustração à direita. Por escolha do especialista, a remoção de artefatos pode ocorrer com ou sem retirada de *trials*. Fonte: Adaptado de KIM, 2013. 14
- Figura 7** Representação da dispersão dos valores de z . Em a) gráfico de dispersão com destaque para *trials* sujeitas a deleção. Em b) detalhe da *trial* circulada em a). Artefatos de piscada destacadas em verde, e ruídos do *drifting* no eletrodo Fp1, em amarelo. 15
- Figura 8** Principais mapas topográficos relacionados com seus respectivos artefatos. Em a) é possível observar que para cada artefato, um padrão particular é obtido, contudo ressalta-se a individualidade de cada sinal EEG, que varia de pessoa para pessoa, portanto estes padrões são aproximados. Em b) o processo de remoção de artefatos é ilustrado. O máximo número de componentes que podem ser obtidos de um sinal é o mesmo número de eletrodos disponíveis. Fonte: Adaptado de Radüntz 2015. 17
- Figura 9** Gráfico de PSD de 45 minutos de dados divididos de 15 em 15 minutos. Observa-se que, para o sujeito em questão, o PSD apresentou comportamento crescente com o aumento da fadiga mental. 22

- Figura 10** Semelhanças entre a estrutura de um neurônio humano à esquerda, e o esquemático da modelagem matemática de um *Perceptron* à direita. Em a) a estrutura fisiológica do neurônio (Dendritos, Soma e Axônio) são semelhantes as variáveis matemáticas (x , somatório e u). Fonte: Retirado de Sánchez, 2011.24
- Figura 11** Principais Funções de Transferência. Fonte: Retirado de Mazi, 2008).....25
- Figura 12** Esquemático de uma rede Perceptrons de múltiplas camadas. Observa-se que apesar das camadas de entrada e saída serem monocamadas, a camada escondida pode ter várias camadas, e com diferente função de ativação da camada de saída. Fonte: Adaptado de Bouzgou, 2012.26
- Figura 13** Esquemático de uma Rede Neural Autoassociativa com o número de neurônios intermediários. Fonte: Adaptado de Reyes, 2012.28
- Figura 14** Esquemático da estrutura competitiva. As duas RNAs de cada classe reconstroem o mesmo dado de entrada, no qual é calculado o erro MSE, que determinará, para o caso de ser o menor, a classe do dado de entrada.30
- Figura 15** Esquemático da implementação da proposta deste trabalho. No pré-processamento remove artefatos e ruídos. Em seguida o PSD é calculado para a criação do vetor de características, que será a entrada para o modelo de classificação proposto neste trabalho....32
- Figura 16** Segmentos do sinal EEG para ambos os estados mentais. Em a) e b), são mostrados os sinais do estado normal para os eletrodos Fp1 e Fp2 respectivamente. Em c) e d), o estado fadigado é exibido para estes mesmos eletrodos respectivos. Fonte: Retirado de Min, 2017.....33
- Figura 17** Concatenação das matrizes de PSD para criação do vetor de características. Em a), a representação do vetor de características para um indivíduo, em b), há a concatenação vertical de todas as 280 trials dos 12 sujeitos. A concatenação horizontal une, linha a linha, os valores das 4 razões, e dos 3 índices para cada um dos 30 canais.37
- Figura 18** Valores da pesquisa em malha com os erros médios quadráticos para cada classe. Em destaque as redes com menor erro para classe 1 e 2 em verde.....40

LISTA DE TABELAS

Tabela 1 Intervalos de frequência dos ritmos cerebrais considerados neste trabalho. Fonte: BANICH, 2018	12
Tabela 2 Organização das matrizes, para cada indivíduo, dos dados filtrados e as do PSD juntamente com suas respectivas nomenclaturas empregadas para a criação do vetor de características.....	35
Tabela 3 Quantidade de padrões para o treinamento, validação e teste.....	39
Tabela 4 Resultados do teste estatístico de Wilcoxon.	42
Tabela 5 Matriz de confusão dos dados de teste	44
Tabela 6 Comparativo de acurácias de classificação de fadiga mental em vários trabalhos..	45
Tabela 7 Matriz de Confusão do treinamento de uma única rede MLP com 100 neurônios..	46

RESUMO

A complexidade da análise da fadiga mental em pessoas saudáveis é evidenciada pela ausência de perturbações específicas no sinal eletroencefalográfico e pela singularidade e variabilidade do perfil cognitivo de cada indivíduo. Identificar esse tipo de estado mental requer a análise de diversos fatores que envolvem o comportamento das regiões cerebrais em diversas faixas de frequência. No contexto da indústria, a fadiga mental compromete a eficiência da cadeia produtiva ao afetar a percepção (concentração e atenção) dos indivíduos, o que aumenta o risco de acidentes e os custos de produção. Desta forma, o monitoramento da condição cognitiva faz-se necessário para a manutenção do desempenho produtivo e cognitivo do indivíduo avaliado.

Dentro deste contexto, este trabalho propõe um sistema para classificação da fadiga mental baseado em uma estrutura competitiva de Redes Neurais Autoassociativas e em sinais obtidos através de um eletroencefalógrafo. O vetor de características usado como entrada para o sistema é composto pelas informações normalizadas de três faixas de frequências (teta, beta e alfa) e quatro métricas que, de acordo com a literatura, diferenciam estados mentais a partir dos dados eletroencefalográficos, em termos de densidade de energia espectral. Os resultados obtidos mostram a eficiência do sistema proposto e a aplicabilidade das redes neurais autoassociativas para problemas de classificação de padrões.

PALAVRAS-CHAVES: Redes Neurais Autoassociativas, Classificação de fadiga mental, Sinais EEG, Pré-processamento de Sinal, Estruturas Competitivas.

ABSTRACT

The complexity of mental fatigue signals in healthy people is due to the absence of specific perturbations in the electroencephalographic activity, and by the singularity and variability of the cognitive profile of each individual. Identifying this mental state requires the analysis of several factors that involve the brain behavior in its regions in various frequency bands. In concern to the industry, mental fatigue compromises the efficiency of the production chain by affecting the perception (concentration and attention) of people, which increases the risk of accidents and production costs. Thus, monitoring the cognitive condition is necessary for the maintenance of the productive and cognitive performance of the evaluated subject.

This work proposes the classification of fatigue using a competitive structure of Associative Neural Networks. This type of neural network allows to find the association between the input data and the reconstructed data from a compact architecture, being indicated for real-time applications. The characteristics vector used for classification is composed of the normalized information of three frequency bands (theta, beta and alpha) and four metrics that, according to the literature, differentiate mental states from electroencephalographic data in terms of Power Spectral Density. The results show the capacity and usability of autoassociative neural networks in patterns classification.

KEYWORDS: Associative Neural Network, Classification of mental fatigue, Cognitive performance

1 INTRODUÇÃO

Tarefas repetitivas e/ou prolongadas requerem um esforço mental contínuo e constante. Após determinado tempo, este esforço conduz ao estado de fadiga mental, caracterizado pelo declínio da atenção, concentração e engajamento cognitivo, principais fatores responsáveis por acidentes de trânsito (ZHAO et al, 2017) e no trabalho (DIMITRAKOPOULOS et al, 2018).

A fadiga mental reflete perturbações nas ondas cerebrais ao longo das bandas de frequência e nas regiões do cérebro e, portanto, influencia efetivamente o comportamento cognitivo de um indivíduo. Entende-se por cognição o conjunto de habilidades ou processos mentais que fornecem meios a uma pessoa, para entender o mundo ao seu redor, e tomar decisões em relação a ele (BENICH, 2018). Deste modo, analisar a cognição de um indivíduo permite que seus perfis emocional, mental e até mesmo fisiológico possam ser estudados de forma que padrões de comportamento, e também de encefalopatias, sejam identificados.

Das várias formas de mensurar as informações cognitivas, as mais usuais são a eletroencefalografia (EEG), a magnetoencefalografia (MEG) e a ressonância magnética (fMRI). Cada uma possui características específicas quanto aos procedimentos de coleta de sinal, resolução no espaço e tempo, e enfoque, como por exemplo, campos elétricos no caso do EEG (BERGER,1929), campos magnéticos para MEG (COHEN, 1972), e fluxo sanguíneo para fMRI (SHERRINGTON,1915).

No contexto da estimação da fadiga mental, dados do tipo EEG são largamente estudados com e sem interação com outras fontes eletrofisiológicas como o eletrocardiograma, eletro-oculograma e a condução cutânea (KATHNER et al., 2014; MATTHEWS; HANCOCK; DESMOND, 2012; HOLM et al., 2009). A abordagem mais difundida envolve a avaliação dos sinais EEG a partir da análise de densidade espectral de energia (*Power Spectral Density*, PSD), que fornece informações relacionadas ao comportamento da energia de um sinal, ou de uma série temporal através das frequências.

Esta abordagem é interessante, visto que os ritmos cerebrais, delimitados pelas bandas de frequência podem ser estudados isoladamente ou conjuntamente, explicitando suas similaridades e dissimilaridades para a análise de um estado mental, emocional ou fisiológico. Por exemplo, em (JOHNSON et al., 2011) a análise a partir do PSD foi empregada para detectar níveis de alerta e sonolência de indivíduos em privação de sono ao longo de várias frequências; já em (HOLM et al., 2009) os valores de PSD foram relacionados em razões entre bandas de frequência para detectar níveis de esforço mental, que em outras palavras seria a capacidade mental para realizar tarefas.

Os esforços para detectar os padrões neurais que caracterizam a fadiga mental a partir de sinais de EEG, em geral, são tomados em experimentos controlados, estabelecendo paradigmas para indução de fadiga em tarefas que requerem o estado de vigília, com atenção sustentada (DIMITRAKOPOULOS et al, 2018), no domínio da atenção visual (LI, 2016) e uso intenso da memória de trabalho (HELTON, 2011).

Atualmente diversos trabalhos vêm sendo apresentados na literatura usando metodologias de Inteligência Computacional aplicadas ao problema de classificação de fadiga mental. Em relação à Redes Neurais Artificiais, as Redes Perceptron de Múltiplas Camadas (MLP), por serem consideradas aproximadoras universais, são fortes candidatas para o problema. Estas redes podem realizar qualquer tipo de mapeamento linear ou não-linear entre as entradas e saídas de um determinado sistema sendo adequadas para problemas de classificação de padrões, que é o caso do problema de detecção de fadiga mental.

Em (MIN et al., 2017), dados de 12 pessoas foram coletados em ambiente de simulação de direção durante períodos entre 1 e 2 horas contínuas, sendo apresentado resultados sobre as regiões cerebrais diretamente ativas durante a ocorrência da fadiga, através de um estudo comparativo entre redes neurais MLP e outros 3 modelos de classificação. Os autores atingiram uma acurácia máxima de 98,3% de acerto de classificação, quando empregado o *Cross-validation* para a classificação de múltiplas entropias. No trabalho de (King, Nguyen, & Lal, 2006), a percepção de fadiga mental entre 20 motoristas profissionais e 35 motoristas casuais é constatada no domínio do tempo, com análise de dados EEG nas bandas de

frequência alfa, beta, delta e teta, sendo utilizada uma rede neural artificial e uma técnica de otimização chamada Função de Gradiente Ampliada (*Magnified Gradient Function*, MGF), uma versão modificada do algoritmo de *Backpropagation*, com a diferença de otimizar a convergência dos dados ao amplificar o gradiente da função de ativação. O trabalho teve acurácia de 81.49% (80.53% sensibilidade, 82.44% especificidade) para classificar motoristas profissionais e 83.06% (84.04% sensibilidade, 82.08% especificidade) para motoristas casuais.

Outros trabalhos utilizam abordagens que implementam vários modelos classificadores (Chai, et al., 2017), e até outros tipos de bases de dados para detectar fadiga mental que não com o uso de sinais EEG (Pimenta, Carneiro, Neves, & Novais, 2016). Em (Chai, et al., 2017) foi realizado um estudo comparativo entre redes neurais artificiais, redes neurais bayesianas, redes de crenças profundas (*Deep Belief Network*), e redes de crenças profundas esparsas (*Sparse Deep Belief Network*). O melhor resultado de classificação, alcançado foi de 93.9% de sensibilidade, 92.3% de especificidade e acurácia de 93.1%. Em (Pimenta, Carneiro, Neves, & Novais, 2016), parâmetros motores de interação de 43 indivíduos com computador foram considerados para análise da fadiga mental, tais como velocidade do cursor do mouse, duração de clicks, distância entre dois clicks e mais 15 outros atributos baseados na utilização do mouse. O estudo de uma rede MLP com 10 neurônios conseguiu uma acurácia de classificação de fadiga mental de 81%.

1.1 OBJETIVOS GERAL E ESPECÍFICO

Considerando a importância do problema de detecção de fadiga mental e as vantagens oferecidas pelas Rede Neurais Artificiais para o problema de classificação, este trabalho tem como objetivo apresentar uma nova metodologia baseada em uma estrutura competitiva de redes neurais Perceptron (MLP) Autoassociativas.

Uma rede Perceptron autoassociativa é um caso especial da rede Perceptron de múltiplas camadas onde o número de entradas da rede é igual ao número de saídas, sendo a rede treinada para realizar um mapeamento do vetor de entrada no vetor de saída, ou seja, a rede é treinada para reproduzir em sua saída os dados apresentados

em sua entrada sendo que a camada intermediária armazena o conhecimento relacionado às principais características do conjunto de dados de entrada.

Para desenvolvimento do sistema de classificação de fadiga mental foram utilizados os dados públicos utilizados no trabalho apresentado em (MIN et al., 2017), sendo criado um vetor de características (entrada do sistema de classificação) composto pelas informações em três faixas de frequências (teta, beta e alfa) e quatro métricas que, de acordo com a literatura, diferenciam estados mentais a partir dos dados eletroencefalográficos, em termos de densidade de energia espectral.

Como objetivos específicos têm-se:

1. Implementar a estrutura competitiva para classificação de dois estados mentais: normal e com fadiga mental
2. Avaliação de diversas topologias de redes autoassociativas para obter a que melhor se adeque à proposta.
3. Utilizar a média do erro quadrático e o teste estatístico de Wilcoxon para avaliar a qualidade de reconstrução das redes autoassociativas.
4. Avaliar a aplicabilidade das redes neurais MLP autoassociativas para o problema de classificação de fadiga mental.

1.2 ESTRUTURA DO TRABALHO

Além deste capítulo introdutório, 4 capítulos estruturam este trabalho. No Capítulo 2 são apresentados os fundamentos sobre cognição e fadiga mental, sendo apresentada definições referentes a regiões corticais, o sinal de eletroencefalografia, ritmos cerebrais e a própria definição de fadiga mental, e como ela se traduz em termos de sinais neurais.

