

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA

CLASSIFICAÇÃO DE EMOÇÕES HUMANAS COM
ABORDAGEM BIDIMENSIONAL A PARTIR DE
INFORMAÇÃO DE CONTEXTO E SINAIS DE
ELETROENCEFALOGRAFIA

TACIANA SAAD RACHED

CAMPINA GRANDE – PB
2015

Classificação de Emoções Humanas com Abordagem Bidimensional a partir de Informação de Contexto e Sinais de Eletroencefalografia

Taciana Saad Rached

Tese de Doutorado apresentada à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande - Campus de Campina Grande como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Processamento da Informação

Angelo Perkusich
Orientador

Campina Grande, Paraíba, Brasil
©Taciana Saad Rached, Outubro de 2015

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

R119c Rached, Taciana Saad.
Classificação de emoções humanas com abordagem bidimensional a partir de informação de contexto e sinais de eletroencefalografia / Taciana Saad Rached. – Campina Grande, 2015.
136 f. : il. color.

Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2015.

"Orientação: Prof. Dr. Angelo Perkusich".
Referências.

1. Eletroencefalografia. 2. Emoções. 3. Contexto. 4. Computação Afetiva. I. Perkusich, Angelo. II. Título.

CDU 621.3(043)

"CLASSIFICAÇÃO DE EMOÇÕES HUMANAS COM ABORDAGEM BIDIMENSIONAL A PARTIR DE INFORMAÇÃO DE CONTEXTO E SINAIS DE ELETROENCEFALOGRAFIA"

TACIANA SAAD RACHED

TESE APROVADA EM 02/10/2015



ANGELO PERKUSICH, D.Sc., UFCG
Orientador(a)

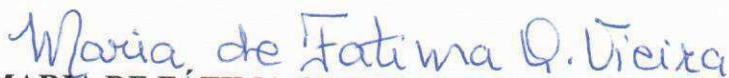
CARLOS JÚLIO TIERRA CRIOLLO, Dr., UFRJ
Examinador(a)



HYGGO OLIVEIRA DE ALMEIDA, D.Sc., UFCG
Examinador(a)



JAIDILSON JÔ DA SILVA, D.Sc., UFCG
Examinador(a)



MARIA DE FÁTIMA QUEIROZ VIEIRA, Ph.D., UFCG
Examinador(a)



MARCO AURÉLIO BENEDETTI RODRIGUES, Dr., UFPE
Examinador(a)

CAMPINA GRANDE - PB

Dedico esta Tese aos meus pais que são a base da minha vida e me ensinaram todos os princípios que me norteiam. Aos meus irmãos pelo exemplo, incentivo, amor e carinho.

Agradecimentos

Com a conclusão desta Tese, chega ao fim uma longa jornada de estudo e aprendizado, essenciais para minha formação. O fato de poder contar com as contribuições de diversas pessoas, algumas delas fundamentais para o término deste trabalho, tornou o desenvolvimento dessa pesquisa mais aprazível. Agradeço, primeiramente e principalmente, ao professor Angelo Perkusich por estar ao meu lado como meu orientador e amigo nos últimos dez anos da minha vida acadêmica, por ser fundamental para minha formação profissional e pessoal e por toda sua colaboração para esta Tese. Agradeço também à professora Maria de Fátima Vieira que me auxiliou nos últimos anos de doutorado. Agradeço à minha família que é o meu alicerce em todos os momentos da minha vida e à Leo de Lucena que esteve ao meu lado nesse último ano sempre me apoiando. Por fim, agradeço aos amigos que contribuíram de forma direta ou indireta para o término desta pesquisa.

Resumo

As emoções humanas são fundamentais para a interação entre indivíduos, assim como também com as máquinas. Diferente de uma interação humano-humano, onde um ser humano interpreta o comportamento emocional de outro, na interação humano-máquina, a última é incapaz de compreender os sentimentos de um indivíduo, o que dificulta a interação entre os mesmos. Nesse cenário, a computação afetiva é uma área de pesquisa recente, na qual o objetivo é reconhecer as emoções de um indivíduo durante sua interação com uma máquina, tornando-a mais simples, fácil e agradável. Existem diversas fontes de dados usadas no reconhecimento das emoções, como as expressões faciais, sinais de voz, linguagem corporal, sinais fisiológicos e sinais cerebrais. Os sinais cerebrais são a fonte de dados mais confiável no reconhecimento das emoções, pois diferentemente dos sinais de voz, expressões faciais e corporais, não são passíveis de falsas simulações e interpretação ambígua. Apesar de ser uma importante fonte de dados, a maioria dos sistemas de detecção afetiva baseados em sinais cerebrais discutidos na literatura são livres de contexto. Esse fato implica em um grave problema para o reconhecimento das emoções, uma vez que o contexto é fundamental na identificação das mesmas. Nesse trabalho é introduzido um método para a detecção das emoções humanas a partir da fusão de informações do contexto de um indivíduo com seus sinais cerebrais. O método é composto por duas componentes: os sinais cerebrais e o contexto. Para avaliar o método proposto foram desenvolvidos três estudos de caso. No primeiro estudo de caso o objetivo foi avaliar a componente do método referente aos sinais cerebrais. Os sinais de EEG de um banco de dados foram processados e classificados em emoções com os algoritmos definidos para esse fim. No segundo estudo de caso o objetivo foi a avaliação da componente do método relativa ao contexto. As variáveis relevantes para caracterização do contexto foram identificadas e suas influências foram definidas. O contexto foi classificado nas emoções dos participantes. Por fim, no terceiro estudo de caso, o método proposto nessa Tese foi avaliado considerando-se suas duas componentes. Os sinais cerebrais e o contexto foram classificados nas emoções dos participantes.

Abstract

Human emotions are fundamental to the way in which individuals interact with each other, as well as with machines. Unlike the human-human interaction, where a human understands another's emotional behavior, in the human-machine interaction, the last one is unable of understand the feelings of a person, which makes hard the interaction process among them. In this scenario, affective computing is a recent research area aiming at the recognition of human emotions during the interaction with a machine, making it simpler, easier and enjoyable. Several data sources are used for emotion recognition, such as facial expressions, voice signals, body language, psychological and brain signals. Brain signals are the most reliable data source to recognize emotions because they are not susceptible to false simulations and ambiguous interpretation, unlike, the facial and body expressions, as well as voice signals. Despite being an important source of data, most affective detection systems based on brain signals discussed in the literature are context free. This fact implies a serious problem for the recognition of emotions, since the context is crucial in identifying them. In this work we propose a method for the detection of human emotions based on the fusion of an individual context information with their brain signals. The method have two components: the brain signals and context. Furthermore, we developed three case studies to evaluate the proposed method. In the first case study, the objective was to evaluate the component of the method related to brain signals. The EEG signals from a database were processed and classified in emotions with algorithms defined for this purpose. In the second case study, the objective was to evaluate the context component of the method. The relevant variables that characterize the context were identified and their influences have been set. The context was classified in the emotions of the participants. Finally, the third case study, the proposed method in this thesis was evaluated considering its two components. The brain signals and the context were classified in the emotions of the participants.

Sumário

1	Introdução	1
1.1	Delimitação da Pesquisa	3
1.2	Descrição do Problema	5
1.3	Hipótese	6
1.4	Relevância	6
1.5	Objetivo Geral	6
1.6	Organização do Texto	7
2	Fundamentação Teórica	8
2.1	Emoções	8
2.2	Computação Afetiva	9
2.3	O Cérebro e as Emoções	10
2.4	Sinais Cerebrais	11
2.4.1	Aquisição dos Sinais Cerebrais	11
2.4.2	Processamento dos Sinais Cerebrais	14
2.5	Entropia e Energia	25
2.6	Contexto	26
2.6.1	Quem?	26
2.6.2	Onde?	27
2.6.3	Quando?	27
2.6.4	Por que?	27
2.6.5	O que?	27
2.6.6	Como?	28
2.7	Síntese	28
3	Método Proposto	30
3.1	Síntese	34
4	Estudo Experimental	36
4.1	Etapa 1 do Estudo de Caso	36

4.1.1	Banco de Dados	36
4.1.2	Pré-Processamento	39
4.1.3	Processamento dos Sinais	39
4.2	Etapa 2 do Estudo de Caso	52
4.2.1	Procedimento Experimental	53
4.2.2	Análise dos Dados	58
4.3	Etapa 3 do Etudo de Caso	59
4.3.1	Participantes	59
4.3.2	Sinais Cerebrais	59
4.3.3	Contexto	63
4.4	Síntese	63
5	Resultados Obtidos	64
5.1	Análise dos Resultados da Etapa 1 do Estudo de Caso	64
5.2	Análise dos Resultados da Etapa 2 do Estudo de Caso	70
5.3	Análise dos Resultados da Etapa 3 do Estudo de Caso	78
5.4	Síntese	89
6	Conclusões e Trabalhos Futuros	91
6.1	Considerações	91
6.1.1	Desenvolvimento da Tese	92
6.2	Trabalhos Futuros Sugeridos	94
	Referências Bibliográficas	96
	Appendices	
	Apêndice A	107
	Apêndice B	111
	Apêndice C	120
	Apêndice D	123

Lista de Tabelas

3.1	Especificações do Emotiv [11]	32
3.2	Saída do método baseado nos sinais cerebrais e contexto do indivíduo	35
4.1	Formato do arquivo de cada participante	40
4.2	Formato do novo arquivo de cada participante	41
4.3	Componentes associadas às características rítmicas do sinal de EEG	42
4.4	Alvos da rede neural e suas respectivas combinações binárias	45
4.5	Algoritmos de treinamento de uma rede neural direta	47
5.1	Valores de média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/excitado	65
5.2	Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/calmo	65
5.3	Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/excitado	66
5.4	Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/calmo	67
5.5	Resultado da classificação das emoções com base na entropia de teta	69
5.6	Resultado da classificação das emoções com base na entropia de alfa	70
5.7	Dados para análise da influência do contexto no desempenho do participante	71
5.8	Matriz de correlação de Pearson	72
5.9	Matriz de p -valores	72
5.10	Análise de Variância	76
5.11	Análise Exploratória (Resíduos)	76
5.12	Coefficientes do modelo de regressão linear	77
5.13	Desvio Padrão dos Resíduos	77
5.14	Resultado da classificação do Contexto em emoções	78
5.15	Dados para análise da influência do contexto no desempenho do participante	79
5.16	Resultado da classificação do contexto em emoções	80
5.17	Número de erros cometidos pelos participantes	80

Lista de Tabelas

5.18	Matriz de correlação de Pearson	81
5.19	Matriz de p -valores	82
5.20	Valores de média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/excitado	83
5.21	Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/calmo	84
5.22	Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/excitado	85
5.23	Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/calmo	86
5.24	Resultado da classificação das emoções com base na entropia de teta	86
5.25	Resultado da classificação das emoções com base na entropia de alfa	87
5.26	Reconhecimento das emoções com base nos sinais de EEG e contexto considerando a entropia de teta	89
5.27	Reconhecimento das emoções com base nos sinais de EEG e contexto considerando a entropia de alfa	89
A.1	Resultados da classificação dos dados dos sinais de EEG do banco de dados 1107	
B.1	Resultados do indivíduo 1 do banco de dados 2	111
B.2	Resultados do indivíduo 2 do banco de dados 2	111
B.3	Resultados do indivíduo 3 do banco de dados 2	112
B.4	Resultados do indivíduo 4 do banco de dados 2	112
B.5	Resultados do indivíduo 5 do banco de dados 2	112
B.6	Resultados do indivíduo 6 do banco de dados 2	112
B.7	Resultados do indivíduo 7 do banco de dados 2	113
B.8	Resultados do indivíduo 8 do banco de dados 2	113
B.9	Resultados do indivíduo 9 do banco de dados 2	113
B.10	Resultados do indivíduo 10 do banco de dados 2	113
B.11	Resultados do indivíduo 11 do banco de dados 2	114
B.12	Resultados do indivíduo 12 do banco de dados 2	114
B.13	Resultados do indivíduo 13 do banco de dados 2	114
B.14	Resultados do indivíduo 14 do banco de dados 2	114
B.15	Resultados do indivíduo 15 do banco de dados 2	115
B.16	Resultados do indivíduo 16 do banco de dados 2	115
B.17	Resultados do indivíduo 17 do banco de dados 2	115
B.18	Resultados do indivíduo 18 do banco de dados 2	115
B.19	Resultados do indivíduo 19 do banco de dados 2	116