No Capítulo 3, o enfoque da dissertação volta-se à Inteligência Computacional, com o capítulo dedicado às Redes Neurais Autoassociativas, que é o tipo de rede utilizada para desenvolvimento do sistema classificador proposto. No Capítulo 4, a metodologia do trabalho é apresentada, desde a descrição da base de dados, seu pré-processamento, o cálculo da densidade espectral de potência, o modelo de

classificação e os resultados obtidos da estrutura proposta em cima da base de testes. Por fim, no Capítulo 5, a conclusão do trabalho evidencia os avanços na análise dos sinais neurais com base no modelo proposto.

2 FUNDAMENTOS SOBRE COGNIÇÃO E FADIGA

A percepção e assimilação de emoções, sensações e comportamentos pelo cérebro, referem-se principalmente às especificidades funcionais do mesmo na geração, transmissão e inibição de pulsos neurais ao longo de toda sua extensão (COHEN, 2014). Portanto, decifrar mecanismos emocionais, mentais e até mesmo fisiológicos, requer um estudo que abrange conceitos que dizem respeito à neurociência e cognição, leia-se áreas corticais, sinais de atividades neurais, ritmos cerebrais, topologias de aquisição de sinal neuronal e outros conceitos abordados nas sessões seguintes. Estas definições colaboram para um melhor entendimento da análise e estudo da fadiga mental na perspectiva cerebral, assim como dos resultados obtidos neste trabalho.

2.1 COGNIÇÃO

Um dos principais questionamentos da neurociência refere-se ao modo em que as áreas do cérebro medeiam diferentes funções cerebrais e comportamentos. Uma vertente de estudiosos acredita que funções específicas do cérebro são geradas em regiões especializadas do córtex – localizacionista -, outros, que cada região cerebral contribui de certa forma para que, determinada função, emoção ou comportamento seja, implementado ou expressado – distribucionista - (LEBEDEV, 2006). Assim, o conceito de regiões, áreas ou lóbulos é introduzido de forma a viabilizar o entendimento dos sinais neurais obtidos de porções do cérebro, e como isto influencia na análise da fadiga mental.

2.1.1 ÁREAS CORTICAIS

Originalmente determinadas por semelhanças anatômicas, as regiões cerebrais foram organizadas segundo o mapa de Brodmann, que divide o córtex, em regiões distintas com similaridades na estrutura e natureza celular, sem qualquer relação com a função destas mesmas células (BRODMANN, 1909). Apesar da correlação entre

estrutura e anatomia variar de acordo com a região, esse mapa é largamente utilizado pela literatura quando se quer referir a uma porção específica do cérebro e a funcionalidades a ela atribuída (BANICH, 2018). A Figura 1 ilustra o mapa de Brodmann no qual é possível observar as delimitações das quatro principais regiões cerebrais: frontal, parietal, temporal e occipital. O mapa reforça a importância do emprego de um protocolo de coleta de sinais, pois o posicionamento incorreto dos eletrodos pode levar a resultados equivocados.

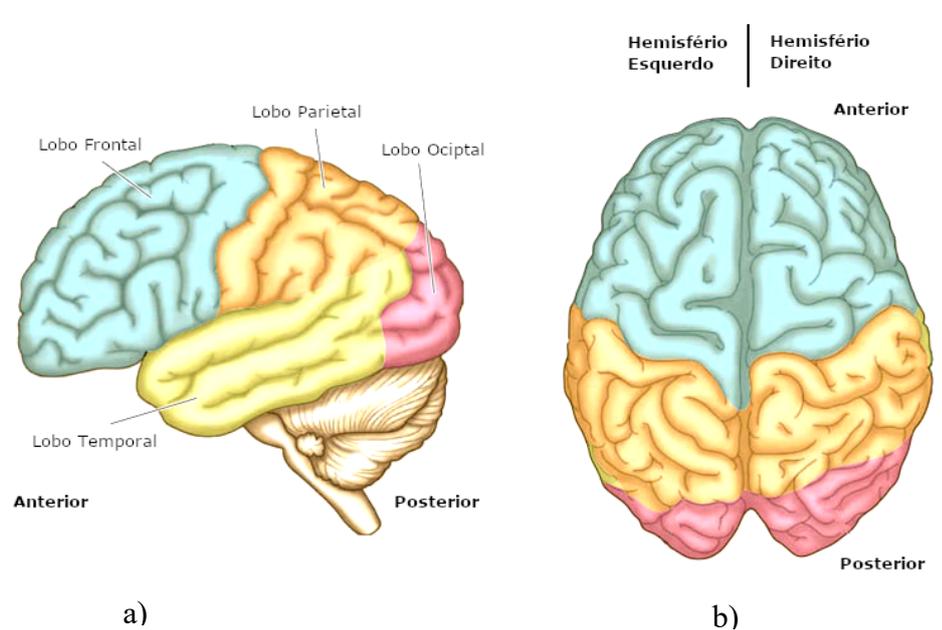


Figura 1 Versão simplificada do mapa de Brodmann, evidenciando a organização das quatro principais regiões cerebrais do córtex, nas perspectivas lateral e superior em a) e b) respectivamente. Tomadas de decisão envolvem predominantemente as regiões anteriores (próximas à face) como as regiões frontais, parte inicial do temporal e parietal. Diferentes hemisférios podem determinar diferenças no comportamento de mesmas regiões e podem definir padrões de comportamento. Fonte: Adaptado de Bradbury (1998)

Além de critério para aquisição de sinal cerebral, o mapa de Brodmann também é utilizado para diagnosticar possíveis consequências de lesões sofridas pelo cérebro, seja por doenças, seja por acidentes. A região frontal se destacada como sensível na elaboração da coordenação motora e refinamento de movimentos. Na região temporal, por sua vez, predomina o processamento auditivo e memória; o olfato e

tato são atribuídos como funcionalidade da região parietal, e finalmente a visão se destaca na região occipital (PARADISO, 2007).

Denominadas também como lobos, a resposta destas regiões diante de diferentes situações emocionais, motoras ou fisiológicas é interpretada como indicador do comportamento da atividade cerebral e, portanto, são cruciais para a análise dos efeitos da fadiga mental em relação aos padrões cerebrais.

2.2 ELETROENCEFALOGRAFIA (EEG)

Um dos primeiros experimentos envolvendo registros neurais foi liderado pelo neurologista e psiquiatra alemão Hans Berger, no início do século XX. Na ocasião, foi desenvolvido o que seria denominado posteriormente de eletroencefalografia (EEG), que mensura a atividade elétrica do cérebro pela diferença de voltagem elétrica em microvolts (mV), entre duas posições no couro cabeludo, denominado cientificamente de escalpo. Portanto, define-se EEG como um método de obtenção de sinais elétricos gerados pela atividade cerebral, dependente do número de posições, ou sítios cerebrais estudados, ao longo dos lobos corticais, durante um determinado intervalo de tempo (TATUM, 2014).

Há duas maneiras de coleta dos sinais neurais, podendo ser extracranianas (não invasivas), quando eletrodos são posicionados na superfície do couro cabeludo, ou intracranianas (invasivas), em que os sinais cerebrais são registrados diretamente da superfície do cérebro, no parênquima cerebral (BANICH, 2018). A Figura 2 ilustra o método de coleta EEG não invasivo, nela percebe-se a touca de eletrodos posicionadas na superfície da cabeça de um indivíduo, e os sinais correspondentes à cada eletrodo sendo exibidos em um monitor. Ressalta-se a importância da posição dos eletrodos em relação aos lobos corticais para análise do comportamento dos sinais em relação a cada função atribuídas às regiões cerebrais.

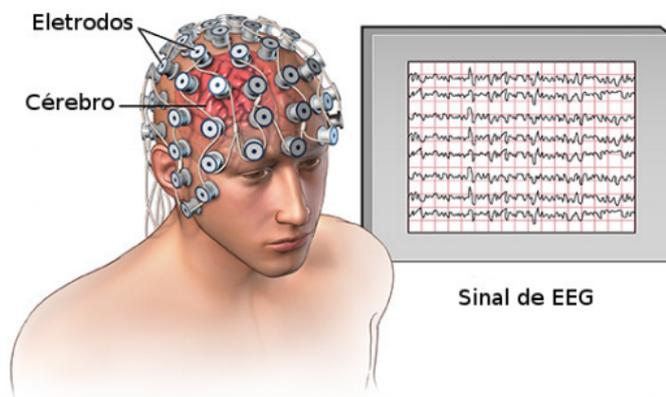


Figura 2 Configuração de uma coleta de sinais cerebrais não invasiva. A dispersão dos eletrodos ao longo do escalpo define a resolução espacial da detecção de atividades elétricas significativas em determinadas regiões cerebrais. Fonte: Adaptada de <http://www.olavkrigolson.com/>

O banco de dados público utilizado neste trabalho foi obtido através de um procedimento de coleta não invasiva e, portanto, detalhes deste tipo de coleta serão abordados em seguida.

2.2.1 CARACTERÍSTICAS DO SINAL EEG

Biopotenciais humanos possuem características peculiares. No caso dos sinais EEG, os tipos de sensores utilizados, seus respectivos posicionamentos, e a natureza dos ruídos provenientes do ambiente e do próprio corpo do indivíduo são fatores que influenciam diretamente na qualidade da análise do sinal.

Os sensores não invasivos usuais utilizados para a captação do sinal EEG, são chamados eletrodos de disco, que podem ser de cúpula ou retos, compostos de prata Ag/AgCl ou ouro, e colados à pele com pastas condutoras, no intuito de atenuar ruídos e promover uma captação estável do sinal. A Figura 3 ilustra estes tipos de eletrodos, em a) os detalhes do eletrodo de cúpula de ouro são exibidos, e em b), os eletrodos de disco estão agrupados em uma touca elástica.



Figura 3 Sensores utilizados na coleta de sinal EEG. a) Detalhe de eletrodo de cúpula de ouro normalmente aplicado um a um no couro cabeludo e face do paciente. b) Touca elástica NeXus EEG Cap com 21 eletrodos embutidos.

Além da especificação dos tipos de sensores, a coleta não invasiva dos sinais EEG segue um protocolo de normatização de posicionamento dos eletrodos, também chamado de sistema, que varia de acordo com o número de sensores adotados, e se baseia na relação entre a posição do eletrodo e a área cortical em que o mesmo está posicionado (MARCUSE, 2015).

O sistema internacional EEG 10-20 empregado neste trabalho foi elaborado pelo Guia da Sociedade Americana de Eletroencefalografia para Nomenclatura e padronização do posicionamento de eletrodos (NOMENCLATURE, Standard Electrode Position, 1991), e é formado por 21 eletrodos (também chamados de canais), com espaçamento entre sensores adjacentes de 10% e 20% da distância total entre a região anterior e posterior do escalpo, e a distância à direita e esquerda dos hemisférios respectivamente (ODOM, 2009). Na Figura 4, as duas ilustrações à esquerda expõem o arranjo de eletrodos segundo o percentual de distância, e o esquemático topográfico à direita, ilustra este mesmo posicionamento enfatizando os eletrodos nomeados segundo a região cortical em que estão alinhados. Por exemplo, eletrodos cujo rótulo inicia-se com ‘F’ estão localizados na região frontal, o mesmo se aplica para todas as outras regiões e eletrodos.

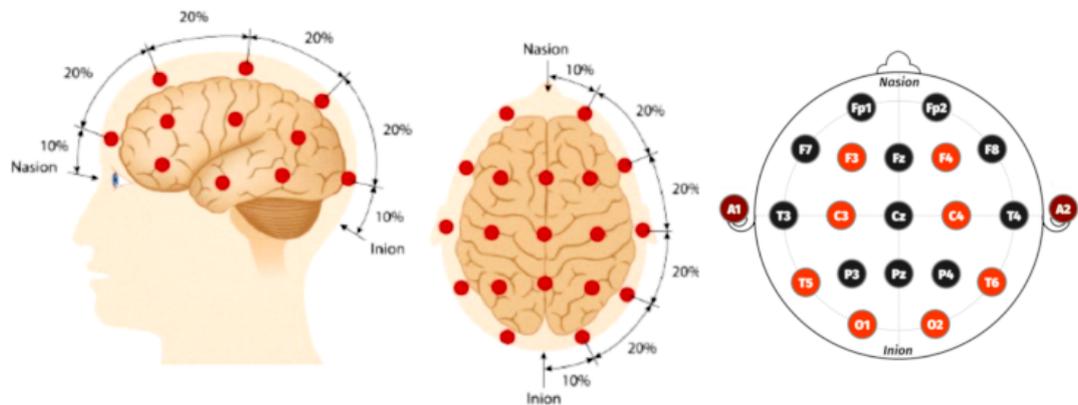


Figura 4 Visão lateral e superior da configuração da distribuição dos eletrodos no escalpo de um indivíduo, segundo o sistema EEG 10-20. As etiquetas dos eletrodos no esquemático à direita são definidas de acordo com a região cortical na qual o sensor está posicionado. Fonte: Adaptada de <http://www.olavkrigolson.com/>

2.3 RITMOS CEREBRAIS

O que faz o cérebro especial e fundamentalmente diferente de todos os outros tecidos vivos é sua organização de ação no tempo, isto é, a coordenação das várias populações de neurônios, que cooperam entre si para disparar um pulso neural ao longo dos lobos corticais (BUZSAKI, 2007).

Desta forma o cérebro manifesta sua habilidade em gerar e perceber informações no tempo, tanto para interpretação, quanto para a tomada de decisão. Essa percepção se baseia no sincronismo de oscilações entre, e ao longo da rede neuronal, advindas dos sulcos cerebrais, ou melhor, das fissuras percebidas na superfície do cérebro.

Oscilações, ritmos ou ciclos são sinônimos para denominar um padrão que se repete no tempo e espaço (BUZSAKI, 2007). Portanto a informação temporal de padrões neurais recorrentes estão dispostos em oscilações de várias frequências, cujos intervalos não são consensuais. Este trabalho considerou os valores exibidos na Tabela 1 para implementar a análise de fadiga mental.

Tabela 1 Intervalos de frequência dos ritmos cerebrais considerados neste trabalho. Fonte: BANICH, 2018

Banda	Faixa de Frequência (Hz)
Delta (δ)	1 - 4
Teta (θ)	4 - 8
Alfa (α)	8 - 15
Baixo Alfa (α_1)	8 - 10
Alto Alfa (α_2)	10 - 15
Beta (β)	15 - 30
Gama (γ)	30 - 100

Estes ritmos cerebrais são dispostos no tempo como senóides, e deste modo apresentam um perfil característico de cada faixa de frequência. A Figura 5 ilustra o padrão das principais bandas de frequência; cada uma delas representa um comportamento neural relacionado ao sono, estado de alerta, ansiedade e, dependendo da área cortical em que ocorre, possíveis encefalopatias.

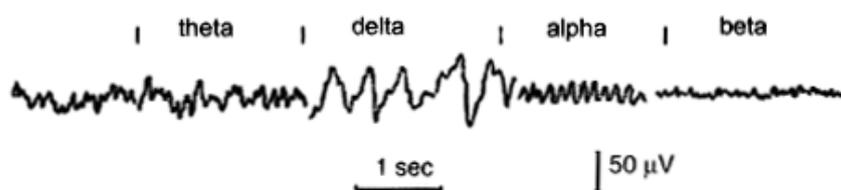


Figura 5 Representação dos diferentes padrões de sinal em várias faixas de frequência ao longo do tempo. Fonte: Retirado de <https://www.medicine.mcgill.ca>

2.4 PRÉ-PROCESSAMENTO DOS SINAIS EEG

O sinal EEG está exposto à ruídos de várias naturezas. Os do ambiente, principalmente os advindos da rede elétrica são os mais comumente reportados como

fonte de distorção externa. Além disso, ruídos originados do próprio corpo e também pelos próprios eletrodos exigem um maior cuidado na atenuação dos mesmos. Geralmente, o tratamento destas distorções é feito através da filtragem, inspeção visual e Análise de Componentes Independentes (ICA).

2.4.1 FILTRAGEM

A filtragem do sinal refere-se à implementação de dois filtros, uma passa banda (FPB) no intervalo da frequência de interesse, e um rejeita faixa (FRF) em uma frequência específica. No primeiro, o intuito é remover ruídos externos como interferências de ondas de rádio, ou até mesmo advindas do funcionamento de máquinas. Esse tipo de filtragem também tem o objetivo de remover ruídos como os provenientes do acúmulo de suor (que funciona como isolante), *drifting* entre eletrodos (alterações na magnitude do sinal produzidas por uma corrente induzida entre eletrodos), movimentação ocasional do corpo ao longo da coleta de dados (algum tique nervoso, por exemplo), e também para evitar o *aliasing* do sinal.

Ressalta-se que o *drifting* também é atenuado de acordo com a posição dos sensores EEG, a distância intereletrodo, e a quantidade de sensores utilizada (BOLFE, 2007; DORGAN,1999). Portanto apenas a filtragem não é capaz de reduzir as distorções resultantes deste ruído, o que justifica a importância da escolha de um sistema de topologia de eletrodos adequado aos dados analisados.

A filtragem com o filtro FRF é empregada principalmente para remoção de ruídos provenientes da linha elétrica, que se origina da frequência da transmissão da corrente alternada. Em aparelhos não aterrados, essa oscilação da transmissão irradia um sinal de mesma frequência (60 Hz) que deve ser rejeitado da análise de filtragem (ALCIATORE, 2007).

2.4.2 SEGMENTAÇÃO DO SINAL

Os dados brutos e os filtrados são denominados contínuos, por serem organizados em uma matriz bidimensional (tempo x eletrodos). Para facilitar a análise, o sinal filtrado é segmentado ao redor de eventos, que são perturbações associadas a um comportamento (como picos epiléticos, por exemplo) ou provenientes de um estímulo externo durante a coleta (imagens ou sons). A análise de dados de uma pessoa saudável e que não tenha recebido estímulos externos, ou seja, sem eventos, a segmentação do sinal é determinada pelo especialista, que ao final da segmentação passará a ter dados organizados em uma matriz tridimensional (tempo x eletrodos x segmentos) (COHEN, 2015).

Além de facilitar a análise do sinal, a segmentação é empregada para remoção de artefatos, que recebem esta denominação por terem origem fisiológica (E COSTA, 2005), como por exemplo, sinais cardíacos (pulso cardíaco), musculares (movimentação do maxilar e músculos da face) e oculares (piscada de olho, movimentação lateral). A

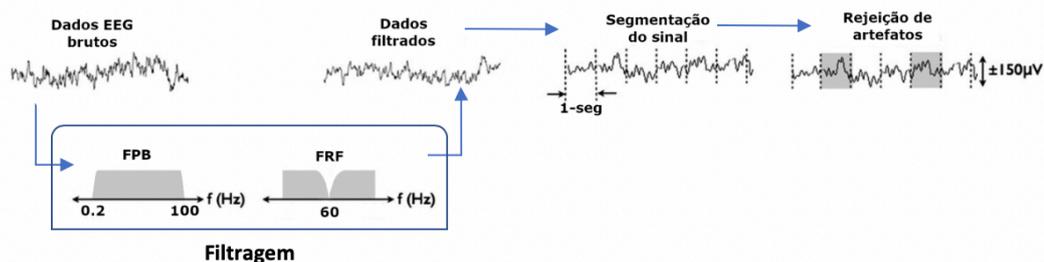


Figura 6 Esquemático do pré-processamento do dado, desde o estado bruto, filtrado, segmentado e finalmente livre de artefatos. A segmentação com a retirada de *trials* ocasiona perda de dados, como pode-se perceber na última ilustração à direita. Por escolha do especialista, a remoção de artefatos pode ocorrer com ou sem retirada de *trials*. Fonte: Adaptado de KIM, 2013.

Como há perda de dados pela deleção de *trials* com artefatos, o processo desta seleção deve seguir um parâmetro estatístico que analise a dispersão das *trials* em relação a maioria. O *z-value*, ou valor z, é o mais comumente empregado para esta

seleção, pois uma vez que é calculado segundo a média e desvio padrão de todas as *trials* em relação a uma *trial n*, os valores mais dispersos são automaticamente considerados como artefatos, e eliminados por inspeção visual. O valor z de uma *trial n* pode ser obtido através de:

$$z_n = \frac{x_n - \mu}{\sigma} \quad (1)$$

sendo z_n a razão da diferença da média de todas as amostras da *trial*, x_n a média μ de todas as *trials* e σ o desvio padrão de todas as *trials* (GOTELLI, 2008).

Os valores de z são então plotados em um gráfico de dispersão, em que suas respectivas *trials* (n), são escolhidas manualmente, sendo que quanto maior o valor de z , maior será a probabilidade deste valor ser removido. A Figura 7 ilustra um exemplo de um gráfico de dispersão de *trials* por valor de z , com uma região destacada (em azul) em que algumas *trials* serão removidas. Na figura a *trial* de número 180 é plotada em termos de canais por tempo, em que os artefatos são visivelmente percebidos.

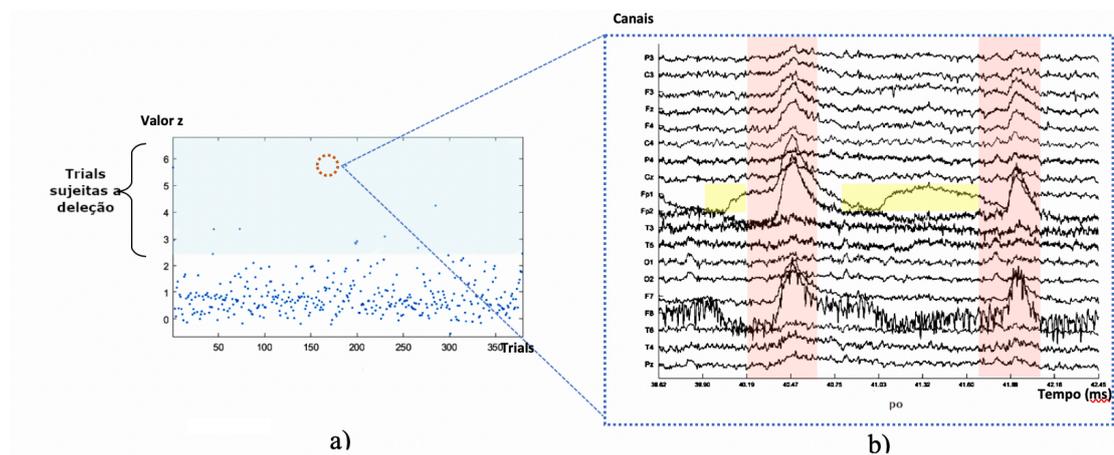


Figura 7 Representação da dispersão dos valores de z . Em a) gráfico de dispersão com destaque para *trials* sujeitas a deleção. Em b) detalhe da *trial* circulado em a). Artefatos de piscada destacadas em verde, e ruídos do *drifting* no eletrodo Fp1, em amarelo.

2.4.3 ANÁLISE DE COMPONENTES INDEPENDENTES

Existem outras fontes de ruído, como os ruídos provenientes de sinais fisiológicos que são captados conjuntamente com o EEG. Esse tipo de ocorrência pode ser tratada pela técnica de Análise de Componentes Independentes (ICA). Essa estratégia decompõe o sinal filtrado e apresenta-o em termos de componentes com o intuito de achar sinais de outras naturezas e separá-los do sinal EEG desejado (COHEN, 2015).

A análise destes componentes é feita principalmente a partir de suas topografias, que apresentam um padrão específico para cada artefato. A Figura 8 ilustra alguns dos componentes mais comuns, como o de piscada, que é um dos mais fáceis de se identificar, uma vez que há uma concentração de energia na parte anterior do córtex. A Figura 8 a) exemplifica o padrão topográfico dos principais artefatos, juntamente com o padrão de um sinal EEG, e em b) é possível observar a correspondência entre alguns mapas topográficos e o comportamento de seus respectivos componentes no sinal original.

Importante ressaltar que a decomposição dos sinais EEG em componentes baseia-se em propriedades puramente estatísticas, e, portanto, um componente pode ter tanto dados EEG como dados indesejáveis (COHEN, 2015), o que justifica que esta seleção de componentes seja manual, e baseada na análise criteriosa dos padrões topográficos de artefatos.

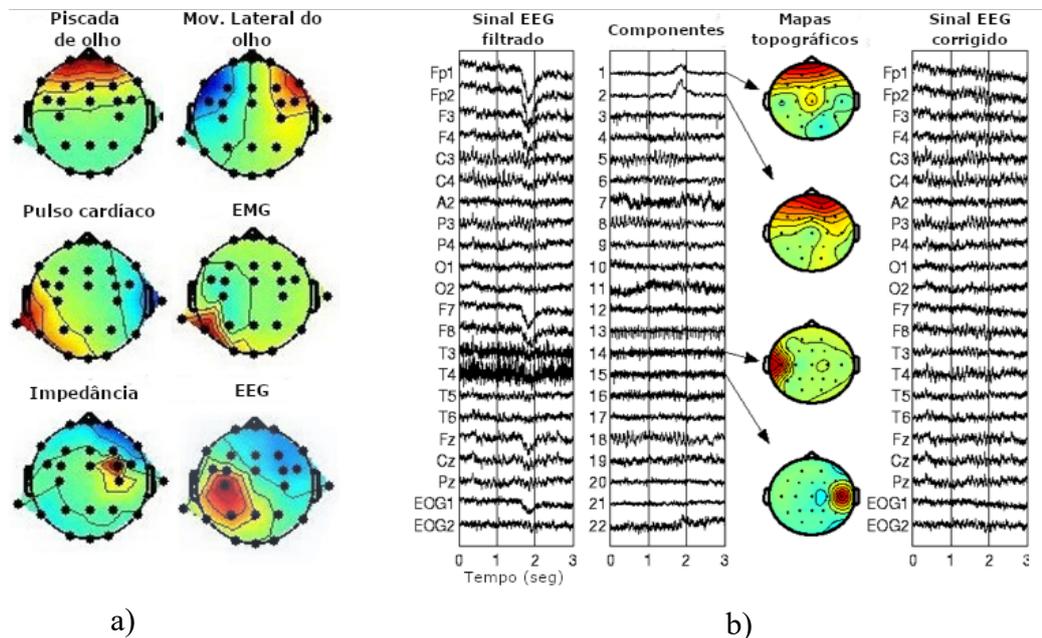


Figura 8 Principais mapas topográficos relacionados com seus respectivos artefatos. Em a) é possível observar que para cada artefato, um padrão particular é obtido, contudo ressalta-se a individualidade de cada sinal EEG, que varia de pessoa para pessoa, portanto estes padrões são aproximados. Em b) o processo de remoção de artefatos é ilustrado. O máximo número de componentes que podem ser obtidos de um sinal é o mesmo número de eletrodos disponíveis. Fonte: Adaptado de Radüntz 2015.

2.5 FADIGA MENTAL

Associada a sintomas como cansaço mental, perda de motivação, de concentração e de atenção, a fadiga mental é um sintoma comum a várias doenças de diferentes naturezas, e aparece de forma induzida, ou seja, após longos períodos de tempo na execução contínua de uma tarefa, em pessoas saudáveis (MIZUNO, 2011).

A fadiga induzida é também referenciada como fadiga aguda, que apesar de ser um sintoma natural, caso seja acumulada sem o devido descanso, pode se tornar irreversível e requer a administração de drogas psicoativas. Além disso, a degradação cognitiva resultante da fadiga mental afeta a percepção do indivíduo, sua acuidade e controle motor, acarretando riscos de acidentes, seja doméstico, no trabalho, no trânsito e entre outros.

O Instituto Brasileiro de Gestão em Prevenção de Acidentes do Trabalho (IBGPAT) divulgou que a jornada 12 por 36, isto é, doze horas de trabalho contínuo e 36 horas de descanso, comum em algumas classes profissionais como a de saúde, registra mais acidentes no trabalho e no percurso até o trabalho que qualquer outra categoria, e estão mais susceptíveis a sofrer acidentes após as doze horas de trabalho (IBGPAT, 2018). Outros trabalhos também destacam a fadiga mental como fator agravante para ocorrência de acidentes de trânsito (WASCHER et al. 2014; MIN et al. 2017; DIMITRAKOPOULOS et al. 2017).

Portanto, caso não seja monitorada e tratada, a fadiga mental pode comprometer e influenciar diretamente a saúde pessoal e profissional de um indivíduo, ocasionando consequências tanto para a saúde da sociedade, como para a indústria, que terá sua cadeia produtiva exposta à riscos de prejuízos humanos e financeiros.

2.5.1 RITMOS E MÉTRICAS DE FADIGA

Em tarefas de prolongada demanda atencional, os efeitos da fadiga mental são intensificados, e, portanto, repercutem oscilações nos ritmos cerebrais, que indicam mudanças de comportamento dos sinais EEG em determinadas bandas de frequência e regiões corticais.