Lista de Tabelas

B.20 Resultados do indivíduo 20 do banco de dados 2	116
B.21 Resultados do indivíduo 21 do banco de dados 2	116
B.22 Resultados do indivíduo 22 do banco de dados 2	116
B.23 Resultados do indivíduo 23 do banco de dados 2	117
B.24 Resultados do indivíduo 24 do banco de dados 2	117
B.25 Resultados do indivíduo 25 do banco de dados 2	117
B.26 Resultados do indivíduo 26 do banco de dados 2	117
B.27 Resultados do indivíduo 27 do banco de dados 2	118
B.28 Resultados do indivíduo 28 do banco de dados 2	118
B.29 Resultados do indivíduo 29 do banco de dados 2	118
B.30 Resultados do indivíduo 30 do banco de dados 2	118
B.31 Resultados do indivíduo 31 do banco de dados 2	119
B.32 Resultados do indivíduo 32 do banco de dados 2	119
C.1 Resultados do indivíduo 1 banco de dados Emotiv	120
C.2 Resultados do indivíduo 2 banco de dados Emotiv	120
C.3 Resultados do indivíduo 3 banco de dados Emotiv	121
C.4 Resultados do indivíduo 4 banco de dados Emotiv	121
C.5 Resultados do indivíduo 5 banco de dados Emotiv	121
C.6 Resultados do indivíduo 6 banco de dados Emotiv	121
C.7 Resultados do indivíduo 7 banco de dados Emotiv	122
C.8 Resultados do indivíduo 8 banco de dados Emotiv	122
C.9 Resultados do indivíduo 9 - Exp. 1 banco de dados Emotiv	122
C.10 Resultados do indivíduo 9- Exp. 2 banco de dados Emotiv	122

Lista de Figuras

2.1	Gráfico da abordagem bidimensional das emoções	9
2.2	Representação do método invasivo para aquisição dos sinais cerebrais	12
2.3	Representação das estruturas anatômicas do cérebro	14
2.4	Ilustração do posicionamento de eletrodos para o Sistema Internacional 10-10 [8]	15
2.5	(a) Exemplo de <i>wavelet</i> , (b) Exemplo de senóide	16
2.6	Sinal original e suas <i>wavelets</i> constituintes [76]	17
2.7	Ilustração para o processo de filtragem do sinal em aproximações e detalhes	19
2.8	Ilustração para o processo de decomposição sucessiva do sinal	19
2.9	Representação de nove <i>wavelets Daubechies</i> [2]	20
2.10	Exemplo de uma <i>wavelet Daubechies</i> 4	20
2.11	Modelo simplificado de um neurônio artificial	23
2.12	Exemplos de funções de ativação de um neurônio artificial	24
3.1	Diagrama do método para o reconhecimento das emoções	30
3.2	Diagrama de blocos para o módulo sinais cerebrais	31
3.3	Imagem do equipamento (<i>Headset</i>) para coleta de dados	31
4.1	Protocolo experimental	37
4.2	Montagem do experimento	38
4.3	Amostra de sinal adquirida a partir do canal AF3	40
4.4	Estrutura de decomposição do sinal original	41
4.5	Gráficos do sinal original, dos detalhes D_1 , D_2 , D_3 e D_4 e da aproximação A_4	42
4.6	Gráficos das entropias de teta	43
4.7	Gráficos da energias de teta	43
4.8	Arquitetura da rede neural usada neste trabalho	46
4.9	Gráfico para a função de transferência tansig	46
4.10	Diagrama de blocos para o processamento das entradas da rede	48
4.11	Diagrama de blocos para o processamento das saídas da rede	48

Lista de Figuras

4.12	Ilustração da tela de treinamento da rede neural	50
4.13	Matrizes com porcentagens de erros e acertos na classificação dos sinais de EEG em emoções	51
4.14	Gráficos das relações entre saídas e alvos da rede neural artificial	52
4.15	Tela do SimuLIHM: simulador de uma subestação elétrica [33]	53
4.16	Ilustração da configuração da sala de teste	54
4.17	Ilustração da configuração da sala de monitoramento	55
4.18	Ilustração do <i>software</i> de configuração do <i>Emotiv, Control Panel</i> [10]	56
4.19	Imagem do ambiente de realização de teste	57
4.20	Amostra de sinal adquirida a partir do canal AF3	60
4.21	Gráficos do sinal original, dos detalhes D_1 , D_2 , D_3 e D_4 e da aproximação A_4	60
4.22	Gráficos das entropias de teta	61
4.23	Gráficos da energias de teta	61
4.24	Matrizes com porcentagens de erros e acertos na classificação dos sinais de EEG em emoções	62
5.1	Gráficos de interações	73
5.2	Gráficos de efeitos	74
5.3	Teste de normalidade	75
5.4	Gráficos de efeitos	83
5.5	Resultados obtidos a partir da entropia de teta	87
5.6	Resultados obtidos a partir da entropia de teta	88

Capítulo 1

Introdução

As emoções são fundamentais no modo pelo qual as pessoas interagem umas com as outras, assim como também com as máquinas [99]. Um ser humano consegue interpretar o comportamento emocional de outro ser humano e agir da melhor maneira para beneficiar a comunicação entre os mesmos em uma dada situação. Isso acontece, pois as emoções podem ser identificadas por um indivíduo a partir de palavras, entonação da voz, expressões faciais e linguagem corporal [26]. Em contraste, as máquinas são incapazes de compreender e de expressar os sentimentos de um indivíduo, o que dificulta a interação entre os mesmos [112].

Nesse contexto, a computação afetiva é uma área de pesquisa recente, na qual o objetivo é reconhecer as emoções de um indivíduo durante sua interação com uma máquina, tornando-a mais simples, fácil e agradável [109]. Por exemplo, o ato de aprender pode se tornar mais simples com a identificação das emoções humanas por uma máquina [31]. Se uma máquina reconhece o estado emocional de um indivíduo durante sua aprendizagem, ela pode adaptar sua interface de forma apropriada para melhorar o rendimento do mesmo.

O reconhecimento das emoções pode ser aplicado à diversas áreas, como no cuidado de idosos em suas residências, em robótica, medicina, aviação e sistemas de automação, entre outras. Em [52], foi apresentado um sistema de monitoramento de sinais fisiológicos (batimentos cardíacos, temperatura do corpo e condutância da pele) com o objetivo de identificar problemas de saúde físicos ou mentais em idosos remotamente. O monitoramento da saúde mental foi baseado nas emoções do idoso. Em robótica, o reconhecimento das emoções é aplicado ao desenvolvimento de robôs que identificam as emoções de um indivíduo e se expressam emocionalmente [14]. Sistemas de reconhecimento de emoções humanas também podem ser aplicados em ambientes de automação para identificação de estresse ou desatenção durante o desempenho de atividades críticas nas quais erros podem ter como resultado graves problemas [88].

As emoções humanas podem ser identificadas a partir de sistemas baseados nas expressões faciais, sinais de voz, linguagem corporal, sinais fisiológicos e sinais cerebrais [26]. Meguid et. al. em [12] propuseram um arcabouço para classificação de expressões faciais espontâneas, capturadas por câmeras, em sete diferentes emoções: raiva, desgosto, medo, felicidade, neutra, tristeza e surpresa. Os autores usaram um detector de imagens comercial para identificar e recortar cada face de cada quadro do vídeo, assim como também para localizar o centro da face. Os autores aplicaram o algoritmo máquina de suporte vetorial para classificar as expressões faciais em emoções e obtiveram diferentes acurácias para cada uma das emoções, sendo a mais alta na identificação da raiva (96,04 %) e a mais baixa no reconhecimento do medo (39,60 %).

Wang et. al. em [113], propuseram um modelo para um novo parâmetro de Fourier baseado no conteúdo percentual da qualidade da voz e nas diferenças de primeira e segunda ordem para o reconhecimento das emoções a partir da voz e independente do orador. As características do parâmetro de Fourier foram usadas para classificar as informações de três diferentes bancos de dados em dois idiomas (chinês e alemão) para identificar sete emoções: felicidade, tristeza, raiva, neutra, tédio, ansiedade e desgosto. Kleinsmith et. al. em [58] realizaram uma revisão da literatura sobre o reconhecimento das emoções a partir da percepção da expressão corporal, com base em toda a postura corporal estática e em movimento.

Os principais problemas em sistemas de reconhecimento de emoções baseados em expressões faciais, na linguagem falada ou na linguagem corporal é que essas fontes de informações são passíveis de interpretação ambígua e de falsas simulações, razões pelas quais a acurácia do sistema pode ser comprometida. Por exemplo, um ator é capaz de simular diversas emoções diferentes do seu estado emocional verdadeiro, como tristeza e alegria. Além disso, tais sistemas não são universais e dependem da cultura, gênero e idade do indivíduo [82]. Em contraste, mesmo que uma pessoa não expresse suas emoções através da voz, expressões faciais ou gestos, mudanças no estado fisiológico são inevitáveis e detectáveis durante o sentimento de uma determinada emoção [71]. Isto acontece porque os nervos simpáticos do sistema nervoso autônomo são ativados quando uma pessoa é estimulada positivamente ou negativamente.

Outra vantagem no uso dos sinais fisiológicos de um indivíduo no reconhecimento das emoções é que esses sinais não podem ser manipulados para simular um falso estado emocional, o que torna os sistemas baseados nessas informações mais confiáveis [70]. Na literatura estão disponíveis sistemas que focam na detecção das emoções através de técnicas de aprendizado para identificar padrões na atividade fisiológica que correspondem à expressão de diferentes emoções [29], [38].

Wen et. al. em [115] investigaram o uso dos batimentos cardíacos, resposta galvânica

da pele e a saturação de oxigênio no sangue para detecção afetiva. Os autores apresentaram filmes aos 101 participantes, com o objetivo de estimular as emoções diversão, raiva, tristeza e medo, durante a aquisição dos sinais fisiológicos. A partir da correlação entre os batimentos cardíacos, a resposta galvânica da pele, a primeira derivada da resposta galvânica da pele e a saturação de oxigênio no sangue, os autores obtiveram uma taxa de acertos de 74 % no reconhecimento das emoções.

O principal problema dos sistemas de reconhecimento de emoções baseados em sinais fisiológicos é a baixa resolução temporal (entre 10 e 40 *ms*), o que impede seu uso em tempo real. Exceção neste caso são os sinais elétricos cerebrais que são adquiridos pelo eletroencefalograma (EEG) e apresentam uma boa resolução temporal (aproximadamente 1 *ms*) o que permite seu uso em tempo real.

1.1 Delimitação da Pesquisa

Recentemente, sistemas baseados em sinais cerebrais vêm sendo bastante aplicados à computação afetiva [89], uma vez que existem diversas razões para o uso desse tipo de informação ser relevante no reconhecimento das emoções, como por exemplo: não suscetibilidade dos sinais cerebrais à falsas simulações e interpretação ambígua; independência de raça, idade e gênero; boa resolução temporal; e disponibilidade de equipamentos portáteis e fáceis de usar, entre outras.

Duan et. al. [40] propuseram o reconhecimento das emoções a partir de uma nova característica dos sinais de EEG, chamada entropia diferencial. Participaram do experimento seis indivíduos, três homens e três mulheres. Os participantes foram estimulados positivamente e negativamente a partir de doze filmes de quatro minutos cada, selecionados com esse propósito. Os sinais de EEG foram adquiridos durante o experimento a partir de 62 canais. Além da entropia diferencial, outras três características (espectro de energia, assimetria racional e assimetria diferencial) foram selecionadas com o objetivo de verificar com qual delas têm-se os melhores resultados. A maior taxa de acertos (84,22 %) foi obtida na classificação da entropia diferencial em emoções positivas e negativas e a pior taxa (76,56 %) foi obtida com uso do parâmetro espectro de energia.