Métodos tradicionais de estimativa de nível de fadiga como Chalder (Borg, 1990), Lis (Lee, 1991), Wong-Baker (Wong, 2001) e *NASA Task Load Index* (NASA-TLX) (Hart, 1986) por exemplo, são baseados em questionários preenchidos pelo próprio indivíduo, seja, por avaliação verbal ou escrita de terceiros. Estas avaliações são susceptíveis à erros, visto que o indivíduo pode ou não fornecer dados precisos sobre si, assim como ter ou não conhecimento preciso acerca de seu estado fadiga (Paris, 2001).

Por outro lado, como a fadiga mental pode ser identificada pelo comportamento espectral do sinal neural do indivíduo, padrões peculiares para cada estágio de fadiga podem ser detectados, criando perfis cognitivos para cada indivíduo ou grupo de indivíduos. Assim, a partir do sinal EEG, a fadiga mental pode ser analisada por

espectros de potência em várias bandas de frequência, destaca-se os índices α , β e θ , e as razões entre estes índices, denominadas métricas, que podem ser calculadas para determinadas regiões, ou para todos os eletrodos.

Os índices, que correspondem a parâmetros diretamente relacionados aos ritmos cerebrais, denotam característica do sinal cortical, apresentando padrões de variação específicos para bandas de frequência de análise (Cheron, 2016). Assim, a banda θ (4-8Hz) exibe sinais com comportamento relacionado à memória, controle sensorimotor e orientação, a banda β (12-30HZ) relacionado à padrões de sinais associados à atenção, acuidade visual e fadiga e a banda α (8-12 HZ) relacionada à criatividade, atenção seletiva e relaxamento. A combinação desses índices para construção de métricas possibilita determinar mensurações relacionadas à eventos singulares como a fadiga mental (Jap, 2009; Eoh, 2005).

A partir dos índices e métricas, as alterações advindas da fadiga mental podem ser percebidas, em sua maioria, nas regiões frontal e parietal, com aumento considerável de energia em teta (4-8Hz), e decréscimo em alfa (8-15Hz) e beta (15-30Hz) (SCHIER, 2000); TREJO, 2015). Este comportamento pode ser interpretado como indicador de cansaço e sonolência (BROOKHUIS & DE WAARD, 2010). Em particular, o aumento do baixo alfa (*low alpha*) (8-10Hz) está relacionado ao decréscimo dos níveis de estimulação e alerta. Nesses casos, o aumento em teta ocorre em menor grau.

No trabalho de (LIU, 2010), alterações nos índices beta e alfa são relacionadas à atenção e acesso à memória, refletindo o engajamento da parte anterior do cérebro na execução de uma atividade. O fluxo direcional no sentido parietal para frontal e o acoplamento funcional entre alfa e beta pode refletir representações cognitivas relacionadas à fadiga.

Métricas e índices foram analisados em diversos trabalhos. Em (Cao, 2014), o comportamento dos índices α , β , θ , e δ foram analisados juntamente com as métricas θ/α (Pyun, 2000), $(\alpha + \theta)/\beta$ (BROOKHUIS & DE WAARD, 2010), com o intuito de estabelecer relação entre o aumento de fadiga e valores de SNR (*Signal Noise Ratio*). Os resultados indicaram comportamento inverso entre os valores de

SNR e da razão θ / α em relação ao aumento de fadiga, para todos os eletrodos, nas bandas teta e alfa. (Jap, 2009) constatou uma significativa atenuação em beta e apesar das métricas apresentarem comportamento crescente, apenas $(\alpha + \theta) / \beta$ (BROOKHUIS & DE WAARD, 2010) apresentou aumento significativo em sua magnitude. De maneira geral, os trabalhos reforçaram a importância de canais nas regiões frontais e parietais para detecção e classificação de fadiga mental.

2.5.2 ANÁLISE ESPECTRAL

Como as alterações relacionadas a fadiga são computadas ao longo das faixas de frequência, ou seja, ao longo dos ritmos ou padrões neurais, a análise do sinal no domínio da frequência é adequada para detectar o perfil da distribuição de energia destas perturbações.

Para isso, com base na decomposição do sinal EEG, ou seja, a partir da transformada de Fourier do sinal, as potências ao longo das frequências podem ser computadas pela densidade espectral de Potência (*Power Spectral Density*, PSD).

A análise de Fourier dada pela equação 2 pode ser entendida como o produto ponto a ponto de um sinal $x[n]$ (no caso, o EEG) por senóides de diferentes frequências, representadas por Euler em $e^{-\varphi i}$. Portanto, o resultado da transformada é uma representação tridimensional da série temporal, cujas dimensões são frequência, potência e fase, sendo esta última normalmente desconsiderada para a maioria das análises. Desta forma, pode-se considerar como os resultados mais típicos da transformada de Fourier uma matriz bidimensional com a frequência no eixo x, e a potência no eixo y (BUZSAKI, 2006).

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-\varphi i} \quad , \text{onde } e^{-\varphi i} = \cos(\varphi) + \text{sen}(\varphi)i \quad (2)$$

em que n se refere ao número de pontos (ou amostras) do sinal x, X é o coeficiente de Fourier da série temporal x na frequência k, e Euler representa as senóides que

representarão o sinal $x[n]$ no domínio da frequência. O produto ponto a ponto da série temporal $x[n]$ e as senóides resultará em uma lista de n números complexos, empregados para o cálculo do PSD.

Apesar de ignorar a precisão temporal do dado, ao transformar o domínio temporal para o frequencial, a transformada de Fourier provê uma análise quantitativa da relação entre a potência e as frequências. Contudo, para sinais não estacionários como o EEG, ou seja, sinais cuja média, variância e covariância mudam com o tempo, a transformada deve ser aplicada por segmentos do sinal ao longo do tempo, o que justifica a divisão do sinal em trials (BUZSAKI, 2006).

Desta forma, a transformada de Fourier é implementada de trial em trial, ou em intervalos de trials, dependendo da especificação do especialista, através da transformada rápida de Fourier (FFT), que disponibiliza os coeficientes necessários para o cálculo da PSD.

A densidade espectral, portanto, é calculada a partir do produto da transformada de Fourier do sinal, dada pela equação 3

$$\phi(\omega) = \frac{F(\omega)F^*(\omega)}{2\pi} \quad (3)$$

onde ω é a frequência, $F(\omega)$ a transformada de Fourier do segmento do sinal $f(t)$, e $F^*(\omega)$ seu conjugado complexo.

Assim, para cada valor de frequência, um valor de PSD é calculado, resultando em um gráfico como o ilustrado pela Figura 9. Nela, o PSD dos dados coletados de um indivíduo durante quarenta e cinco minutos foram calculados por *trial*, e depois a média do PSD das trials correspondentes aos 15 primeiros minutos (1 a 15 min), 15 minutos intermediários (15 a 30 min) e 15 minutos finais (30 a 45 min) foram plotadas, de forma a evidenciar o comportamento do PSD com o aumento da fadiga mental.

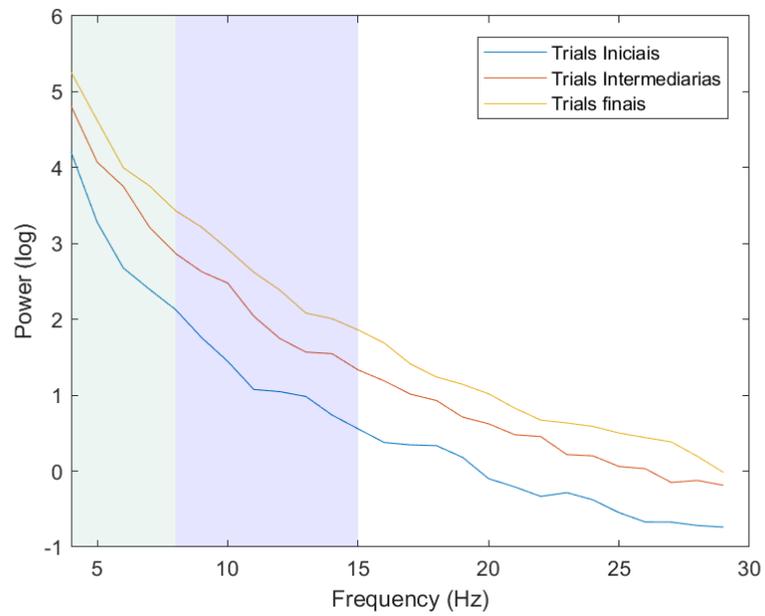


Figura 9 Gráfico de PSD de 45 minutos de dados divididos de 15 em 15 minutos. Observa-se que, para o sujeito em questão, o PSD apresentou comportamento crescente com o aumento da fadiga mental.

3 REDES NEURAIS AUTOASSOCIATIVAS

As redes neurais artificiais (RNA) ou simplesmente redes neurais (RN) têm viabilizado a resolução de uma variedade de problemas em diferentes áreas de estudo. Os estudos iniciais de Warren McCulloch e Walter Pitts, em 1943, repercutiram nos próximos 50 anos, e ainda repercutem na forma em que a ciência lida com dados, e como pode ser interpretada.

Neste capítulo, serão apresentados os fundamentos importantes para o entendimento das RNs, com ênfase na Rede Neural Autoassociativa, que foi utilizada neste trabalho.

3.1 O *PERCEPTRON*

As pesquisas iniciais do que viria a ser as RNs tinham o propósito inicial de serem inspiradas no sistema nervoso humano e, portanto, a modelagem matemática destes primeiros estudos se assemelhava com a lógica fisiológica do corpo humano. Por exemplo, a estrutura mais simples da Inteligência Computacional, o Perceptron, também referenciado como neurônio na perspectiva computacional, tem sua estrutura e matemática semelhantes a um neurônio humano. No esquemático da Figura 10 pode-se observar esta similaridade ao compararmos a fisiologia de um neurônio em a), com o modelo do *Perceptron* em b).

Esta similitude se justificava pela motivação de cientistas na época em modelar o sistema nervoso, imitando a forma em que neurônios transmitem os pulsos neurais. Contudo, a semelhança entre organismos biológico e computadores não é uma preocupação compartilhada por pesquisadores atuais, sendo um dos fatores motivacionais a construção de computadores com alto grau de paralelismo (DE AZEVEDO, 2000).

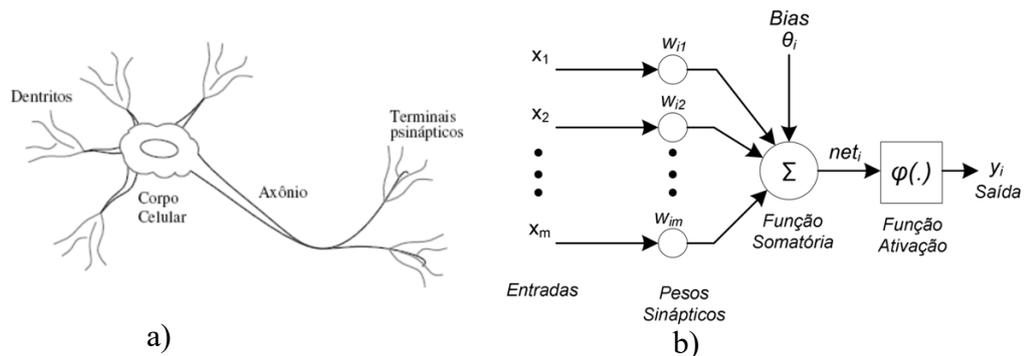


Figura 10 Semelhanças entre a estrutura de um neurônio humano à esquerda, e o esquemático da modelagem matemática de um *Perceptron* à direita. Em a) a estrutura fisiológica do neurônio (Dendritos, Soma e Axônio) são semelhantes as variáveis matemáticas (x , somatório e u). Fonte: Retirado de Sánchez, 2011.

Ainda sobre a Figura 10, em b) o esquemático evidencia a estrutura do neurônio artificial, que computa uma função φ sobre uma soma ponderada das entradas binárias x_1, x_2, \dots, x_n , que associadas a pesos w_1, w_2, \dots, w_n , retorna uma resposta y , dada pela equação 4

$$y = \begin{cases} 1, & \text{se } \sum_{i=1}^m x_i w_i \geq t, \\ 0, & \text{outro} \end{cases} \quad (4)$$

A função φ , chamada de função de transferência ou função de ativação, tem papel fundamental no desempenho da rede neural, pois determina quando a saída do neurônio será alta (1) ou baixa (0 ou -1). As funções de ativação mais usualmente empregadas na literatura são: tangente hiperbólica, linear e sigmoide, exibidas na Figura 11.

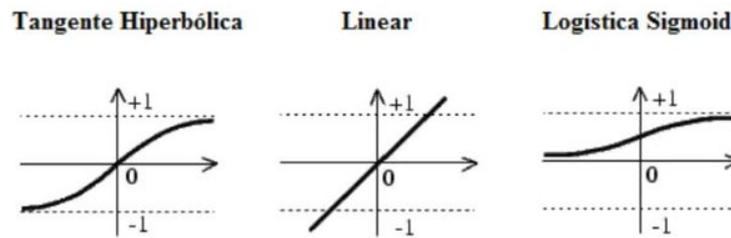


Figura 11 Principais Funções de Transferência. Fonte: Retirado de Mazi, 2008)

3.2 REDES MULTILAYER PERCEPTRON

A associação de Perceptron em camadas é denominada Perceptron de múltiplas camadas, do inglês, Multilayer Perceptron (MLP), e apresenta uma ou mais camadas intermediárias (também denominadas como escondidas), uma camada de entrada e outra de saída. As camadas intermediárias concentram o processo de aprendizagem, assim, a partir dos dados recebidos pela camada de entrada, faz o mapeamento linear ou não de forma a constituir uma resposta na forma definida pelos parâmetros da camada de saída. São consideradas redes aproximadoras universais, podendo realizar qualquer tipo de mapeamento linear ou não linear entre as entradas e saídas de um determinado sistema. A Figura 12 representa o esquemático da MLP, em que os neurônios estão agrupados em camadas de forma totalmente conectada.

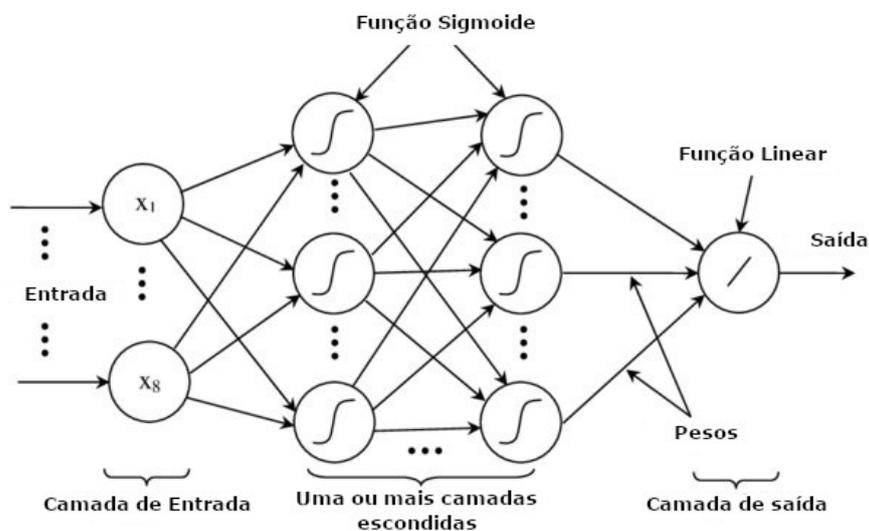


Figura 12 Esquemático de uma rede Perceptrons de múltiplas camadas. Observa-se que apesar das camadas de entrada e saída serem monocamadas, a camada escondida pode ter várias camadas, e com diferente função de ativação da camada de saída. Fonte: Adaptado de Bouzgou, 2012.

3.3 IMPLEMENTAÇÃO E APRENDIZAGEM DAS REDES NEURAIIS

A implementação de uma rede neural requer muito além de especificar o número de camadas, neurônios e funções de ativação. A aprendizagem da rede é determinada pela preparação dos dados a serem analisados e por modelos e algoritmos de aprendizagem.

A preparação dos dados refere-se à divisão dos mesmos em três categorias: treinamento, validação e teste. Essa divisão segue proporção que, em geral, varia entre 70% para o treinamento, 15% para validação e 15% para o teste. Dados de treinamento são utilizados para ajuste dos pesos w_n da rede. Os dados de validação por sua vez, verificam a capacidade de generalização da mesma. Por fim, os dados de teste são utilizados para verificação do desempenho da rede previamente treinada e validada, sem que haja nenhum ajuste nos pesos.

Quanto aos modelos de aprendizado, tem-se duas abordagens: modelo supervisionado e o não supervisionado. Entende-se por supervisionado o

aprendizado orientado, em que há a presença de um “supervisor externo”, isto é, além dos dados de entrada e saída, tem-se o sinal de erro que é calculado e empregado para avaliar os acertos da rede. O aprendizado não supervisionado por sua vez, não faz uso de nenhum dado além dos da entrada e saída, e é utilizado para explorar ou descrever um conjunto de informações, leia-se clusterização ou associação.

O algoritmo de aprendizagem refere-se à forma em que o ajuste dos pesos é realizado, e difere entre si dependendo do modelo de aprendizagem adotado (DE PADUA BRAGA, 2007). Para modelos de aprendizado supervisionado, o *Backpropagation* (WIDROW, 1986) é o algoritmo mais empregado, principalmente em redes de múltiplas camadas. Nele, o ajuste de pesos ocorre em duas fases: na primeira, chamada *forward*, os pesos são usados para o cálculo da saída da rede neural a partir de um sinal de entrada apresentado a rede. Na segunda fase, chamada *backward*, o erro de cada neurônio da camada de saída é utilizado para ajustar os pesos da camada escondida, e ocorre da camada de saída até a primeira camada escondida. O ajuste prossegue até que um critério de parada seja atingido, sendo o mais usual quando o erro médio quadrático da rede é menor que um determinado limiar.

Para modelos não supervisionados, o algoritmo de aprendizagem é determinado pela existência de regularidades e redundâncias nos dados de entrada. Destacam-se os mapas de Kohonen (KOHONEN, 1982), modelos ART (CARPENTER, 1988) e modelo Hebbiano (HEBB, 1948), sendo que em todos se visa a descoberta de características estatisticamente relevantes para os dados de entrada, com a descoberta de agrupamentos ou classes.

3.4 REDES NEURAI AUTOASSOCIATIVAS

Uma Rede Neural autoassociativa (RNAA) é um caso especial da rede MLP, onde se tem uma rede com o mesmo número de entradas e saídas, sendo que a rede deverá ser treinada para realizar um mapeamento do vetor de entrada no vetor de

saída. Durante a fase de treinamento, a rede deverá aprender a reproduzir em sua saída os dados apresentados em sua entrada, sendo que a camada intermediária funcionará como camada codificadora que permitirá que a rede armazene em seus pesos sinápticos somente o conhecimento relacionado às principais características do conjunto de dados de entrada.

A Figura 13 apresenta um esquemático de uma RNAA em que um vetor de entrada X de m elementos é introduzido na rede. A rede apresenta m neurônios para ambas as camadas de entrada e saída. A rede apresenta 3 camadas escondidas : a camada de mapeamento $G(.)$, que apresenta uma quantidade de neurônios maior que a entrada; a de estrangulamento ou “*bottleneck*” $t(.)$, que possui a menor dimensão da rede; e a terceira camada escondida, a de desmapeamento $H(.)$, que tem dimensão igual à camada de mapeamento (KRAMER, 1991; HINES, 2000; NAJAFI, 2004).

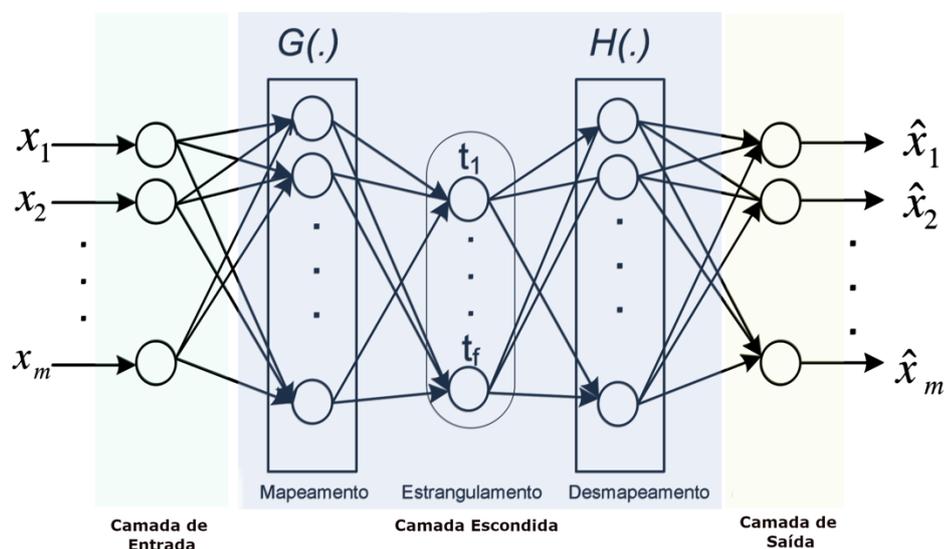


Figura 13 Esquemático de uma Rede Neural Autoassociativa com o número de neurônios intermediários. Fonte: Adaptado de Reyes, 2012.

As redes neurais autoassociativas são inspiradas na análise de componentes principais não lineares (NPCLA)(KRAMER, 1991; (TORRES, DE SEIXAS, &

SOARES FILHO, 2004)). A NPCLA é uma técnica para análise multivariada de dados, similar ao método de análise de componentes principais (PCA), e é usada para identificar e remover correlações entre variáveis de um problema como auxílio para redução de dimensionalidade e visualização e análise exploratória de dados. Enquanto a PCA identifica apenas correlações lineares a NPCLA trata também as correlações não lineares, sem restrição ao caráter das não linearidades presentes nos dados.

Apesar de serem usualmente utilizadas para problemas de redução de dimensionalidade, extração de características, processamento e restauração de dados ausentes, as propostas de usá-las para classificação de padrões têm sido exploradas em vários trabalhos (CHAKROBORTY, 2013; IVERSEN; TAYLOR; MIRANDA; CASTRO; LIMA, 2011, 2012).

Quando uma RNAA for utilizada para problemas de classificação, como será no caso desta proposta de dissertação, a necessidade do número de neurônios na camada escondida ser menor do que da camada de entrada/saída é eliminada. O que se pretende somente é utilizar a capacidade de mapeamento de identidade da RNAA, onde esta deverá guardar em seus pesos as características dos padrões/dados utilizados para o treinamento da rede. A rede deverá aprender a distribuição dos dados apresentados à mesma. Para este caso, após a fase de treinamento da RNAA, ao se apresentar para os mesmos padrões que não fizeram parte da distribuição dos dados utilizados no treinamento, a rede não conseguirá responder adequadamente, apresentando valor elevado de erro entre entrada e saída da mesma.

4 REDES NEURAIS AUTOASSOCIATIVAS APLICADAS À CLASSIFICAÇÃO DE FADIGA MENTAL

4.1 INTRODUÇÃO

Como já mencionado, uma rede Autoassociativa é um caso especial da rede MLP, onde a Rede é treinada para realizar um mapeamento do vetor de entrada no vetor de saída, sendo que a camada intermediária permite que seja armazenado em seus pesos sinápticos somente conhecimento relacionado às principais características do conjunto de dados de entrada.

Considerando então as características autoassociadoras das RNAs, este capítulo tem como objetivo apresentar o sistema proposto desenvolvido para classificação de fadiga mental através de sinais EEG empregando uma estrutura competitiva de RNAs.

A Figura 14 apresenta o esquema da estrutura competitiva de RNAs proposta.

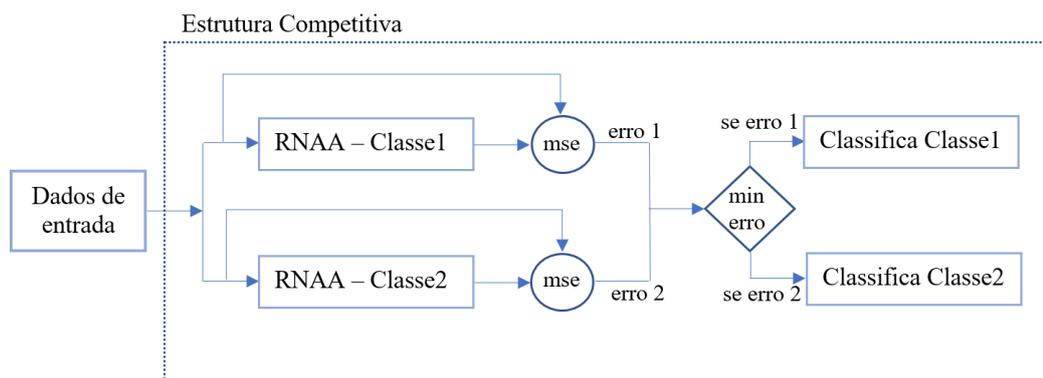


Figura 14 Esquemático da estrutura competitiva. As duas RNAs de cada classe reconstróem o mesmo dado de entrada, no qual é calculado o erro MSE, que determinará, para o caso de ser o menor, a classe do dado de entrada.

O sistema proposto funciona recebendo um padrão que serve como entrada simultânea para duas RNAs, sendo que cada RNA foi, numa etapa anterior, treinada para aprender a função que realiza o mapeamento do vetor de entrada no vetor de saída. Uma RNA foi treinada apenas com padrões representativos da classe Normal (indivíduo sem fadiga mental) e a outra RNA com padrões representativos da classe de indivíduos com fadiga Mental. Após a apresentação do padrão a ser classificado para as duas redes previamente treinadas, cada uma calcula a sua saída. O cálculo do erro médio quadrático entre a entrada e saída de cada rede deverá então ser realizado. A RNA que apresentar menor erro quadrático médio será considerada a rede vencedora e conseqüentemente o padrão apresentado na entrada do sistema será classificado de acordo com a classe atribuída à esta rede. A RNA vencedora é a rede cujo os seus padrões de treinamento (distribuição dos dados) mas se aproximaram dos padrões apresentados na entrada para classificação.

Para o desenvolvimento do sistema proposto foi seguido o esquema apresentado na Figura 15. São 3 as principais etapas as quais os dados foram submetidos para poderem então ser utilizados para treinamento das duas RNAs e desenvolvimento da estrutura competitiva proposta. Na primeira etapa tem-se o pré-processamento do sinal EEG, onde os dados foram filtrados e analisados para remoção de ruídos e interferências de outros sinais humanos (como cardíacos, musculares, oculares entre outros). Em seguida, numa segunda etapa, o cálculo da densidade espectral de potência foi realizado com o intuito de identificar perturbações no sinal que estejam relacionadas a fadiga mental. Na terceira etapa as perturbações refletidas pelo PSD foram organizadas em um vetor de características que, após ser normalizado, serviu como sinal de entrada para desenvolvimento da estrutura competitiva de RNA (classificação). As sessões seguintes abordarão a implementação de cada uma destas etapas, sendo então apresentado no final do capítulo os resultados alcançados da estrutura desenvolvida para classificação de fadiga mental a partir de sinais EEG.

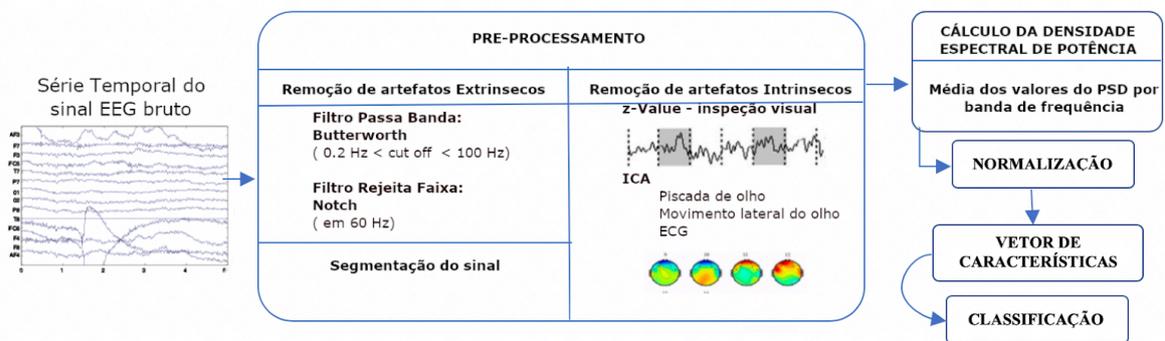


Figura 15 Esquemático da implementação da proposta deste trabalho. No pré-processamento remove artefatos e ruídos. Em seguida o PSD é calculado para a criação do vetor de características, que será a entrada para o modelo de classificação proposto neste trabalho.