Em [39], Dongwei et. al. apresentaram o desenvolvimento de um detector de emoções baseado numa interface cérebro-computador. O sistema implementado pelos autores foi usado no reconhecimento das emoções agradável, desagradável e neutra. Foram usadas 90 figuras do sistema internacional de figuras afetivas [65], sendo 30 na indução de cada uma das três emoções. Os autores usaram um equipamento de EEG de 32 canais para aquisição dos sinais cerebrais, sendo que 28 canais foram distribuídos na superfície do couro cabeludo do participante do experimento para medição dos sinais elétricos cerebrais,

um canal foi usado para medição do eletrocardiograma (ECG) , um segundo canal foi usado para adquirir o eletrooculograma (EOG) e os dois canais restantes foram usados como referência. Apenas um indivíduo participou do experimento realizado para validar o sistema.

Em [105], os autores apresentaram duas aplicações baseadas no reconhecimento das emoções, sendo uma delas um jogo para ajudar no aprendizado e a outra, um avatar emocional. Músicas ou sons são tocados durante a execução das aplicações para estimular diferentes emoções. Os sinais de EEG são coletados durante a interação do usuário com as aplicações e classificados em emoções. Vijayan et. al. em [111] propuseram um novo algoritmo para o reconhecimento das emoções a partir dos sinais de EEG. O banco de dados DEAP [1] foi usado para avaliação do algoritmo. Os sinais de EEG foram decompostos nas características delta, teta, alfa, beta e gama com o algoritmo *wavelets*. Em seguida, a entropia de *Shannon* foi calculada com base em cada uma das características dos sinais de EEG. Os modelos de correlação cruzada e auto-regressivo foram aplicados à entropia. Por último, com o algoritmo máquina de suporte vetorial, os sinais foram classificados nas emoções excitado, feliz, triste e ódio com uma acurácia de 94,097 %.

Paul et. al. em [83] apresentaram uma nova abordagem no reconhecimento das emoções a partir dos sinais de EEG. No experimento, sinais de áudio foram usados para induzir emoções positivas e negativas nos oito participantes. Os sinais de EEG foram adquiridos a partir de sete canais, sendo as características de todas as bandas de frequência extraídas com o algoritmo análise de flutuação retificada multifractal. A classificação dos sinais em emoções foi realizada a partir de diversos algoritmos, como a máquina de suporte vetorial, análise discriminante linear, análise discriminante quadrática e k-vizinhos próximos. A maior acurácia foi obtida com a máquina de suporte vetorial (84,5 %) e a menor com os k-vizinhos próximos (70,5 %).

Bhardwaj et. al. em [21] propuseram o reconhecimento de sete emoções a partir dos sinais de EEG. As emoções foram estimuladas a partir de figuras do sistema internacional de figuras afetivas [65]. Os sinais de EEG foram adquiridos a partir de quatro canais e decompostos nas bandas de frequência delta, teta, alfa, beta e gama. A densidade espectral de potência e a energia das características teta, alfa e beta foram obtidas, sendo usadas como entradas dos algoritmos máquina de suporte vetorial e análise discriminante linear para classificação dos sinais nas emoções feliz, triste, desgosto, neutro, surpresa e raiva. Como resultado, os autores obtiveram uma acurácia de 74,13 % com a máquina de suporte vetorial e 66,50 % com a análise discriminante linear.

As emoções humanas são influenciadas por diversos estímulos internos e externos, como por exemplo, o contexto, as experiências passadas e recentes, a personalidade, o afeto e a interpretação da rede cognitiva dessas influências [68]. De acordo com a revisão

bibliográfica realizada para o desenvolvimento deste trabalho, nenhum desses fatores são considerados nos sistemas de reconhecimento de emoções disponíveis na literatura, pois os mesmos foram desenvolvidos apenas para detecção de emoções estimuladas a partir de imagens, sons, músicas ou vídeos.

1.2 Descrição do Problema

Os principais problemas enfrentados pela humanidade envolvem as emoções e consequentemente a humanidade pode progredir sem considerar as emoções tão rápido quando alguém que corre com uma perna só [94]. As emoções influenciam na tomada de decisão, cognição, percepção, criatividade, memória, atenção, raciocínio e no aprendizado nas atividades desempenhadas no dia-a-dia, sendo fundamentais na qualidade do trabalho desenvolvido por um indivíduo [102].

Nesse cenário, a computação afetiva é uma área de pesquisa essencial na atualidade, uma vez que a interação entre o homem e uma máquina se tornou tão habitual quanto a interação entre pessoas, em alguns casos até mais popular. Dessa forma, o desenvolvimento de sistemas de detecção afetiva é imprescindível para tornar a relação homem-máquina próxima da comunicação entre indivíduos e vem sendo bastante discutido na literatura na última década, devido à sua importância para as mais diversas áreas, como entretenimento, aprendizado, medicina, robótica, aviação e automação, entre outras [52], [14], [88].

Apesar disso, com base na discussão apresentada na Seção 1.1, assim como na maioria disponível na literatura, as abordagens usadas no reconhecimento das emoções a partir dos sinais cerebrais não consideram o contexto no qual o indivíduo está inserido, ou seja, os sistemas de detecção são treinados com conjuntos de dados nos quais as expressões afetivas foram coletadas em ambientes livres de contexto, sendo este definido como qualquer informação que seja relevante para caracterizar a situação do indivíduo. Entretanto, a natureza das emoções não pode ser considerada como sendo livre de contexto, ao contrário disso, ela é altamente dependente da situação e o contexto é fundamental na distinção entre diferentes emoções [94]. Além disso, as emoções podem possuir diferentes significados em diferentes contextos [32].

Considerando-se que a principal lacuna observada na computação afetiva é a ausência do contexto em sistemas usados no reconhecimento das emoções baseados nos sinais cerebrais, o problema de interesse neste trabalho é: *Como inserir informações que caracterizam o contexto do indivíduo para o reconhecimento das emoções durante o desempenho de atividades do dia-a-dia de um indivíduo, de modo a dar respaldo aos estados emocionais identificados a partir dos sinais cerebrais?*

1.3 Hipótese

Considerando o problema abordado neste trabalho, é necessária a obtenção de informações relacionadas as tarefas do dia-a-dia, a situação e a personalidade de um indivíduo para caracterização do contexto. Portanto, é considerada a hipótese de que: *“É possível identificar as emoções de um indivíduo durante a realização de atividades do cotidiano com a inserção do contexto aos sistemas de detecção afetiva baseados nos sinais cerebrais.”*

1.4 Relevância

O contexto de um indivíduo é essencial na distinção de suas emoções, uma vez que diferentes contextos podem estimular diferentes emoções em um mesmo indivíduo. Considerando-se a importância do contexto em sistemas de detecção afetiva, a principal contribuição deste trabalho é a inserção do contexto no reconhecimento das emoções baseados em sinais de EEG para que com base nessas duas fontes de informação obtenha-se um detector de emoções mais confiável.

Neste trabalho define-se um método para o reconhecimento das emoções a partir do contexto do indivíduo e sinais de EEG. Como os dados de contexto e sinais de EEG possuem diferentes processos de classificação em emoções, a etapa de fusão dos dados ocorre na fase de decisão do processo. Sendo assim, o resultado da classificação do contexto em emoções oferece respaldo a classificação dos sinais cerebrais em emoções.

1.5 Objetivo Geral

No presente trabalho o objetivo é introduzir um método para auxiliar no reconhecimento das emoções considerando-se dois tipos de informações, os sinais cerebrais e o contexto de um indivíduo, durante o desempenho de atividades do cotidiano. Para isso, foram definidos alguns objetivos específicos:

- Definição da estrutura de relação das diferentes fontes de informações usadas no método;
- Abordagem a ser usada na componente do método baseada nos sinais cerebrais: canal de aquisição dos sinais e algoritmos de seleção e classificação;
- Abordagem a ser aplicada à componente do método referente ao contexto, considerando a importância de todos os fatores que são relevantes na caracterização do contexto que o indivíduo está inserido, assim como a influência que cada um desses fatores tem sobre o contexto;

- Definição da etapa de decisão do método proposto considerando os sinais cerebrais e o contexto;
- Avaliação da componente referente aos sinais cerebrais;
- Avaliação da componente referente ao contexto;
- Avaliação do método proposto.

1.6 Organização do Texto

Neste Capítulo foi apresentada uma introdução deste trabalho, sendo discutidos os principais problemas encontrados na computação afetiva, assim como o problema abordado neste trabalho e sua relevância. Também foram apresentados os objetivos deste trabalho de Tese.

No Capítulo 2 é apresentada a base conceitual para o desenvolvimento desse trabalho. Primeiramente, é discutido o que são emoções, os diferentes tipos de abordagens e influência no comportamento do ser humano. Em seguida, é apresentada a área de pesquisa computação afetiva e sua importância na melhora da comunicação entre um indivíduo e uma máquina. O terceiro tópico discutido é a relação entre o cérebro e as emoções. Em seguida, apresenta-se a interface cérebro-computador e as etapas de aquisição dos sinais cerebrais e processamento desses sinais. Uma discussão sobre entropia e energia é realizada. Por último, é discutida a definição de contexto.

No Capítulo 3 é apresentado o método proposto neste trabalho. Os algoritmos utilizados na seleção e classificação das características dos sinais cerebrais em emoções são discutidos. Além disso, apresenta-se a abordagem utilizada neste trabalho para caracterização do contexto e classificação do mesmo em emoções.

No Capítulo 4 são apresentados três estudos de caso para avaliar o método para reconhecimento das emoções humanas proposto neste trabalho. No primeiro, avalia-se a componente do método referente aos sinais cerebrais, no segundo a componente relativa ao contexto e no terceiro estudo de caso o método proposto, considerando os sinais cerebrais e o contexto.

No Capítulo 5 são discutidos os resultados obtidos nos três estudos de caso apresentados neste trabalho. Por fim, no Capítulo 6 são apresentadas as conclusões desta Tese e uma discussão sobre os trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Neste Capítulo são apresentados os conceitos e tecnologias usados no desenvolvimento deste trabalho. Primeiramente, é realizada uma discussão sobre a definição das emoções humanas. Em seguida, a área de pesquisa computação afetiva é abordada. Depois, a relação entre as emoções e o cérebro humano e a interface cérebro-computador são apresentadas. É realizada uma discussão sobre entropia e energia. Por fim, é realizada uma discussão sobre o contexto do usuário.

2.1 Emoções

A qualidade do trabalho realizado no dia-a-dia, seja ele uma simples atividade do cotidiano como colocar uma mesa de café-da-manhã, ou uma atividade de grande responsabilidade na empresa onde se trabalha, está diretamente relacionada com as emoções de um indivíduo. As emoções afetam a capacidade cognitiva, a atenção, a memória e o comportamento humano, entre outros fatores, sendo fundamentais na qualidade do trabalho que um indivíduo desempenha. Mas afinal, o que são as emoções?

Apesar de ser um área bastante discutida devido a importância que as emoções têm na vida do ser humano, ainda não existe um consenso na literatura para a definição das emoções [99]. Os cientistas definem as emoções como um sistema que envolve variáveis subjetivas, fisiológicas, expressivas e comportamentais. Já a psicologia defende que o indivíduo nasce com algumas emoções básicas, como alegria, tristeza, raiva e medo, e que estas dão origem a outros sentimentos [108]. Em [34], o autor afirma que uma emoção propriamente dita é uma série de respostas químicas e neurais que formam um padrão diferente.

As emoções humanas são classificadas de acordo com duas abordagens: a discreta e a bidimensional [99]. Na abordagem discreta, as emoções são classificadas pontualmente em estados emocionais como feliz, triste, aborrecido, entre outros. Na abordagem bidimensio-

nal, as emoções são classificadas em um gráfico bidimensional com relação a sua excitação (excitado ou calmo) e valência (positivo ou negativo), como apresentado na Figura 2.1.



Figura 2.1: Gráfico da abordagem bidimensional das emoções

A abordagem utilizada no reconhecimento das emoções neste trabalho é a bidimensional, devido ao banco de dados usado ser baseado nessa abordagem.