4.2 BASE DE DADOS

Disponibilizada em domínio público por (MIN, WANG, & HU, 2017), trata-se de uma base de dados coletada de 12 indivíduos homens, com variação de idade entre 19 e 24 anos. Todos foram orientados a se abster de medicamentos, álcool, café ou qualquer outro tipo de estimulante, e que dormissem por pelo menos 8 horas. Os equipamentos de coleta não foram especificados, contudo a autora especifica a taxa de amostragem de 1000 Hz, e faz referência a uma touca de captura de sinais neurais com 30 eletrodos, organizados segundo o sistema EEG 1020.

O experimento da coleta consiste em dirigir continuamente um carro virtual em um simulador estático em ambiente controlado. O cenário do ambiente virtual escolhido foi uma estrada de baixo tráfego de carros. Antes do experimento de aquisição dos sinais neurais, os participantes se ambientaram com o simulador durante 5 minutos, seguidos de 10 minutos de descanso, para então, a coleta de 1 a 2 horas de duração ser iniciada.

A gravação dos dados se dava em duas fases, na primeira, quando o experimento já tinha 20 minutos de simulação, os últimos 5 minutos de dados EEG são separados e etiquetados como estado normal (ou não fadigado). Na segunda fase,

quando a gravação já perdurara entre 40 e 100 minutos, ou quando o indivíduo manifestava fadiga baseado pelos questionários de Escala de Chalder (Borg, 1990) e Escala Subjetiva de Lee (Lee, 1991), os últimos 5 minutos de sinal EEG coletado são separados e rotulados como no estado de fadiga. Portanto, os dados analisados têm 5 minutos de duração para a classe normal e 5 minutos de duração para a classe fadigada, para cada um dos 12 sujeitos.

A Figura 16 mostra exemplos de sinais obtidos dos eletrodos Fp1 e Fp2 de um segmento do sinal, que evidencia a diferença visual entre os estados normal e fadigado. A classificação por esta diferença visual é possível, contudo o uso de um parâmetro característico (como a energia, por exemplo) para detectar fadiga é mais efetivo (MIN, WANG, & HU, 2017).

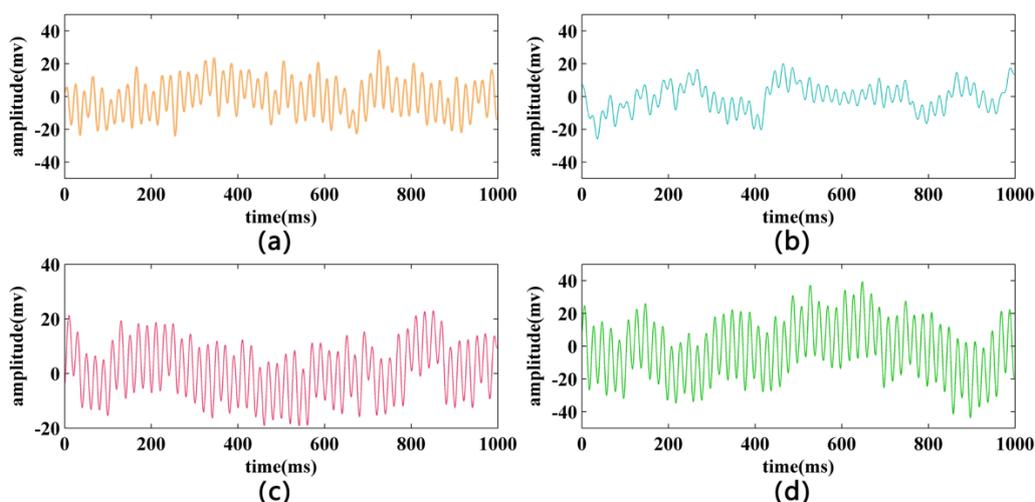


Figura 16 Segmentos do sinal EEG para ambos os estados mentais. Em a) e b), são mostrados os sinais do estado normal para os eletrodos Fp1 e Fp2 respectivamente. Em c) e d), o estado fadigado é exibido para estes mesmos eletrodos respectivos. Fonte: Retirado de Min, 2017.

4.3 PRÉ-PROCESSAMENTO

A filtragem e cálculo da análise independente de componentes foram empregadas no processo de remoção de ruídos e artefatos. Os filtros implementados

foram o filtro passa banda (BP) Butterworth de quarta ordem com as frequências de corte 0.2 e 100 Hz, e o filtro rejeita faixa do tipo Notch em 60 Hz. O intervalo 0.2 a 100 Hz foi considerado por englobar todas as frequências de interesse de delta (1 – 4 Hz) a gama (30 – 100 Hz).

Em seguida, o sinal contínuo foi segmentado em trials de 1 segundo. Com a taxa de amostragem de 1kHz, os 5 minutos de dados, ou melhor, 300 segundos de dados de cada classe, resultaram em 300 trials de mil amostras cada, resultando em uma matriz multidimensional de 300 trials por 30 canais por 100 frequências.

A segmentação do sinal possibilita a inspeção visual do mesmo, para a remoção de trials com picos ou distorções produzidas por piscada de olho ou impedância entre eletrodos. Trials com estes tipos de ruídos apresentam um valor z maior, ou seja, o desvio padrão da média de todas as amostras de uma trial em relação a todas as outras 299 trials é bem maior, caracterizando um valor de “ z ” mais disperso em relação a maioria das trials.

Como esta inspeção ocasiona perda de dado, o especialista normalmente define qual a quantidade máxima de trials que pode remover. Neste trabalho, foi considerado que das 300 trials, até 20 poderiam ser removidas com base no z value, resultando em uma remoção de no máximo 20 segundos dos dados originais. Assim, os dados filtrados resultaram em 280 trials, ou 4 minutos e 40 segundos para cada classe, organizados em uma matriz tridimensional de 280 trials por 30 canais por 100 frequências.

Após este procedimento, a análise de componentes foi implementada para remover sinais indesejados de naturezas adversas. A partir dos padrões de componentes referidos na Figura 8 o sinal EEG foi filtrado de ruídos de diferentes origens fisiológicas.

4.4 DENSIDADE ESPECTRAL DE POTÊNCIA

O sinal pré-processado possibilita que a densidade espectral de potência seja calculada para cada trial, eletrodo e frequência. Contudo, a presente proposta da análise da fadiga mental por métricas e índices, determina que as matrizes de PSD fossem calculadas de acordo com os índices α (8 – 15Hz), β (15 - 30Hz) e θ (4 - 8Hz), e com as razões θ/α , β/α , $\frac{(\alpha + \theta)}{\beta}$ e $\frac{(\alpha + \theta)}{(\alpha + \beta)}$. A Tabela 2 resume a organização das matrizes (trial x canal x frequência) do sinal filtrado e as do PSD, suas respectivas nomenclaturas e os índices e métricas calculados. A média dos valores da frequência seguiu a abordagem de calcular os índices do PSD para os seus respectivos intervalos. Nas razões, além da média nas frequências, a média nos canais (ou eletrodos) foi considerada para que as razões fossem calculadas para todas as regiões corticais.

Tabela 2 Organização das matrizes, para cada indivíduo, dos dados filtrados e as do PSD juntamente com suas respectivas nomenclaturas empregadas para a criação do vetor de características.

Nomenclatura	Índices e métricas	Matrizes dos dados filtrados (trials x canal x freq)	Matrizes dos valores PSD (trials x canal)
I_α	α	280 x 30 x 5	280 x 30
I_β	β	280 x 30 x 5	280 x 30
I_θ	θ	280 x 30 x 4	280 x 30
r_1	θ/α	280 x 30	280 x 1
r_2	β/α	280 x 30	280 x 1
r_3	$\frac{(\alpha + \theta)}{\beta}$	280 x 30	280 x 1
r_4	$\frac{(\alpha + \theta)}{(\alpha + \beta)}$	280 x 30	280 x 1

4.5 VETOR DE CARACTERÍSTICAS

Apesar de cada índice e métrica possuírem uma performance particular como indicadores de fadiga, considerou-se que o agrupamento de diferentes frequências e razões possibilitasse uma análise compensativa, no sentido de cada razão contribuir para uma detecção minuciosa de padrões cognitivos em que, caso uma métrica não seja suficientemente sensível a uma perturbação, esta seja compensativamente detectada por outra métrica. Razões e índices reforçaram a importância dos canais das regiões frontais e parietais para detecção e classificação de fadiga mental.

Assim, de acordo com a nomenclatura da Tabela 2, o vetor de características V_{irpsd} será criado a partir da concatenação horizontal das razões $\{r_1, r_2, r_3, r_4\}$ e dos índices $\{I_\alpha, I_\beta, I_\theta\} \in \mathbb{R}^\varepsilon$, onde $\varepsilon = 30$ canais, descrito como na equação 9.

$$V_{irpsd} = [r_1, r_2, r_3, r_4, I_\alpha^1, I_\alpha^2, \dots, I_\alpha^\varepsilon, I_\beta^1, I_\beta^2, \dots, I_\beta^\varepsilon, I_\theta^1, I_\theta^2, \dots, I_\theta^\varepsilon] \quad (9)$$

Desta forma, o vetor de características consiste no agrupamento vertical das matrizes do PSD dos 12 sujeitos, ou seja, (280 trials * 12 sujeitos = 3360 amostras) para cada classe, resultando então em 6720 amostras (3360 * 2 classes), e 94 atributos concatenados horizontalmente (30 canais I_α + 30 canais I_β + 30 canais I_θ + $r_1 + r_2 + r_3 + r_4$).

A Figura 17 ilustra esta ordenação dos índices e métricas no vetor de características. Em a), a figura exhibe a ordenação das razões e métricas para um indivíduo, seguindo a notação $r_n^{t,s}$ para as razões e $I_{\varepsilon,c}^{t,s}$ para as métricas. Em ambas, as variáveis t e s dizem respeito à quantidade de trials concatenadas (ou seja, de 1 a 280 para 1 indivíduo, e de 1 a 3360 para os 12 indivíduos) e ao número de sujeitos respectivamente. Em $r_n^{t,s}$, n se refere as n razões empregadas (de 1 a 4), por exemplo de $r_4^{1,2}$ a $r_4^{280,2}$, temos a concatenação das 280 trials do sujeito 2 para a

razão 4. Em $I_{\varepsilon,c}^{t,s}$, ε refere-se aos índices α, β ou θ , e c , aos canais que variam de 1 a 30.

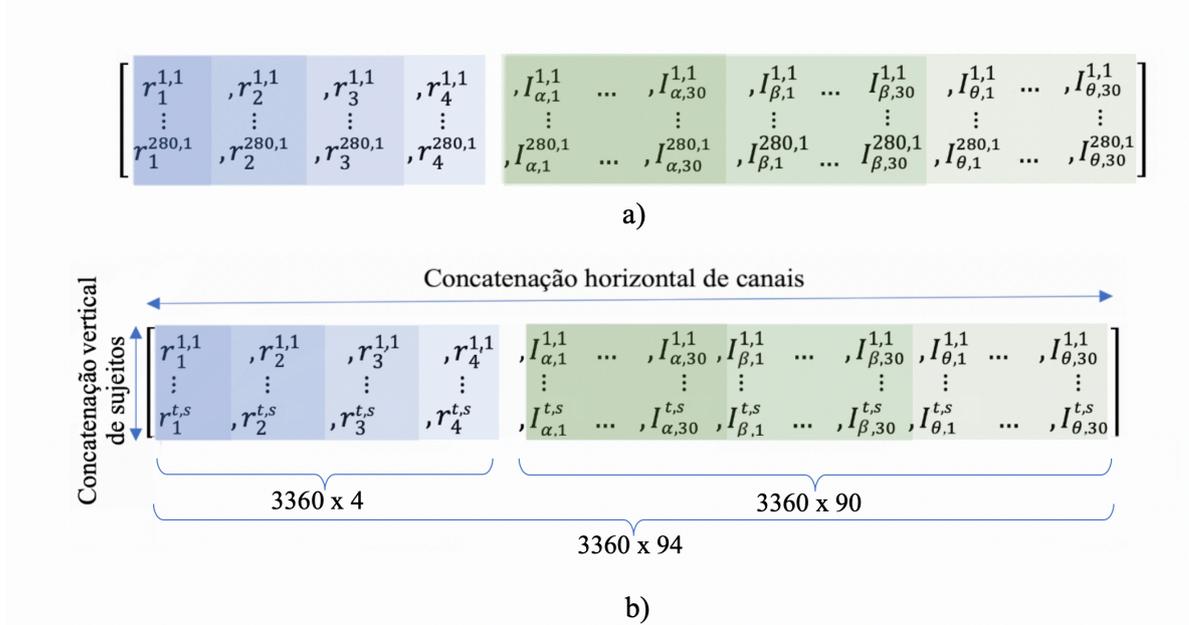


Figura 17 Concatenação das matrizes de PSD para criação do vetor de características. Em a), a representação do vetor de características para um indivíduo, em b), há a concatenação vertical de todas as 280 trials dos 12 sujeitos. A concatenação horizontal une, linha a linha, os valores das 4 razões, e dos 3 índices para cada um dos 30 canais.

Em 17 b), a mesma representação de 17 a) é retratada, contudo considerando todos os 12 indivíduos, assim as 280 trials de cada sujeito são concatenadas verticalmente, resultando em 3360 amostras. Deste modo, o vetor de características possui 3360 amostras por 94 atributos para cada classe. Os dois vetores de entrada para a rede são todos os 94 atributos para cada uma das amostras, o que definirá a quantidade de neurônios na camada de entrada e na de saída da RNAA, que será de 94.

4.6 NORMALIZAÇÃO DO SINAL

Seguinte a criação do vetor de características, a redução da variabilidade dos dados foi feita a partir de uma normalização do tipo min-máx em cada um dos 94 atributos, de ambas as classes entre 0 e 1 (Siravenha, 2016). As equações 5, 6, 7 e 8 foram empregadas para normalizar as quatro razões (r_i) e cada um dos índices C_α , C_β e C_θ respectivamente.

$$Norm_{r_i} = \frac{r_i - \min(r_i)}{\max(r_i) - \min(r_i)}, \quad i = [1,2,3,4] \quad (5)$$

$$Norm_{C_\alpha} = \frac{C_\alpha^{\zeta,i} - \min(C_\alpha^{\zeta,i})}{\max(C_\alpha^{\zeta,i}) - \min(C_\alpha^{\zeta,i})}, \quad i = [1,2,3,4,5] \text{ e } \zeta = [1,2, \dots, 30] \quad (6)$$

$$Norm_{C_\beta} = \frac{C_\beta^{\zeta,i} - \min(C_\beta^{\zeta,i})}{\max(C_\beta^{\zeta,i}) - \min(C_\beta^{\zeta,i})}, \quad i = [1,2,3,4,5] \text{ e } \zeta = [1,2, \dots, 30] \quad (7)$$

$$Norm_{C_\theta} = \frac{C_\theta^{\zeta,i} - \min(C_\theta^{\zeta,i})}{\max(C_\theta^{\zeta,i}) - \min(C_\theta^{\zeta,i})}, \quad i = [1,2,3,4,5] \text{ e } \zeta = [1,2, \dots, 30] \quad (8)$$

Onde $Norm_{r_i}$ é a normalização de cada uma das quatro razões com i de 1 a 4, e $Norm_{C_\alpha}$, $Norm_{C_\beta}$ e $Norm_{C_\theta}$ referem-se a normalização dos índices α , β e θ , calculadas em todos os 30 canais.