2.2 Computação Afetiva

Quando dois indivíduos interagem, além da comunicação verbal, existe a não-verbal. A comunicação não-verbal acontece porque os seres humanos têm a capacidade de interpretar as expressões faciais e corporais de outro indivíduo, além de compreender sua entonação da voz. Isto permite que as pessoas entendam o estado emocional de um outro indivíduo e se adaptem a uma determinada situação, tornando a comunicação humano-humano adequada [112].

Nesse contexto, a computação afetiva é a área de pesquisa onde se busca proporcionar uma relação emocional entre uma máquina e um indivíduo [109]. O objetivo nesse relacionamento é tornar a interação humano-máquina o mais semelhante possível à interação humano-humano, de modo a melhorar o desempenho de um indivíduo na realização de tarefas do dia-a-dia.

Imagine que uma pessoa trabalha numa empresa realizando atividades perigosas que podem colocar em risco a vida de pessoas e gerar grandes prejuízos financeiros caso ocorra algum erro humano. A função desse indivíduo exige muita atenção, experiência e responsabilidade. Além disso, as atividades que ele desempenha são rotineiras e monótonas, o que pode ser cansativo dependendo do seu estado mental.

O reconhecimento das emoções por uma máquina, no caso descrito anteriormente, pode evitar erros que ocasionem acidentes graves [80]. Numa interação humano-humano, um

indivíduo é capaz de identificar o estado emocional e sugerir que ele não deve desempenhar determinadas atividades nesse dia para evitar maiores problemas [112]. Isso pode ser feito também na interação humano-máquina, desde que a mesma possa detectar as emoções humanas.

Como discutido no Capítulo 1, o reconhecimento das emoções humanas por uma máquina pode ser baseado em diversas fontes de informações, como os sinais e entonação da voz, expressões faciais e corporais e os sinais fisiológicos. Os sinais fisiológicos podem ser os batimentos cardíacos, dilatação da pupila, condutância da pele e os sinais cerebrais, entre outros [26].

Neste trabalho, é proposto um método para o reconhecimento das emoções humanas a partir dos sinais cerebrais e do contexto no qual um indivíduo está inserido, como é apresentado no Capítulo 3. Na Seção 2.3 é apresentada a relação entre o cérebro e a geração das emoções.

2.3 O Cérebro e as Emoções

No dia-a-dia de um indivíduo todos os acontecimentos levam ao sentimento de alguma emoção, por exemplo, alegria, tristeza e raiva. Sabe-se hoje que as áreas relacionadas com os processos emocionais ocupam algumas áreas do encéfalo, destacando-se entre elas o hipotálamo, o córtex pré-frontal e o sistema límbico [73]. Apesar disso, apenas a região pré-frontal é ativada durante o sentimento de qualquer emoção, seja ela positiva ou negativa [85].

A região pré-frontal que é bem conectada com o tronco cerebral e formações límbicas, entre elas a amígdala e o hipotálamo, desempenha um papel importante no comportamento emocional [46]. Essa região tem como funções a escolha das opções e estratégias comportamentais mais adequadas à situação física e social do indivíduo; manutenção da atenção; e o controle do comportamento emocional [47]. Além disso, a região pré-frontal é mais acessível na aplicação dos eletrodos. Nessa área, o eletrodo está em contato direto com a pele do usuário, podendo ser usado um eletrodo seco [69]. Devido a ausência de cabelos na região pré-frontal, o sinal adquirido possui menos distorções se comparado aos obtidos a partir das outras áreas cerebrais. Portanto, neste trabalho, os sinais adquiridos a partir dessa região com o uso do canal AF3 foram utilizados na identificação do estado emocional do indivíduo.

Apesar de neste trabalho não ter sido desenvolvido um sistema em tempo real, o método proposto visa o reconhecimento das emoções neste tipo de aplicação, sendo necessário um equipamento para aquisição dos dados minimamente intrusivo e com comunicação sem fio para fornecer conforto ao usuário; e um dispositivo portátil para o processamento dos

dados, devido à aplicação poder ser usada em qualquer lugar. Por essa razão foi utilizado apenas um canal para aquisição dos dados.

Na Seção 2.4 é apresentada uma discussão sobre a aquisição e o processamento dos sinais cerebrais, sendo discutidos os diversos métodos de aquisição e processamento dos sinais cerebrais.

2.4 Sinais Cerebrais

Inicialmente, os sinais cerebrais foram usados para auxiliar pessoas com sérios problemas neuromusculares a interagirem com dispositivos disponíveis no ambiente [90], [81], [116]. Porém, com a popularização da eletrônica de consumo para aquisição dos sinais cerebrais, seu uso foi estendido à pessoas saudáveis tanto em aplicações médicas, como no entretenimento [84], [91], [92]. Recentemente, os sinais cerebrais vem sendo bastante empregados na computação afetiva [53], como discutido na Seção 1.1, e são vistos como uma fonte de informação promissora nesta área.

Para o uso dos sinais cerebrais na detecção afetiva, são necessárias três etapas até a obtenção das emoções: a aquisição dos sinais, o pré-processamento e o processamento.

2.4.1 Aquisição dos Sinais Cerebrais

A aquisição dos sinais cerebrais de um indivíduo é a primeira etapa para identificação das emoções, sendo que a leitura desses sinais pode ser realizada a partir de diversas técnicas que são divididas em dois grupos: métodos invasivos e não-invasivos [81].

Os métodos invasivos consistem na aplicação direta de eletrodos ao cérebro, ou seja, é necessária uma intervenção cirúrgica para o seu uso. Esses métodos são os mais precisos, pois a aquisição do sinal é realizada diretamente do cérebro humano, evitando distorções do sinal resultantes de obstáculos, como por exemplo, o crânio de um indivíduo. Porém, o uso de técnicas invasivas por pessoas saudáveis não é indicado devido à necessidade de procedimento cirúrgico [64]. Na Figura 2.2 é apresentada uma ilustração de um exemplo de método invasivo.

Nos métodos não-invasivos, a aquisição do sinal cerebral é realizada sem intervenção cirúrgica. Esses métodos podem ser usados na realização de testes em humanos sem comprometer a saúde destes [101].

Existem diversas técnicas não-invasivas para o monitoramento dos sinais cerebrais. Esses métodos incluem a Magnetoencefalografia (MEG) [97], a Ressonância Magnética [67], Espectroscopia de Infravermelho Próximo [55] e a Eletroencefalografia (EEG), entre outros [81]. EEG é a técnica mais usada, em relação às citadas anteriormente, devido à sua facilidade de uso, baixo custo, alta resolução temporal (aproximadamente 1 *ms*) e




Figura 2.2: Representação do método invasivo para aquisição dos sinais cerebrais

portabilidade, ou seja, o EEG pode ser usado em qualquer ambiente [61], [98]. Os sinais de EEG foram usados como fonte de dados para o reconhecimento das emoções neste trabalho.

Sinais de EEG

Quando um neurônio é excitado, ocorre uma diferença de potencial entre seu interior e exterior. Um sinal de entrada libera íons de sódio que são transportados através da célula, causando um aumento na tensão dentro da célula (quando comparada com o ambiente externo à célula) [41]. Quando essa tensão aumenta até um determinado limite, um potencial de ação é gerado pelo rápido fluxo de entrada de sódio e baixo fluxo de saída de potássio. Esse potencial de ação é uma onda de descarga elétrica que viaja através do dendrito para os neurônios vizinhos. Durante esse evento, o qual tem duração de aproximadamente dois milissegundos, a tensão varia de -60 mV até $+20\text{ mV}$ [22].

A atividade elétrica medida pelos eletrodos aplicados à superfície do couro cabeludo de um indivíduo é representada pelos potenciais resultantes da combinação da atividade de várias células neurais [18]. A atividade dos neurônios localizados no córtex cerebral, ou seja, mais próximos do crânio e, conseqüentemente dos eletrodos, é observada mais claramente no EEG. A atividade elétrica gerada em estruturas cerebrais mais profundas não pode ser observada diretamente com o uso do EEG [22].

A atividade cortical medida pelo EEG é atenuada pelos tecidos e ossos que existem entre os eletrodos aplicados à cabeça de um indivíduo e seu córtex cerebral. Por essa razão, a amplitude dos potenciais de EEG é da ordem de μV , mesmo representando a atividade de vários neurônios com tensão variando em mV [41].

Apesar dos sinais de EEG adquiridos serem medidas combinacionais, eles fornecem importantes informações relativas à atividade elétrica cortical, como o estado de alerta de

uma pessoa, a imaginação motora, padrões no sinal que ajudam na detecção de doenças neurais e o estado emocional de um indivíduo (foco deste trabalho), entre outras. A frequência e a amplitude são as características obtidas do EEG adquirido. As frequências variam de 1 a 100 Hz (divididas nas bandas delta, teta, alfa, beta e gama) e possuem amplitudes entre 10 e 100 μV [81].

Os sinais elétricos cerebrais são medidos por pequenos eletrodos aplicados à superfície do couro cabeludo de um indivíduo. O número de eletrodos pode variar de 1 à 256 [18]. Porém, com o uso de muitos canais, torna-se inviável o uso do EEG em atividades do dia-a-dia de um indivíduo devido à três fatores principais.

O primeiro está relacionado com a complexidade na aplicação do equipamento de EEG que exige auxílio profissional para tal função. Os dispositivos com grandes quantidades de canais geralmente são usados em aplicações clínicas ou pesquisa. Para que esses equipamentos funcionem adequadamente, é preciso medir a resistência dos eletrodos para averiguar a continuidade elétrica entre as extremidades dos mesmos antes de serem aplicados a cabeça do usuário para garantir o funcionamento adequado dos mesmos. Além disso, é necessário aplicar uma pasta condutora aos eletrodos para melhorar o contato com o couro cabeludo do usuário e medir a impedância após a aplicação de cada eletrodo [106]. O processo de aplicação dos eletrodos tem duração de 30 a 60 minutos, dependendo da quantidade dos mesmos e da experiência do indivíduo a manuseá-los.

O segundo fator diz respeito a restrição da mobilidade do usuário do equipamento de EEG. Os dispositivos de EEG com grandes quantidades de canais possuem uma grande quantidade de fios que conectam os eletrodos ao equipamento receptor dos sinais o que limita os movimentos do seu usuário.

O terceiro fator está relacionado à necessidade de armazenar uma grande quantidade de informações, que muitas vezes são redundantes e exigem muito tempo para serem processadas.

Para tornar viável o uso do EEG em tarefas do cotidiano, diversos esforços têm sido dispendidos no desenvolvimento de equipamentos de EEG portáteis, que possuem um número reduzido de canais, fáceis de ser aplicados ao couro cabeludo do usuário e em alguns casos podem também realizar parte ou todo o pré-processamento do sinal. Exemplos de equipamentos de EEG portáteis incluem o Emotiv [27] e o MindSet [6]. Embora esses equipamentos não possuam a mesma precisão de equipamentos de EEG usados em hospitais, de acordo com [42], eles podem ser usados em qualquer aplicação, exceto em reabilitação e controle de próteses.

Posicionamento dos Eletrodos e Nomenclatura

Os sinais de EEG podem ser medidos a partir de diferentes áreas do cérebro. A seleção dos canais de monitoramento dos sinais de EEG depende das características do sinal que serão usadas pelo sistema. O cérebro é composto por quatro regiões: o lóbulo Frontal, o lóbulo Parietal, o lóbulo Occipital e o lóbulo Temporal, como mostrado na Figura 2.3. Cada lóbulo desempenha diferentes funções. O lóbulo frontal está relacionado com a elaboração do pensamento, planejamento, programação das necessidades individuais e emoção. O lóbulo parietal está relacionado as sensações de dor, tato, gustação, temperatura e pressão. O lóbulo temporal está relacionado com o sentido da audição, possibilitando o reconhecimento de tons específicos e intensidade do som. O lóbulo occipital é responsável pelo processamento da informação visual [73].




Figura 2.3: Representação das estruturas anatômicas do cérebro

Os canais usados para aquisição dos sinais de EEG são localizados sobre o couro cabeludo do indivíduo de acordo com o sistema Internacional 10-10. Esse sistema é usado para padronizar a localização dos eletrodos com o objetivo de facilitar a realização de comparações entre diferentes estudos. No sistema Internacional 10-10, como ilustrado na Figura 2.4, os nomes dos eletrodos são compostos por algumas letras e um número. As letras se referem às estruturas anatômicas do cérebro (lóbulos Frontal, Parietal, Occipital e Temporal e o sulco central). Os números denotam a linha sagital (anterior ou posterior). Os números ímpares correspondem ao hemisfério esquerdo, enquanto os números pares correspondem ao direito. A letra “z” minúscula é usada em nomes de eletrodos localizados na linha sagital central [62].

2.4.2 Processamento dos Sinais Cerebrais

O processamento dos sinais de EEG é dividido em duas partes: a extração das características do sinal e a classificação dessas características. A escolha do método a ser usado na primeira etapa depende de em qual domínio, tempo ou frequência, as características




Figura 2.4: Ilustração do posicionamento de eletrodos para o Sistema Internacional 10-10 [8]

do sinal se encontram. Já na segunda etapa, a escolha do método independe do domínio do sinal.

Seleção das Características dos Sinais Cerebrais

A seleção das características dos sinais cerebrais tem como objetivo a identificação das características do sinal que são de interesse para uma determinada aplicação. As características do sinal podem ser selecionadas a partir de diversas técnicas, sendo algumas delas discutidas a seguir.

A transformada de *Fourier* [59] é usada para seleção das características do sinal de EEG em alguns trabalhos, porém essa técnica não é adequada para essa funcionalidade, pois os sinais de EEG são não-estacionários e contêm vários eventos transientes. As funções de base infinita usadas na transformada de *Fourier* são adequadas para extrair informações de frequência de sinais periódicos e não transientes. Os coeficientes de *Fourier* de um sinal são determinados a partir de todo o sinal. Isso implica que o espectro de frequência de um sinal como um resultado da transformada de *Fourier* não é localizado no tempo e as informações temporais não podem ser extraídas dos coeficientes da transformada de *Fourier*. A retenção de informações de um sinal apenas na frequência, e não no tempo é uma grande desvantagem da transformada de *Fourier*.

A transformada de *Fourier* de tempo curto [57] é um método de análise de um sinal no tempo-frequência no qual as informações relativas ao tempo e à frequência são localizadas por uma janela de deslizamento uniforme no tempo para todas as frequências. Em outras palavras, apenas uma pequena janela local é analisada usando a transformada de *Fourier*. Essa janela é deslocada ao longo do sinal para análise do próximo segmento do sinal até

que todo o sinal seja analisado.

As *wavelets* [78] vem sendo bastante usadas para seleção das características do sinal de EEG em sistemas de reconhecimento das emoções e são definidas como pequenas ondas que possuem duração limitada e zeros como valores médios, diferentemente da senoide que possui duração infinita. A energia de uma *wavelet* é concentrada no tempo, o que proporciona uma ferramenta para análise de sinais ou funções transientes, não estacionários e variantes no tempo. Uma *wavelet* mantém a característica de onda oscilatória, mas também permite a análise do sinal ou função no domínio do tempo e da frequência, simultaneamente [24]. Na Figura 2.5, pode-se observar um exemplo de *wavelet* na qual a energia é concentrada em um ponto e um exemplo de senoide oscilando em torno de $-\infty < t < \infty$, e portanto, com uma energia infinita.

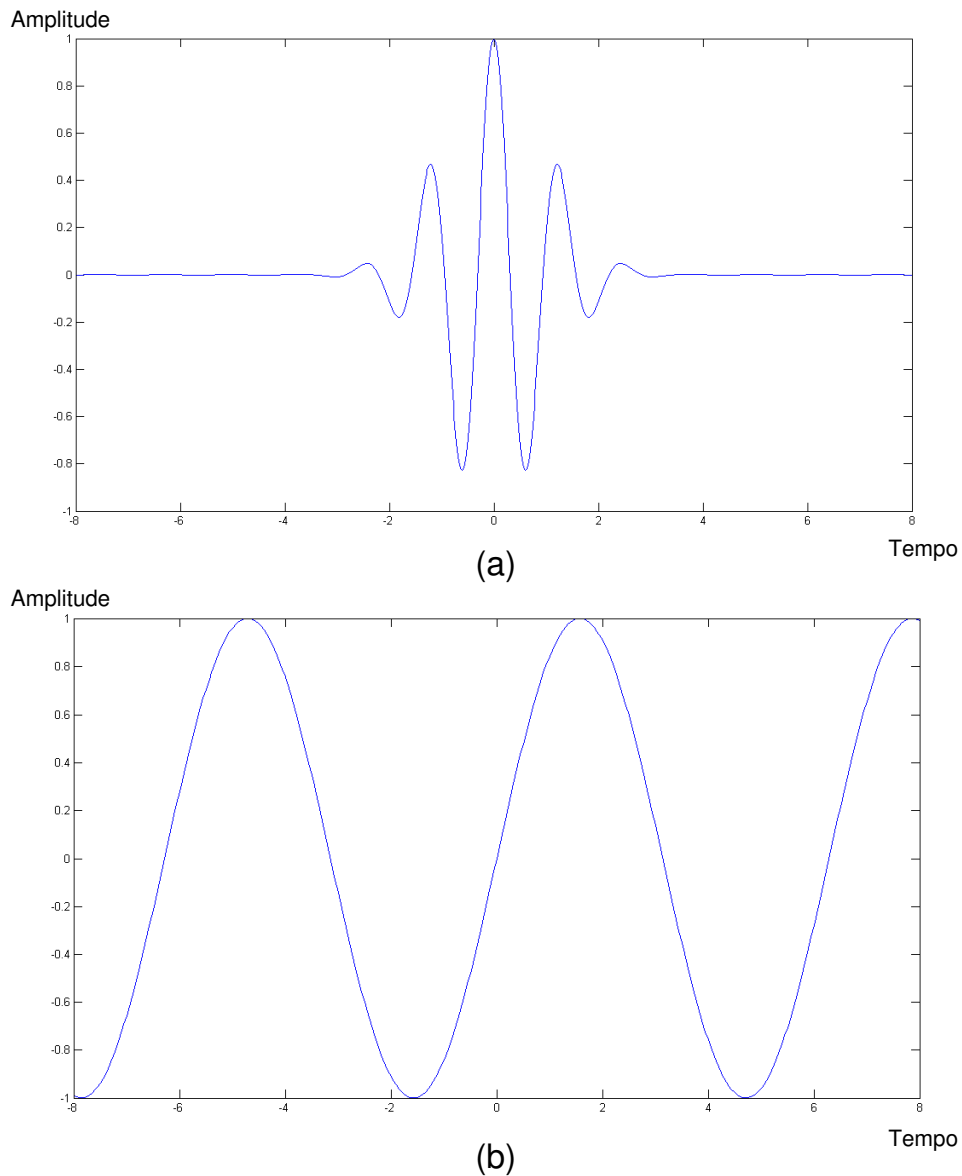


Figura 2.5: (a) Exemplo de *wavelet*, (b) Exemplo de senoide

A análise de *Fourier* consiste na decomposição de um sinal em ondas senoidais de várias frequências. De modo similar, na análise *wavelet* o sinal é decomposto em diferentes versões deslocadas e de diferentes escalas da *wavelet* original [24].

A principal vantagem das *wavelets* com relação a outros métodos é que com seu uso é possível observar aspectos dos dados não passíveis de detecção com o uso de outras técnicas de análise, como tendências, pontos de degradação e auto-similaridade. Devido a essas particularidades das *wavelets* é possível comprimir um sinal ou remover seus ruídos sem que ocorra uma degradação considerável [54].

A análise *wavelet* é dividida em contínua e discreta [28]. A transformada *wavelet* contínua é definida como a soma do sinal f em todo o tempo (t) multiplicado pelas versões deslocadas e de diferentes escalas da função *wavelet* Ψ .

$$C(\text{escala}, \text{posição}) = \int_{-\infty}^{\infty} f(t)\Psi(\text{escala}, \text{posição}, t)dt \quad (2.1)$$

O resultado da transformada *wavelet* contínua são os coeficientes C que são função da *escala* e *posição*. A multiplicação de cada coeficiente pela *wavelet* na *escala* e *posição* apropriada produz as *wavelets* constituintes do sinal original [76]. Na Figura 2.6, é apresentado um exemplo da transformada *wavelet*.




Figura 2.6: Sinal original e suas *wavelets* constituintes [76]

O cálculo dos coeficientes da *wavelet* em todas as possíveis escalas requer muito trabalho e gera um grande número de dados irrelevantes. Para obter-se uma análise mais eficiente e precisa, deve-se escolher um subconjunto de escalas e posições para o cálculo dos coeficientes de uma *wavelet* [76]. Essa abordagem é chamada de transformada *wavelet* discreta e foi usada neste trabalho.

Para definir a transformada *wavelet* discreta [24], tem-se que uma função $f(t)$, normalmente é melhor analisada, descrita ou processada se expressada como uma decomposição linear [24] por:

$$f(t) = \sum_l a_l \psi_l(t) \quad (2.2)$$

onde $l \in \mathbb{Z}$ é um índice para o somatório finito ou infinito, $a_l \in \mathbb{R}$ e são os coeficientes de expansão e ψ_l é um conjunto de funções no tempo t com valores reais chamado de

conjunto de expansão. Se a expansão (2.2) é única, o conjunto é chamado de base para a classe de funções [24]. Se a base é ortogonal, tem-se a seguinte relação:

$$\langle \psi_k(t), \psi_l(t) \rangle = \int \psi_k(t) \psi_l(t) dt = 0, k \neq l \quad (2.3)$$

então os coeficientes são calculados pelo produto interno, como mostrado a seguir:

$$a_k = \langle f(t), \psi_k(t) \rangle = \int f(t) \psi_k(t) dt. \quad (2.4)$$

Substituindo a equação (2.2) em (2.4) e usando (2.3), tem-se o coeficiente a_k . Para a série de *Fourier* as funções base ortogonais são $\sin(kw_0t)$ e $\cos(kw_0t)$ com frequências de kw_0 . Para a expansão *wavelet*, um sistema de dois parâmetros construído a partir da equação (2.2) tem-se:

$$f(t) = \sum_k \sum_j a_{j,k} \psi_{j,k}(t) \quad (2.5)$$

onde j e $k \in \mathbb{Z}$ e $\psi_{j,k}(t)$ são funções de expansão *wavelet* que normalmente formam uma base ortogonal. O conjunto de coeficientes de expansão $a_{j,k}$ são chamados de transformada *wavelet* discreta de $f(t)$ e a equação (2.5) é a transformada inversa [24].

Na transformada *wavelet* discreta, as escalas e posições são escolhidas com base em potências de dois, chamadas escalas e posições diáticas, fornecendo uma análise mais eficiente e com melhor acurácia [74].

Para muitos sinais, o conteúdo de baixa frequência é a parte mais importante, é ele que dá identidade ao sinal. O conteúdo de alta frequência, por outro lado, confere apenas algumas peculiaridades. Por exemplo, considerando-se a voz humana, tem-se que se as componentes de alta frequência forem removidas, a voz soa diferente, mas ainda pode-se entender o que está sendo dito. No entanto, se um número suficiente de componentes de baixa frequência for removido, ouve-se apenas ruídos [76].

Por essa razão, na análise *wavelet* usam-se as aproximações e os detalhes de um sinal, como ilustrado na Figura 2.7. As aproximações são as componentes de baixa frequência e os detalhes são as componentes de alta frequência do sinal [24].

Como ilustrado na Figura 2.8, o sinal original \mathbf{S} é processado por dois filtros complementares e é decomposto em dois outros sinais. O processo de decomposição é repetitivo, com sucessivas aproximações sendo decompostas, de modo que um sinal é dividido em várias componentes de baixa resolução [24].

Existem diversas famílias de wavelets discretas, como a *Haar*, *Morlet* e a *Daubechies* [24]. A família de *wavelets Daubechies* foi inventada por Ingrid Daubechies, uma das pessoas mais importantes na área de pesquisa *wavelets* [35]. Ingrid Daubechies criou as *wavelets* ortonormais compactas, tornando a transformada *wavelet* discreta prática.