4.7 MODELO DE CLASSIFICAÇÃO

Para desenvolvimento do modelo de classificação proposto e apresentado na Figura 15, a primeira etapa consistiu no treinamento das duas RNAAs, sendo que

uma RNAA foi treinada para aprender os padrões para caso de indivíduos sem fadiga mental e outra para o caso de indivíduos com fadiga mental. Após o treinamento das RNAAs, a estrutura competitiva pôde ser organizada e testada a partir de uma base de testes para então ser avaliada a partir dos resultados obtidos.

4.7.1 TREINAMENTO E VALIDAÇÃO DAS RNAAS

Para treinamento das duas RNAAs a base de dados foi dividida randomicamente na proporção 70 % para o treinamento, 15% para a validação e 15% para o teste.

A Tabela 3 apresenta o número de padrões de treino, validação e teste para cada classe. Como o vetor de características possui 3360 amostras por classe, a quantidade de amostras para o treinamento, validação e teste foi a mesma.

Tabela 3 Quantidade de padrões para o treinamento, validação e teste

	Treinamento	Validação	Teste
Classe	2352	504	504

Várias topologias de redes, com diferentes números de neurônios na camada escondida (100, 150, 175 e 200 neurônios) foram treinadas para que fossem então escolhidas as duas topologias (para cada classe) com menor erro MSE para dados de teste. Lembrando que de acordo com o vetor de características, as topologias apresentam 94 neurônios na camada de entrada e saída. Cada topologia de rede foi treinada cinco vezes (5 inicializações de pesos), para aumentar a possibilidade de se chegar ao menor valor de erro possível (mínimo global). Para treinamento utilizou-se o Método do Gradiente Conjugado. Para evitar “sobre treinamento” da rede utilizou-se o Cross-validation [(KOHAVI, 1995)] como método de parada. Todos os treinamentos foram realizados utilizando o Matlab e o toolbox Fieldtrip.

Os resultados para as diversas topologias treinadas são apresentados na Figura 18, onde a pesquisa em malha para os quatro valores de neurônios intermediários

{100, 150, 175, 200} (eixo x) nos cinco laços (eixo y), retornou os erros médios quadráticos para base de teste das redes neurais para cada classe. Para a classe 1, ou seja, para a classe da fadiga, a rede neural com 100 neurônios escondidos na segunda inicialização de pesos apresentou o menor valor MSE, sendo este valor de 0.003714. Para a classe 2, isto é, para a classe normal, a topologia de 150 neurônios, da primeira inicialização de pesos apresentou o menor erro quadrático, sendo este valor de 0.001433. Portanto, estas redes foram selecionadas para serem utilizadas na estrutura competitiva para classificação de fadiga e serão chamadas de agora em diante de RN1, para a da classe 1, e RN2 para a da classe 2.

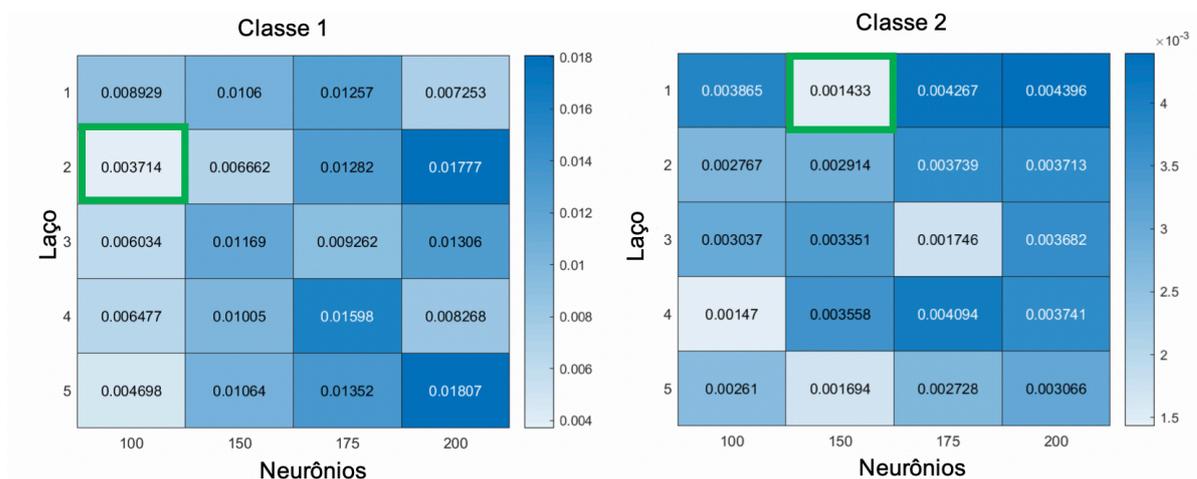


Figura 18 Valores da pesquisa em malha com os erros médios quadráticos para cada classe. Em destaque as redes com menor erro para classe 1 e 2 em verde.

Antes de se organizar a estrutura competitiva com as duas redes selecionadas, optou-se por realizar uma segunda etapa para validar as redes selecionadas, sendo que, nesta etapa, foi realizada a avaliação das duas redes neurais em termos de percentual de erro de reconstrução, a partir do teste de Wilcoxon.

O teste de Wilcoxon é um método estatístico não paramétrico, ou seja, que não exige conhecimento prévio da distribuição das amostras em relação a população, nem de parâmetros estatísticos como variância e desvio padrão. É um dos mais interessantes testes estatísticos, pois leva em consideração a diferença da magnitude entre as amostras comparadas, e permite atribuir maior peso aos pares com maior diferença.

Esse teste assume que as amostras são independentes, e indica se os sinais comparados são, amostra a amostra, significativamente diferentes, através de um valor de “p”, expresso como um valor escalar no intervalo de 0 a 1, onde valores $p \leq 0.05$ fornecem uma evidência que os dois sinais comparados são diferentes.

A condição dos sinais comparados serem iguais é denominada hipótese nula e, portanto, quando os sinais são significativamente diferentes, diz-se que a hipótese nula foi rejeitada.

Matematicamente, o teste de Wilcoxon é calculado através do ranqueamento pela diferença absoluta, da diferença entre dois pares de amostras. Esta ordenação é feita levando em conta o sinal da diferença entre pares. O somatório destas diferenças é comparado com valores tabelados chamados de valores críticos, que variam de acordo com o número de amostras. Os valores de “p” de “W” de cada amostra são calculados segundo a equação 10

$$W = \sum_{i=1}^N [\text{sgn}(x_{2,i} - x_{1,i}) \cdot R_i] \quad (10)$$

em que N é o número de amostras, $x_{2,i}$ e $x_{1,i}$ são as duas amostras comparadas, e R_i a posição no *ranking* das diferenças das amostras. O valor de p de W é calculado então a partir do somatório dos postos positivos ou negativos da diferença entre duas amostras organizadas segundo a diferença absoluta entre os mesmos.

A partir de Wilcoxon calcula-se o erro de reconstrução (*er*) dado em percentual, que representa o quanto do dado reconstruído não foi satisfatoriamente replicado em termos estatísticos. A equação 11 define o cálculo do *er*.

$$er = \frac{100 \cdot n}{q} \quad (11)$$

sendo n o número de amostras com diferença significativa segundo Wilcoxon, (ou seja, com $p \leq 0.05$), q a quantidade de padrões analisados de acordo com a base utilizada (Wilcoxon será empregado na base de teste, e portanto o valor de q sempre será 504). Assim, caso 10 amostras da validação tenham $p \leq 0.05$, e por isso apresentem diferença estatística entre si, o percentual do *er* será dado por $\frac{100 \cdot 10}{504}$.

Para avaliar as duas RNAAs através do método estatístico, os dados da base de teste das duas classes foram introduzidos nas duas redes RN1 e RN2. Espera-se com essa avaliação, verificar o percentual de erro de reconstrução, presumindo que a rede treinada, para sua respectiva classe, tenha um percentual de erro no sinal de saída menor do que para a outra classe. Também é de interesse investigar o quanto de dados com diferença significativa uma rede especializada em uma classe apresenta.

Como o vetor de características para o teste tem 504 amostras por 94 atributos por classe, correspondentes aos 15% da base de dados, o percentual de erro será calculado em relação à este valor de 504. Os cenários de análise são as combinações das redes neurais de cada classe e as classes propriamente ditas, por exemplo RN1C1 refere-se a rede neural treinada para a classe 1 recebendo a classe 1. A Tabela 4 apresenta os resultados do erro “*er*” baseado no teste estatístico de Wilcoxon, considerando cenários a combinação e redes e classes.

Tabela 4 Resultados do teste estatístico de Wilcoxon.

Cenários	Amostras com diferença estatística	Amostras iguais	Erro de reconstrução (%)
RN1C1	10	494	1,9841
RN1C2	44	460	8,7302
RN2C1	74	430	14,5714
RN2C2	18	486	3,5714

Assim, o teste estatístico indica que para redes treinadas para uma determinada classe, o erro de reconstrução não atinge 5% do sinal de entrada quando se entra com dados da própria classe. Para o caso em que se entra com dados que não pertencem a classe para a qual a rede foi treinada, o erro de reconstrução é um pouco maior, chegando a quase 15%, o que confirma que as redes selecionadas pelo menor erro MSE, e especializadas em uma classe, apesar de ainda apresentar um erro de reconstrução, este não é suficiente para prejudicar a classificação.

4.7.2 ESTRUTURA COMPETITIVA DE RNAAS PARA CLASSIFICAÇÃO DE FADIGA MENTAL

Após o treinamento e escolha das duas RNAAs, a estrutura competitiva apresentada na Figura 15 foi implementada e avaliada considerando-se a base de teste.

Os dados de teste para as duas classes foram concatenados, sendo as 504 primeiras amostras, as da classe fadigada (classe 1) e as 504 últimas, as da classe normal, portanto, o vetor de características da entrada com os dados de teste para a classificação foi de 1008 amostras por 94 atributos.

Uma forma de se avaliar o desempenho de um classificador é através de sua matriz de confusão, que permite identificar acertos e erros de classificação da rede. Desta matriz, derivam-se diversas medidas que podem ser utilizadas para análise de desempenho: acurácia, taxa de verdadeiros positivos (sensitividade), verdadeiros negativos (especificidade), entre outras (POWERS, 2011).

Estas medidas abrangem conceitos relacionados aos tipos de erros e acertos do sistema. Tomando-se uma classe como classe positiva, e outra como classe negativa, denomina-se falso negativo (fn) quando amostras do dado de entrada de classe positiva são classificadas incorretamente como classe negativa, falso positivos (fp) quando amostras de classe negativa são erroneamente classificadas como classe positiva, verdadeiro positivo (vp) quando se classifica corretamente os dados para as classes positivas, e por fim, verdadeiro negativo (vn), para amostras da classe negativa classificadas corretamente.

A sensitividade indica a taxa de classificação correta que um classificador pode apresentar (COHEN J. , 1960). Assim, quanto maior a sensibilidade, mais acertos o classificador apresenta. A sensitividade pode ser calculada através de:

$$s = \frac{vp}{(vp+vn)} \quad (12)$$

A especificidade é uma medida também derivada da análise da matriz de confusão e diz respeito a capacidade do sistema em detectar quando não é determinada classe (COHEN J. , 1960) e pode ser calculada através de:

$$esp = \frac{vn}{(vn+fp)} \quad (13)$$

A acurácia também é uma medida analisada a partir da matriz de confusão, e indica a relação entre todas as classificações corretas de ambas as classes, por todas as classificações corretas e erradas do modelo classificador (COHEN J. , 1960), sendo calculada através de :

$$acc = \frac{(vp+vn)}{(vp+vn+fp+fn)} \quad (14)$$

A matriz de confusão para o sistema classificador para a base de dados de teste é apresentada na Tabela 5. Este tipo de tabela é interpretado de forma que cada linha representa a predição da classificação das classes, e as colunas, os mesmos dados rotulados para cada classe. Linhas e colunas podem ter seu significado invertido.

Tabela 5 Matriz de confusão dos dados de teste

Classe	1	2	Sensibilidade (%)	Especificidade (%)
1	503	1	99,80%	99,60%
2	2	502	99,60%	99,80%
Acurácia				99,70%

Os altos valores de sensibilidade e especificidade da matriz de confusão da Tabela 6, indicam que o sistema proposto tem grande capacidade de predizer e classificar corretamente as classes dos estados mentais, e em apontar corretamente verdadeiros negativos, ou seja, de predizer e classificar corretamente quando uma classe verdadeiramente não ocorre, por exemplo, quando não é a classe 2, e de fato não era a mesma.

Comparando os resultados com cinco outros trabalhos que também objetivam a classificação da fadiga mental empregando MLP, a abordagem proposta apresenta, em média, um desempenho superior de 8,85%. A Tabela 6 exibe o percentual de acurácias destes trabalhos. Ressalta-se que na abordagem original de (MIN, WANG, & HU, 2017), a acurácia máxima foi de 98,30%.

É importante salientar que uma comparação direta entre resultados deve ser realizada com cuidado visto que os sistemas desenvolvidos apresentam diferentes dados de entrada para o sistema assim como diferentes divisões para dados de treino, validação e teste das redes.

Tabela 6 Comparativo de acurácias de classificação de fadiga mental em vários trabalhos.

Trabalho	Acurácia
Presente trabalho	99,70%
(Ferreira, 2018)	98,8%
(MIN, WANG, & HU, 2017)	98,3%
(Chai, et al., 2017)	93,1%
(Pimenta, Carneiro, Neves, & Novais, 2016)	81%
(King, Nguyen, & Lal, 2006)	83,06%

Para comparação de resultados usando a mesma base de dados, foi realizado o treinamento de uma única rede MLP. Diversas topologias variando-se o número de neurônios na camada escondida foram testadas sendo que o melhor resultado foi para a MLP com 100 neurônios. A entrada para a rede MLP foram os 94 atributos usados no sistema proposto. A Tabela 7 apresenta a matriz de confusão obtida para a base de testes.