Figura 2.7: Ilustração para o processo de filtragem do sinal em aproximações e detalhes

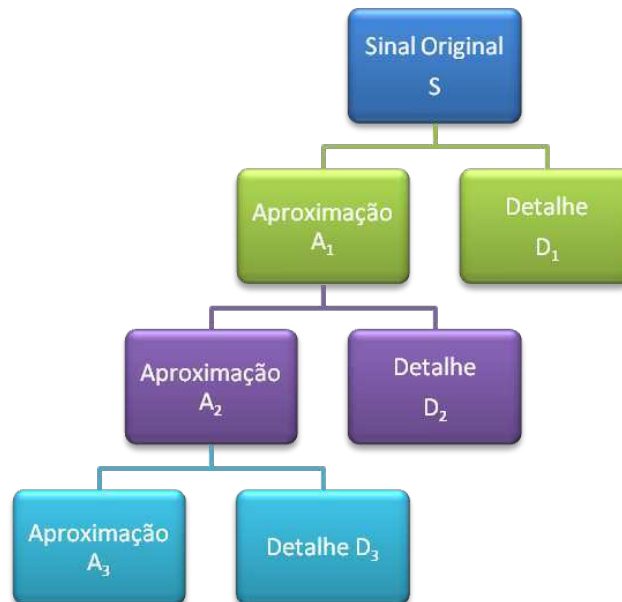
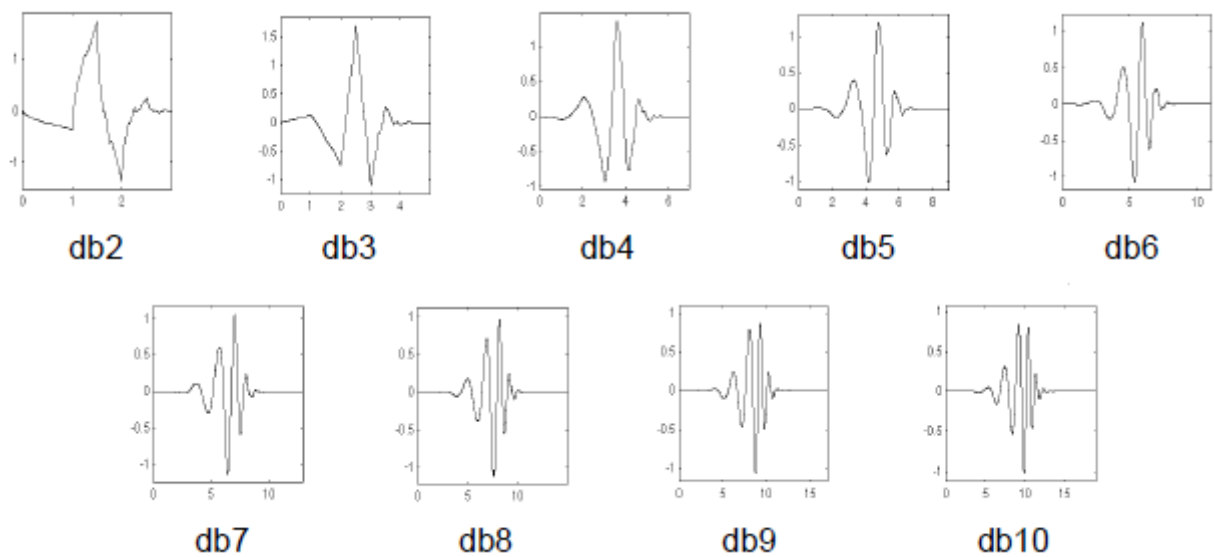



Figura 2.8: Ilustração para o processo de decomposição sucessiva do sinal

Os nomes das *wavelets* da família *Daubechies* são escritos como **dbN**, onde **N** é a ordem e **db** é o nome da *wavelet* [35]. Na Figura 2.9, apresenta-se um exemplo com nove *wavelets* *Daubechies*.

A *wavelet* *Daubechies* 4 possui a característica de suavizar o sinal e a propriedade de localizar de forma quase ótima o sinal no tempo e na frequência. Essas características tornam esse tipo de *wavelet* adequado para detectar mudanças nos sinais de EEG [107], [79], [114]. Além disso, em [78] foram realizados diversos experimentos com várias famílias de *wavelets* sendo observado que a *wavelet* **db4** melhor representa os sinais de EEG. Portanto, a *wavelet* *Daubechies* 4 foi usada neste trabalho na seleção das características dos sinais, como apresentado na Seção 4.1.3. Na Figura 2.10 apresenta-se um exemplo de *wavelet* *Daubechies* 4.

Figura 2.9: Representação de nove *wavelets Daubechies* [2]Figura 2.10: Exemplo de uma *wavelet Daubechies 4*

Classificação das Características dos Sinais Cerebrais

A segunda fase do processamento de sinais de EEG é a classificação do sinal e trata-se da transformação das características do sinal em sinais de interesse para uma determinada aplicação usando algoritmos de tradução. O processo de classificação pode ser não supervisionado ou supervisionado. Na classificação não supervisionada a tradução das características é realizada a partir das similaridades que existem entre os pontos de dados. Nenhuma informação é fornecida anteriormente sobre os grupos ou sobre as características dos pontos de dados dos grupos. Na classificação supervisionada é necessário o treinamento do classificador para reconhecer que certos pontos de dados pertencem a certos grupos. Os dados são divididos em dois grupos: os dados de treinamento e os dados de teste. Os dados de treinamento são fornecidos ao classificador juntamente com as características conhecidas do grupo. Geralmente, baseado nas informações apresentadas, o algoritmo classificador seleciona parâmetros e regras que modelam apropriadamente a classificação dos dados de treinamento. Os mesmos parâmetros e regras são aplicados aos

dados de teste para classificá-los no grupo adequado e validar a precisão do método de classificação [72].

A análise de agrupamento é um algoritmo de aprendizado não supervisionado. Uma importante característica da análise de agrupamento é a definição da similaridade ou proximidade entre cada par de pontos por uma medida de distância, como a distância Euclidiana, entre outras. O método dos vizinhos mais próximos é aplicado no agrupamento dos objetos. Com o uso desse método os dois objetos mais próximos com relação a sua proximidade métrica são colocados juntos em um agrupamento binário. Se algum objeto não agrupado estiver mais próximo desse agrupamento binário do que de outros objetos não agrupados, ele formará um agrupamento binário com o agrupamento descrito no passo anterior. Caso contrário, ele é colocado juntamente com outro objeto não agrupado em um agrupamento binário diferente do discutido no passo anterior. Se dois agrupamentos estão mais próximos um do outro que de outros objetos não agrupados, então esses agrupamentos formarão um grande agrupamento. Esse processo continua até que todos os objetos sejam agrupados em um grande agrupamento que contenha todos os agrupamentos menores.

O algoritmo k -médias é uma variação do método não supervisionado de agrupamento. O k -médias é também um método de agrupamento não supervisionado que difere do método regular de agrupamento por ter um número k fixo de agrupamentos. Nesse sentido, esse algoritmo não é completamente não supervisionado já que o número de agrupamentos é fornecido anteriormente.

Na análise discriminante [78] há um aumento na separação dos diferentes grupos de dados através do mapeamento ou projeção do espaço de características de entrada em um espaço de saída de menor dimensão que o de entrada onde a variância entre os dados de um grupo é minimizada e a variância entre diferentes grupos é maximizada. A análise discriminante é um método de classificação supervisionado e requer dados de treinamento.

A análise das componentes principais [103] é outro método estatístico usado geralmente para transformar um espaço de entrada em um espaço de saída de menor dimensão. O sistema de coordenadas é rotacionado usando uma transformação linear. Os eixos do novo sistema de coordenadas são os autovetores que descrevem o conjunto de dados e, portanto são combinações lineares dos eixos originais. A componente do eixo primário ou principal é selecionada para representar a direção de variação máxima dos dados. O eixo secundário, ortogonal ao eixo primário, representa a próxima maior variação dos dados e assim por diante. No espaço com as novas direções, a maior parte das variações dos dados está concentrada nas primeiras poucas componentes. Consequentemente, as componentes que possuem as maiores variações são mantidas, enquanto o restante é descartado. Como resultado, a dimensionalidade é reduzida sem o comprometimento da precisão na

representação dos dados.

As redes neurais artificiais [49] são modelos computacionais de aprendizagem desenvolvidos com base na biologia do cérebro humano. Esses modelos consistem de neurônios interconectados por sinapses. De um ponto de vista funcional, as redes neurais possuem a capacidade de aprender, assim como o cérebro e, idealmente, podem ser treinadas para o reconhecimento de qualquer informação, dado um conjunto de dados de entrada, pelo ajustamento dos pesos sinápticos. As redes neurais artificiais são sistemas computacionais para resolução de vários problemas práticos, mas sua maior utilização é na resolução de problemas que podem ser classificados como o reconhecimento de padrões, o que inclui uma diversidade de aplicações, como reconhecimento de voz, de imagens e de padrões em sinais cerebrais [15].

As redes neurais artificiais possuem diversas características que tornam o uso dessa ferramenta para resolução de problemas mais adequado com relação a outras técnicas [104], como as discutidas anteriormente. Algumas dessas características são apresentadas a seguir [48]:

- **Aprendizagem:** As redes neurais artificiais possuem a capacidade de aprender a partir de exemplos e automaticamente criar regras para o reconhecimento dos mesmos através de um processo iterativo de ajustes aplicados aos seus parâmetros livres (ex: pesos sinápticos).
- **Generalização:** As redes neurais artificiais podem apresentar uma saída adequada para uma entrada não presente no processo de aprendizagem.
- **Não linearidade:** Um neurônio pode ser linear ou não linear. Uma rede neural artificial é não linear quando constituída por neurônios não lineares conectados. Esta é uma característica importante quando considerado um sistema para geração de dados de entrada não linear. Nesse tipo de sistema, a separabilidade linear dos dados é inviável, já que não é possível separar os padrões dos dados com apenas uma reta.
- **Adaptabilidade:** É a capacidade que as redes neurais possuem de se adaptar a partir de alterações em seus pesos sinápticos perante as modificações no contexto, ou seja, uma rede neural treinada para operar em um contexto específico pode ser facilmente re-treinada para absorver pequenas alterações nesse contexto.
- **Tolerância a Falhas:** Uma parte das conexões da rede neural artificial pode não funcionar, sem que ocorra mudanças significativas em seu desempenho, devido ao seu conhecimento ser distribuído. Porém esta é uma propriedade característica de redes implementadas na forma física (em *hardware*).

- Resposta a Evidências: As redes neurais artificiais usadas no reconhecimento de padrões podem fornecer em sua saída informação sobre a confiança na decisão tomada, além de qual padrão selecionar. Essa característica fornece a rede a capacidade de rejeitar padrões ambíguos, de modo a melhorar o seu desempenho.

Uma rede neural artificial é composta por unidades de processamento, os neurônios. O modelo do neurônio artificial foi proposto com o objetivo de simular o comportamento do neurônio biológico [15]. Na Figura 2.11 apresenta-se o corpo do neurônio com suas entradas E_i e saída Y . O corpo do neurônio é dividido em duas partes, sendo que a primeira é responsável pela soma (Σ) do produto das entradas E_i pelos seus respectivos pesos w_i . Na segunda parte tem-se a função de ativação ou transferência f , que tem a função de controlar o valor a ser enviado pela saída. Cada neurônio possui ligações com outros neurônios denominadas sinapses e através delas os sinais são enviados e recebidos [20].