Tabela 7 Matriz de Confusão do treinamento de uma única rede MLP com 100 neurônios

Classe	1	2	Sensibilidade (%)	Especificidade (%)
1	492	12	97,60%	100%
2	0	504	100%	97,7%
Acurácia				98.80%

Temos que para este caso o sistema errou a classificação para 12 casos, enquanto que para o sistema proposto, para a mesma base de teste, o sistema errou apenas 3 casos, mostrando assim a eficiência do sistema proposto e a aplicabilidade das redes neurais autoassociativas para o problema de classificação de fadiga mental.

5 CONCLUSÃO

Este trabalho apresentou a proposta de um sistema de classificação de fadiga mental baseado em uma estrutura competitiva de redes neurais autoassociativas baseada em sinais EEG. Para desenvolvimento do sistema utilizou-se a base de dados pública composta de dados de 5 minutos de 12 indivíduos, rotulados como dados normais e fadigados a partir de questionários de fadiga aplicados durante a coleta de dados. Como entrada para o sistema de classificação proposto foi usado um vetor de características composto pelas informações em três faixas de frequências (teta, beta e alfa) e quatro métricas, que diferenciam estados mentais a partir dos dados eletroencefalográficos, em termos de densidade de energia espectral.

Os bons resultados de classificação de fadiga, acima de 99% , obtidos a partir do sistema proposto demonstram a sua eficiência e aplicabilidade.

Considerando o uso de redes autoassociativas, podemos considerar que os resultados obtidos demonstram a aplicabilidade destas estruturas para problemas de classificação. Para o desenvolvimento das topologias autoassociativas, foi demonstrado que o erro médio quadrático e o teste estatístico de Wilcoxon se mostraram medidas viáveis para a avaliação da qualidade de reconstrução do sinal destas redes.

As dificuldades neste trabalho se concentraram no estudo da melhor forma de pré-processar os dados e agrupá-los em um vetor de características. Por tratar-se de discretas mudanças até mesmo na ótica da análise espectral, o agrupamento dos valores de índices e métricas foi desafiador, pois a ordenação das mesmas pode influenciar na classificação, o que deveria ser investigado.

O trabalho publicado no qual este estudo foi fundamentado se intitula “Uma Abordagem para Classificação de Fadiga Mental baseada em Sinais de Eletroencefalografia (EEG) “, publicado nos anais do IV Simpósio de Descoberta de Conhecimento, Mineração e Aprendizado (KDMILE), e pode ser acessado no endereço <https://bracis2018.mybluemix.net/files/anais-kdmile-2018.pdf>

Sugere-se para trabalhos futuros, um estudo comparativo sem a remoção de trials, preservando a quantidade dos dados, e aumentar a duração das trials para evitar efeitos de borda, aumentando a resolução dos dados. Além disso, aprofundar o estudo do percentual de erro de reconstrução com o valor de MSE e o próprio desempenho do sistema na classificação dos dados.

Também é sugerido implementar a proposta em outras bases de dados com menor taxa de amostragem e menor quantidade de eletrodos, para comparar a generalização do modelo proposto.

Os altos índices de acurácia, especificidade e sensibilidade do classificação são resultados que reforçam a eficiência do sistema proposto, assim como a aplicabilidade das redes neurais autoassociativas para problemas de classificação.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ALCIATORE, D. G. (2017). *Introduction to mechatronics and measurement systems*. Tata McGraw-Hill Education.
- BANICH, M. T., & COMPTON, R. J. (2018). *Cognitive neuroscience*. Cambridge University Press.
- BERGER, H. (1929). Electroencephalogram in humans. *Archiv fur Psychiatrie und nervenkrankheiten*, 527-570.
- BOLFE, V., RIBAS, S., MONTEBELO, M., & GUIRRO, R. (2007). Comportamento da impedância elétrica dos tecidos biológicos durante estimulação elétrica transcutânea. *Brazilian Journal of Physical Therapy*, 153-159.
- Borg, G. (1990). Psychophysical scaling with applications in physical work and the perception of exertion. *Scandinavian journal of work, environment & health* (, pp. 55-58.
- BOUZGOU, H. (2012). Advanced Methods for the Processing and Analysis of Multidimensional Signals: Application to Wind Speed. *Tese de Doutorado*. Université de Batna.
- BRADBURY, J. W., & VEHCAMP, S. L. (1998). *Principles of animal communication*.
- Brodman, K. (2006). *Brodman's: Localisation in the Cerebral Cortex*. Springer US.
- BROOKHUIS, K. A., & DE WAARD, D. (2010). Monitoring drivers' mental workload in driving simulators using physiological measures. *Accident Analysis & Prevention*, 898-903.
- BUZSAKI, G. (2006). *Rhythms of the Brain*. Oxford University Press.
- Cao, T. a. (2014). Objective evaluation of fatigue by EEG spectral analysis in steady-state visual evoked potential-based brain-computer interfaces. *Biomedical engineering online*, p. 28.
- CARPENTER, G. A., & GROSSBERG, S. (1988). The ART of adaptive pattern recognition by a self-organizing neural network. *Computer*, 21(3), 77-88.
- Chai, R., Ling, S. H., San, P. P., Naik, G. R., Nguyen, T. N., Tran, Y., . . . Nguyen, H. (2017). Improving EEG-Based Driver Fatigue Classification Using Sparse-Deep Belief Networks. *Frontiers in Neuroscience*, p. 103.
- Cheron, G. e. (2016). Brain oscillations in sport: toward EEG biomarkers of performance. *Frontiers in psychology* 7, p. 246.
- Chunlin Zhao, M. Z. (2018). The Reorganization of Human Brain Networks Modulated by Driving Mental Fatigue. *IEEE Journal of Biomedical and Health Informatics* , 743-755.
- COHEN, J. (1960). A coefficient of agreement for nominal scales. *Education and Psychological Measuremen*, 61-62.
- COHEN, M. X. (2015). *Cycles in mind: How brain rhythms control perception and action*. MIT press.
- DE AZEVEDO, F. M., BRASIL, L. M., & DE OLIVEIRA, R. C. (2000). *Redes neurais com aplicações em controle e em sistemas especialistas*. Redes neurais com aplicações em controle e em sistemas especialistas.

- DE PÁDUA BRAGA, A., DE LEON FERREIRA, A. C., & LUDERMIR, T. B. (2007). *Redes neurais artificiais: teoria e aplicações*. LTC Editora.
- DORGAN, S. J., & REILLY, R. B. (1999). A model for human skin impedance during surface functional neuromuscular stimulation. *IEEE Transactions on Rehabilitation Engineering*, 7, 341-348.
- E COSTA, M. F. (2005). *Dicionário de termos médicos*. Porto Editora.
- Eoh, H. J.-H. (2005). Electroencephalographic study of drowsiness in simulated driving with sleep deprivation. *International Journal of Industrial Ergonomics*, pp. 307-320.
- Georgios N. Dimitrakopoulos, I. K. (2017). Driving Mental Fatigue Classification Based on Brain Functional Connectivity. Em I. L. Boracchi G., *Engineering Applications of Neural Networks. EANN* (pp. 465-474). Springer, Cham.
- Gevins, A., Leong, H., Du, R., Smith, M., Le, J., DuRousseau, D., . . . Libove, J. (1995). Towards measurement of brain function in operational environments. *Biological Psychology*, 169-186.
- Hart, S. a. (1986). NASA Task Load Index (TLX) V1. 0 Users Manual.
- HAYKIN, S. (2007). *Redes neurais: princípios e prática*. Bookman Editora.
- Hebb, D. (1949). *The Organization of Behavior*. Psychology Press.
- HELTON, W. S., & RUSSELL, P. N. (2011). Working memory load and the vigilance decrement. *Experimental brain research*, 429-437.
- Holm, A., Lukander, K., Korpela, J., Sallinen, M., & Müller, K. (2009). Estimating brain load from the EEG. *Scientific World Journal*.
- Jap, B. T. (2009). Using EEG spectral components to assess algorithms for detecting fatigue. *Expert Systems with Applications*, pp. 2352 - 2359.
- Johnson, R. R., Popovic, D. P., Olmstead, R. E., Stikic, M., Levendowski, D. J., & Berka, C. (2011). Drowsiness/alertness algorithm development and validation using synchronized EEG and cognitive performance to individualize a generalized model. *Biological Psychology*, 241-250.
- Junhua Li, J. L. (2016). Mid-task break improves global integration of functional connectivity in lower alpha band. *Frontiers in Human Neuroscience*.
- Käthner, I., Wriessnegger, S. C., Müller-Putz, G. R., Kübler, A., & Halder, S. (2014). Effects of mental workload and fatigue on the P300, alpha and theta band power during operation of an ERP (P300) brain-computer interface. *Biological Psychology*, 118-129.
- King, L., Nguyen, H., & Lal, S. (2006). Early Driver Fatigue Detection from Electroencephalography. *Proceedings of the 28th IEEE*.
- KOHAVI, R. e. (1995). study of cross-validation and bootstrap for accuracy estimation and model selection. *Ijcai*.
- KOHONEN, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 59-69.
- KRAMER, M. A. (1991). Nonlinear principal component analysis using autoassociative neural networks. *AICHE journal*, 233-243.
- LAL, S. K., & CRAIG, A. (2001). A critical review of the psychophysiology of driver fatigue. *Biological psychology*, 173-194.
- LEBEDEV, M. A., & NICOLELIS, M. A. (2006). Brain-machine interfaces: past, present and future. *TRENDS in Neurosciences*, 29, 536-546.
- Lee, K. A.-M. (1991). "Validity and reliability of a scale to assess fatigue." . *Psychiatry research* , pp. 291-298.

- Leonard J. Trejo, K. K. (2015). EEG-Based Estimation and Classification of Mental Fatigue. *Psychology*, 572-589.
- LORENA, A. C., GAMA, J., & FACELI, K. (2011). *Inteligência Artificial: Uma abordagem de aprendizado de máquina*. Grupo Gen-LTC.
- MARCUSE, L. V., FIELDS, M. C., & YOO, J. J. (2015). *Rowan's Primer of EEG E-Book*. Elsevier Health Sciences.
- MATTHEWS, G., HANCOCK, P. A., & DESMOND, P. A. (2012). *Models of individual differences in fatigue for performance research*. CRC Press Book.
- MIN, J., WANG, P., & HU, J. (2017). Driver fatigue detection through multiple entropy fusion analysis in an EEG-based system. *PLoS one*.
- Mizuno, K., Tanaka, M., Yamaguti, K., Kajimoto, O., Kuratsune, H., & Watanabe, Y. (2011). Mental fatigue caused by prolonged cognitive load associated with sympathetic hyperactivity. *Behavioral and Brain Functions*, 7-17.
- NAJAFI, M., GULP, C., & LANGARI, R. (2004). Enhanced auto-associative neural networks for sensor diagnostics (E-AANN). *IEEE International Conference on*, (pp. 453-456).
- Nicholas J. Gotelli, A. M. (2012). *A Primer of Ecological Statistics*. Oxford University Press.
- NOMENCLATURE, Standard Electrode Position. (1991). American electroencephalographic society guidelines for. *Journal of clinical Neurophysiology*, 200-202.
- ODOM, J. V., Bach, M., Brigell, M., Holder, G. E., McCulloch, D. L., Mizota, A., & Tormene, A. P. (2016). ISCEV standard for clinical visual evoked potentials: (2016 update). *Documenta Ophthalmologica*, 133, 1-9.
- PARADISO, M. A., BEAR, M. F., & CONNORS, B. W. (2007). *Neuroscience: exploring the brain*.
- Paris, S. G. (2001). Classroom applications of research on self-regulated learning. *Educational psychologist* 36.2 , pp. 89 - 101.
- Pimenta, A., Carneiro, D., Neves, J., & Novais, P. (2016). A neural network to classify fatigue from human-computer interaction. *Neurocomputing*, p. 172.
- POWERS, D. M. (2011). Evaluation: From precision, recall and f-measure to roc., informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 37-63.
- Pyun, H. a. (2000). A study on the effect of emotion-evoking advertisement with EEG analysis. Em S. KIIE and KORMS, *Proceedings of 2000 Joint Conference of KIIE and KORMS*. Seoul.
- REYES, J., VELLASCO, M., & TANSCHHEIT, R. (2012). Monitoramento e diagnóstico de múltiplos sensores por redes neurais auto-associativas. *Sba Controle & Automação [online]*, 121-137.
- Rifai Chai, S. H. (2017). Improving EEG-Based Driver Fatigue Classification Using Sparse-Deep Belief Networks. *Frontiers in Neuroscience*.
- SÁNCHEZ, J. E. (2011). Sistema de Monitoramento de Múltiplos Sensores por Redes Neurais Auto-Associativas e Lógica Fuzzy. *Tese de Doutorado*. PUC-Rio.
- SCHIER, M. A. (2000). Changes in EEG alpha power during simulated driving: a demonstration. *International Journal of Psychophysiology*, 155-162.
- SHERRINGTON, C. S., & SOWTON, S. C. (1915). Observations on reflex responses to single break-shocks. *The Journal of physiology*, 49, 331-348.

- T. Radüntz, J. S. (2015). EEG artifact elimination by extraction of ICA-component features using image processing algorithms. *Journal of Neuroscience Methods*, 84-93.
- TATUM IV, W. O. (2014). *Handbook of EEG interpretation*. Demos Medical Publishing.
- TREJO, L. J. (2015). EEG-based estimation and classification of mental fatigue. *Psychology*, p. 572 .
- TURING, A. M. (2009). *Computing machinery and intelligence*. Springer.
- WANG, Z., & BOVIK, A. C. (2009). Mean squared error: Love it or leave it? A new look at signal fidelity measures. *IEEE signal processing magazine*.
- Wascher, E., R. B., Sängler, J., Hoffmann, S., Schneider, D., Rinkenauer, G., . . . Gutberlet, I. (2014). Frontal theta activity reflects distinct aspects of mental fatigue. *Biological Psychology*, 57-65.
- WIDROW, B., & HOFF, M. E. (1986). Adaptive Switching Networks. *Parallel Distributed Processing*.
- Wong, D. a. (2001). Smiling face as anchor for pain intensity scales. *Pain*, pp. 295 - 297.
- Xu, J. W. (1970). An Evaluation of Instrument Calibration Monitoring Using Artificial Neural Networks. *Transactions of the American Nuclear Society*.
- Yu-Ting Liu, S.-L. W.-P.-Y.-C.-T. (2016). Driving fatigue prediction with pre-event electroencephalography (EEG) via a recurrent fuzzy neural network. *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. Vancouver, BC, Canada: IEEE.