Figura 2.11: Modelo simplificado de um neurônio artificial

Além das entradas E_i , existe uma entrada não identificada nos neurônios biológicos e opcional nos neurônios artificiais, chamada viés, que possui sempre o valor 1 e tem se mostrado bastante útil em diversas aplicações [15]. A primeira parte do processamento, geralmente chamada de *net* é uma combinação linear das entradas como mostrado na equação (2.6) [15].

$$net = w_1 E_1 + w_2 E_2 + \dots + w_i E_i + w_v = \sum_{i=1}^n w_i E_i + w_v \quad (2.6)$$

Em que E_i são as entradas da rede, w_i são os pesos associados as entradas e refletem a importância das entradas e w_v é o peso da entrada de viés. O resultado da combinação linear é o valor de *net* [15]. A informação fornecida na saída Y do neurônio é obtida com a aplicação do valor *net* à uma função de ativação (f). Essa função de ativação pode ser, por exemplo, uma função linear, uma função escala ou uma sigmóide [20]. Para exemplificar, esses três tipos de função são apresentados na Figura 2.12.




Figura 2.12: Exemplos de funções de ativação de um neurônio artificial

O potencial e flexibilidade dos sistemas baseados em redes neurais artificiais são devido a existência de conjuntos de neurônios que estão interligados. Esse paralelismo de elementos com processamento local fornece a inteligência da rede. Um elemento da rede recebe um estímulo nas suas entradas, processa esse sinal e emite um novo sinal em sua saída que por sua vez é recebido pelos outros elementos [20].

As redes neurais podem ser classificadas considerando-se diversos critérios, como por exemplo, quanto ao número de camadas de neurônios, quando é possível ter uma, duas ou múltiplas camadas; à sua conectividade, que pode ser parcialmente ou totalmente conectada, quando todos os neurônios de uma camada estão conectados a todos os neurônios da camada imediatamente à frente; de acordo com o fluxo dos sinais processados, que pode ser sempre da entrada para a saída, chamadas de redes diretas, ou usando realimentação, chamadas redes com realimentação; e quanto ao tipo de treinamento, que pode ser supervisionado ou não supervisionado [48].

No treinamento supervisionado é necessário que a rede receba o vetor com os dados de entrada e o vetor com os alvos da rede, ou seja, a resposta desejada na sua saída. Neste caso, as diferenças entre os valores desejados e os valores obtidos são usadas para alterar os valores dos pesos existentes nas entradas dos neurônios, possibilitando o aprendizado da rede [15].

No treinamento não supervisionado a rede altera os valores dos seus pesos unicamente a partir do resultado do seu processamento. Nesse caso, o padrão de entrada geralmente é composto pelos atributos dos objetos que se deseja que a rede aprenda a reconhecer [15].

As redes neurais artificiais têm sido utilizadas com sucesso em várias aplicações médicas e na resolução de problemas não resolúveis por outras técnicas de processamento de sinal [104]. Essa técnica, junto com os classificadores lineares, é a mais usada em pesquisas com os sinais de EEG [72]. Além disso, as redes neurais artificiais podem ser usadas para classificar sinais de EEG com precisão, especialmente quando um pequeno número de eletrodos é usado [63]. Chen and Hou afirmaram que as redes neurais artificiais são

uma técnica eficaz para classificar dados de EEG devido à sua capacidade de lidar com dados ruidosos de forma eficiente [30]. Portanto, as redes neurais artificiais foram usadas na classificação das características dos sinais de EEG em emoções neste trabalho. Na Seção 4.1.3, é apresentada a rede usada neste trabalho.

2.5 Entropia e Energia

A entropia é a medida do grau de ordem/desordem do processo dinâmico base associado ao sinal. Um processo ordenado pode ser um sinal periódico com uma única frequência. Esse tipo de sinal é representado por uma wavelet com apenas um nível de resolução. Um sinal gerado por um processo totalmente aleatório representa um comportamento muito desordenado. Esse tipo de sinal possui uma representação wavelet com contribuição significativa de todas as bandas de frequência [93]. Já a energia corresponde a amplitude de cada banda de frequência do sinal de EEG [78]. A entropia e a energia vêm sendo usadas em diversos trabalhos como parâmetros para o reconhecimento das emoções.

Em [78], os autores estimularam cinco tipos de emoções em vinte indivíduos com o uso de vídeos. Os sinais de EEG foram adquiridos durante o experimento sendo suas bandas de frequências selecionadas com quatro diferentes tipos de *wavelets*: “db4”, “db8”, “sym8” e “coif5”. Os parâmetros estatísticos entropia, desvio padrão, variância e energia da característica alfa foram considerados para classificação com o uso dos algoritmos k-vizinhos próximos e análise discriminante linear.

Hosseini et. al. [96] propuseram um sistema para o reconhecimento de duas classes de emoções: calmo/neutro e negativo/excitado. Os autores estimularam quinze participantes com o uso de imagens, sendo os sinais de EEG adquiridos durante o experimento. As entropias dos sinais foram obtidas e classificadas em emoções com o algoritmo máquina de suporte vetorial.

Em [40], os autores usaram vídeos para estimular emoções positivas ou negativas em seis indivíduos. Para identificar essas emoções, os autores utilizaram diferentes parâmetros obtidos a partir das características dos sinais de EEG. As características dos sinais foram extraídas com a transformada de *Fourier* e a entropia e a energia foram obtidas. Esses parâmetros foram usados na classificação dos sinais de EEG em emoções com o uso de três algoritmos: máquina de suporte vetorial, k-vizinhos próximos e sistema linear dinâmico.

Murugappan et. al. [77] induziram em vinte indivíduos cinco emoções a partir de estímulos áudio-visuais: felicidade, surpresa, desgosto, medo e neutra. Os autores selecionaram as características dos sinais de EEG com a transformada rápida de *Fourier*. A entropia foi obtida a partir dessas características e usada na classificação dos sinais de EEG em emoções com os algoritmos k-vizinhos próximos e rede neural probabilística.

2.6 Contexto

O contexto do usuário é essencial no reconhecimento das emoções de um indivíduo [94]. Os acontecimentos do cotidiano, a personalidade e as preferências de uma pessoa estão intrinsecamente relacionados com suas emoções. Quando um indivíduo é submetido à uma situação semelhante a outra que tenha ocorrido no passado, é provável que ele sinta as mesmas emoções sentidas anteriormente [45].

Na literatura não existe uma concordância na definição de contexto. Em [100], definiu-se que o contexto está relacionado com a localização, identidade das pessoas e objetos da vizinhança e mudanças nesses objetos. De modo similar em [23], contexto é definido como a localização, identidade das pessoas ao redor do usuário em questão, horário do dia, temperatura, etc.

Em [95], o contexto é descrito como a localização, o ambiente, a identidade e o tempo. Já em [36], o contexto está relacionado com o estado emocional do usuário, atenção, localização e orientação, data e tempo, objeto e pessoas no ambiente do usuário.

Neste trabalho, o contexto é definido como qualquer informação que pode ser usada para caracterizar a situação de uma entidade. Uma entidade é uma pessoa, lugar ou objeto que seja considerada relevante na interação entre um usuário e uma aplicação, incluindo também o usuário e a aplicação [37].

Para definição dos fatores que caracterizam o contexto do usuário considerando apenas as informações relevantes, foi usada a abordagem dos 5 Ws 1 H (do inglês) [51], [56]. Nessa abordagem, o contexto é obtido a partir das respostas à seis questionamentos: “quem?”, “onde?”, “quando?”, “por que?”, “o que?” e “como?”

2.6.1 Quem?

“Quem” refere-se as informações relativas à identidade do indivíduo, como por exemplo, seu nome, idade, sexo, preferências e personalidade, entre outras. Esses dados podem ser obtidos automaticamente ou manualmente, onde ele mesmo é responsável por fazer uma descrição de seu perfil. O levantamento do perfil pode ser feito através da aplicação de questionários elaborados para esse propósito.

“Quem?” também está relacionado com a identificação das pessoas envolvidas no acontecimento, além do usuário do sistema. É importante saber quem são essas pessoas e como elas se relacionam com o usuário, por exemplo, se são amigos, irmãos ou colegas de trabalho, para que se tenha uma melhor descrição do contexto do usuário.

2.6.2 Onde?

“Onde?” refere-se ao local onde está ocorrendo o evento no qual o usuário do sistema se encontra. Essa localização pode ser definida de forma mais abrangente, por exemplo, como o país, o estado ou a cidade em que o indivíduo se encontra, assim como também de forma mais específica, como o bairro, a rua ou um endereço em particular. O nível de especificidade da localização do usuário depende de sua relevância para descrição do contexto do usuário.

A localização do indivíduo pode ser identificada automaticamente ou manualmente, sendo o usuário o responsável por fornecer essa informação.

2.6.3 Quando?

“Quando?” se refere ao ano, mês, dia do acontecimento ou qualquer dado relacionado ao tempo como, o período do dia (manhã, tarde ou noite), a estação do ano ou a hora do dia do evento, desde que a informação seja relevante para o contexto do indivíduo. Essa informação pode ser obtida automaticamente através do calendário e relógio de um dispositivo móvel, por exemplo.

2.6.4 Por que?

“Por que?” refere-se à razão que ocasionou o acontecimento. O conhecimento da motivação para ocorrer o evento é bastante importante, já que apenas essa informação tem um grande impacto no estado emocional de um indivíduo. Quando fala-se em motivações positivas, provavelmente o cérebro do usuário é estimulado positivamente. O contrário provavelmente acontece para razões negativas. A razão para ocorrência de uma determinada situação pode ser obtida manualmente, quando o próprio usuário a informa, ou automaticamente.

2.6.5 O que?

“O que?” está relacionado com o tipo de ocasião que está sendo realizada, como por exemplo, uma festa, um enterro, uma aula ou uma reunião de trabalho, entre outras. O tipo de evento, assim como sua motivação, está diretamente relacionado com o estado emocional do indivíduo. Por exemplo, se o evento é um enterro, provavelmente o cérebro do indivíduo será estimulado negativamente, já que trata-se de um evento triste. No caso de uma festa, provavelmente o cérebro humano será estimulado positivamente, já que trata-se de um evento motivado por alguma razão positiva.

Ainda existem algumas situações em que o tipo de evento não é decisivo na definição do estado emocional humano, por exemplo durante uma reunião de trabalho, a emoção sentida pelo indivíduo dependerá do seu nível de comprometimento com suas tarefas.

2.6.6 Como?

“Como?” refere-se ao modo que está sendo realizado o evento. Para definição da maneira que o evento está acontecendo, é necessário a obtenção de informações que indiquem métodos ou significados. Por exemplo, quando se define o local de um evento, a partir dessa informação pode-se inferir algumas características do evento. Quando trata-se de uma festa em uma casa de recepções, provavelmente se trata de um evento mais formal do que uma festa em uma residência. Além disso, informações relacionadas a motivação do evento também podem ajudar na definição de como o mesmo irá ocorrer.

2.7 Síntese

Neste Capítulo foram apresentados os conceitos e tecnologias necessários para o entendimento do método proposto neste trabalho para o reconhecimento das emoções humanas. A abordagem utilizada foi a identificação de quatro tipos de emoções a partir dos sinais cerebrais e contexto de um indivíduo, como pode ser visto no Capítulo 3. Por essa razão, primeiramente foi discutido sobre a definição das emoções. Em seguida, abordou-se a computação afetiva, que é a área de pesquisa onde tem-se como objetivo identificar as emoções durante a interação homem-máquina para tornar a mesma semelhante a interação humano-humano, como visto na Seção 2.2.

Neste trabalho, uma das fontes de dados utilizada foram os sinais cerebrais. As emoções são geradas no cérebro, e essa foi uma das motivações para o uso desses sinais na detecção das mesmas. Além disso, os sinais cerebrais não são passíveis de falsas simulações e interpretação ambígua, entre outras importantes características apresentadas no Capítulo 1. Na Seção 2.3, foi apresentada a relação existente entre o cérebro e as emoções, expondo quais áreas cerebrais são ativadas quando um indivíduo sente uma emoção, com foco na área pré-frontal do cérebro usada neste trabalho como fonte de dados.

Em sistemas de reconhecimento de emoções, os sinais cerebrais vêm sendo bastante usados, como visto na Seção 2.4. Para aquisição, seleção e classificação dos sinais cerebrais existem diversas técnicas, como visto nas Seções 2.4.1 e 2.4.2. A escolha de tais técnicas é importante para o desenvolvimento e obtenção das emoções com uma boa acurácia. Na Seção 2.5, foi realizada uma breve revisão sobre o uso da entropia e da energia em sistemas de reconhecimento de emoções.

Neste trabalho, foi proposto um método para o reconhecimento das emoções baseado nos sinais cerebrais e no contexto, como pode ser visto no Capítulo 3. Na Seção 2.6, foi realizada uma discussão sobre a definição de contexto usada neste trabalho.

Capítulo 3

Método Proposto

Neste Capítulo propõe-se um método para o reconhecimento das emoções humanas que pode ser aplicado à diversas áreas, como entretenimento, educação, medicina, sistemas tutores inteligentes, aviação e automação. Nessas áreas, o reconhecimento das emoções pode ser usado para diferentes fins, que variam desde o auxílio no ensino/aprendizado à redução de erros humanos na realização de atividades críticas que podem ocasionar acidentes graves tendo como consequência grandes prejuízos e até a morte.

O método tem como base os sinais cerebrais e o contexto de um indivíduo, sendo que escolheu-se essas informações com o objetivo de reconhecer as emoções sentidas por um indivíduo em situações do cotidiano, diferentemente dos trabalhos identificados e discutidos no Capítulo 1, onde são apresentados sistemas que reconhecem apenas emoções induzidas a partir de imagens, músicas ou vídeos. Na Figura 3.1, é apresentado o diagrama de blocos do método proposto.

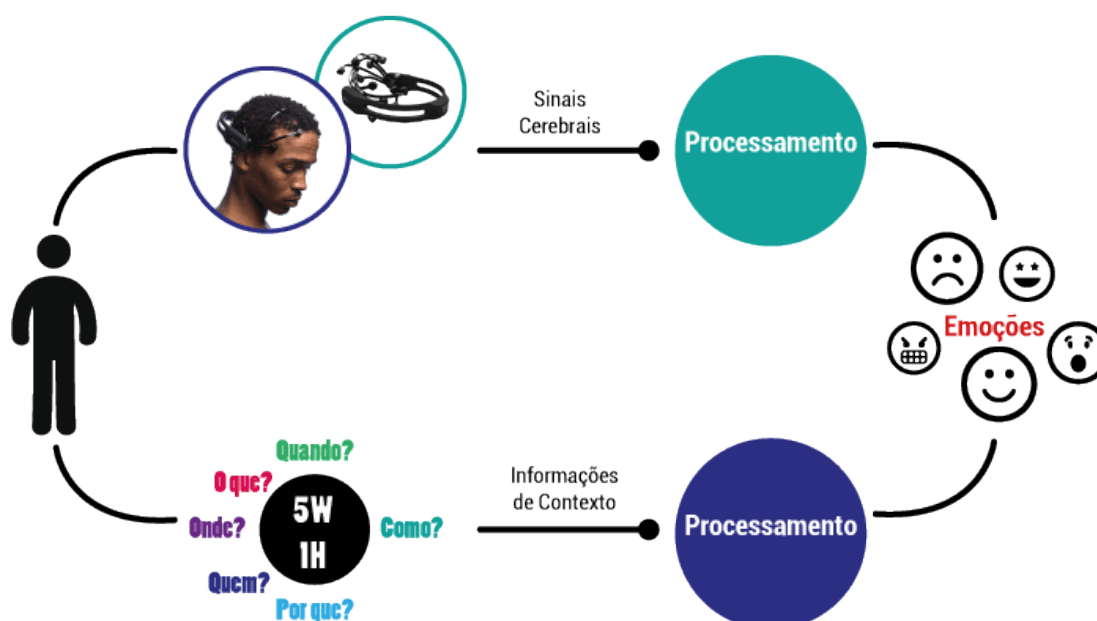


Figura 3.1: Diagrama do método para o reconhecimento das emoções

Como pode-se observar na Figura 3.1, as emoções do indivíduo são o resultado da classificação dos sinais cerebrais em emoções e do mapeamento do contexto em emoções. Os sinais cerebrais são classificados nas emoções excitado/positivo, excitado/negativo, calmo/positivo e calmo/negativo. Como já foi discutido na Seção 2.4, para a obtenção das emoções a partir dos sinais cerebrais são necessárias três etapas principais: a aquisição; o pré-processamento; e o processamento, sendo esta dividida na seleção e classificação das características do sinal. O diagrama de blocos da parte do método relativa aos sinais cerebrais é apresentado na Figura 3.2.



Figura 3.2: Diagrama de blocos para o módulo sinais cerebrais

Para aquisição dos sinais é considerado neste método o EEG, devido a disponibilidade de equipamentos portáteis e de baixo custo que possibilitam seu uso no cotidiano, sem causar desconforto ao usuário, como por exemplo o Emotiv [27] e o MindSet [6]. Neste trabalho foi utilizado o *Emotiv Epoch* da *Emotiv Systems* [117], porém outros dispositivos portáteis também são indicados. Embora esses equipamentos não possuam a mesma precisão de equipamentos de EEG usados em hospitais, de acordo com [42], eles podem ser usados em qualquer aplicação, exceto em reabilitação e controle de próteses.



Figura 3.3: Imagem do equipamento (*Headset*) para coleta de dados

O Emotiv, apresentado na Figura 3.3, é um equipamento de EEG, não invasivo, que possui quatorze canais para leitura dos sinais elétricos gerados pelos neurônios e dois canais de referência CMS/DRL - Common Mode Sense/Driven Right Leg nos terminais

P3/P4. De acordo com o sistema Internacional 10-10, os eletrodos são posicionados em AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4. As especificações do *Emotiv* são apresentadas na Tabela 3.1.

Tabela 3.1: Especificações do Emotiv [11]

Número de Canais	14 (além de dois canais de referência CMS/DRL nos terminais P3/P4)
Nomenclatura	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Método de Amostragem	Amostragem sequencial (Conversor AD único)
Taxa de Amostragem	128 amostras por segundo
Resolução	14 bits 1 LSB = 0,51 μ V (16 bit ADC, 2 bits de ruído instrumental descartados)
Largura de Banda	0,2 - 45Hz, digital notch filters em 50Hz e 60Hz
Filtragem	Filtro digital de quinta ordem
Entrada	8400 μ V (pp)
Modo de Acoplamento	Acoplamento AC
Conectividade	Conexão sem fio proprietária, banda de 2.4 GHz
Alimentação	Bateria de Lítio
Autonomia da Bateria	12 horas
Medição de Impedância	Qualidade de contato em tempo real usando o sistema patenteado

No método, o pré-processamento é realizado pelo próprio Emotiv como pode ser observado na Tabela 3.1; a seleção das características é realizada pela transformada *wavelet*, como discutido na Seção 2.4.2; e a classificação dos sinais cerebrais nas emoções positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo, com as redes neurais artificiais, como discutido na Seção 2.4.2.

O contexto é essencial para o reconhecimento das emoções sentidas por um indivíduo, pois fatores como o temperamento, personalidade, motivação, percepções, recordações e aprendizagens, são fundamentais para se perceberem as emoções. Como foi discutido na Seção 2.6, o contexto neste trabalho é definido como qualquer informação que pode ser usada para caracterizar a situação de uma entidade, desde que essa informação seja relevante para a situação abordada. Uma entidade é uma pessoa, lugar ou objeto que seja considerada relevante na interação entre um usuário e uma aplicação, incluindo também o usuário e a aplicação [37].

As informações usadas na definição do contexto são obtidas com base na teoria dos 5W1H [56]. Nessa abordagem, o contexto é obtido a partir das respostas à seis questionamentos: “quem?”, “onde?”, “quando?”, “por que?”, “o que?” e “como?”. No método proposto, apenas as respostas relevantes para caracterização do contexto são consideradas. No estudo de caso apresentado neste trabalho, em que o cenário trata-se do contexto de trabalho de um operador de sistemas elétricos, tem-se diversas respostas para os ques-

tionamentos, porém apenas os fatores importantes são considerados, como por exemplo:

- “Quem?”: nome do operador, idade, sexo, formação e nível de atenção, entre outros. Porém, variáveis como nome e idade não são relevantes e não precisam ser consideradas.
- “Onde?”: país, estado, cidade e rua, entre outros. Apesar das diversas variáveis, a maior parte delas não é relevante para caracterizar o contexto de trabalho do operador.
- “Quando?”: ano, mês, dia, turno e horário, entre outros, sendo que o ano, o mês e o dia são irrelevantes.
- “Por que?”: é o motivo pelo qual o trabalho está sendo realizado, e deve-se analisar se o mesmo deve ser considerado para o contexto de trabalho.
- “O que?”: trata-se de qual trabalho está sendo realizado. No caso, uma manobra em um sistema elétrico e deve ser considerada no contexto.
- “Como?”: cansaço, estresse, carga de trabalho, entre outros. No estudo, todos esses fatores são importantes.

Após o levantamento dos fatores relevantes para caracterizar o contexto, caso sejam muitos, deve-se realizar uma análise para verificar as que possuem maior influência no contexto para identificação das emoções. No método, propõe-se realizar uma análise estatística, sendo necessário identificar primeiramente a variável de saída. Como no cenário definido para o estudo de caso, tem-se como o contexto do indivíduo, seu contexto de trabalho, o erro humano foi escolhido como parâmetro para quantificar o peso das variáveis devido à sua relação com as emoções de um indivíduo.

De acordo com [17], as emoções negativas afetam o indivíduo na eficiência do processamento em uma tarefa cognitiva. Além disso as emoções negativas deixam o indivíduo mais susceptível a cometer erros [25]. Já as emoções positivas estão associadas com a flexibilidade de raciocínio e uma maior criatividade na resolução de problemas [16].

Considerando-se o erro humano, a primeira parte da análise estatística é o cálculo da matriz de correlação e matriz de p -valor, para verificar a correlação dos fatores relacionados ao contexto e o erro. Em seguida, deve ser realizado o teste de normalidade da variável de saída para identificar qual tipo de modelo pode ser aplicado.

No caso de normalidade, aplica-se o modelo de regressão linear múltipla, onde são identificadas as estimativas de influência de cada variável. Pode-se observar com essas estimativas que cada fator possui um impacto diferente na definição do contexto. Por

essa razão, a classificação do contexto em emoções negativas, positivas ou neutras é realizada a partir de todas as informações relevantes para caracterizá-lo, considerando-se sua influência.

A parte do método relativa à classificação do contexto em emoções, consiste no produto de todas as variáveis selecionadas por seus respectivos pesos (estimativa de cada variável no modelo), dividido pela soma dos pesos, como mostrado na equação (3.1).

$$C = \frac{w_1 F_1 + w_2 F_2 + \dots + w_i F_i}{w_1 + w_2 + \dots + w_i} = \frac{\sum_{i=1}^n w_i F_i}{\sum_{i=1}^n w_i} \quad (3.1)$$

onde, C é o contexto, F_i são os fatores que caracterizam o contexto e w_i os respectivos pesos que cada um dos fatores tem sobre o contexto. $0 \leq F_i \leq 2$ e $F_i \in \mathbb{N}$.

Para cada um dos fatores deve-se associar um valor entre 0 e 2, onde o 0 corresponde ao nível mais baixo de dado fator, 1 corresponde ao nível intermediário e 2 ao nível mais alto. Por exemplo, dado o nível de experiência no desempenho de uma tarefa: 0, corresponde à um baixo nível de experiência; 1, à um nível médio e 2, à um nível alto de experiência. Aplicando esta escala, o contexto representado na equação (3.1) tem como resultado uma das três emoções apresentadas a seguir:

$$\begin{aligned} 0 \leq C < 1, & \quad \textit{Negativo} \\ C = 1, & \quad \textit{Neutro} \\ 1 < C \leq 2, & \quad \textit{Positivo} \end{aligned} \quad (3.2)$$

A última etapa do método é a fusão dos sinais cerebrais classificados nas emoções positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo com o contexto classificado nos estados emocionais positivo, negativo e neutro. Como essa fusão é na etapa de decisão, é realizada uma combinação dos resultados obtidos a partir dos sinais cerebrais e do contexto, como mostrado na Tabela 3.2.

3.1 Síntese

Neste Capítulo foi proposto o método para o reconhecimento das emoções humanas estimuladas durante os eventos do cotidiano. A arquitetura proposta é composta por dois módulos principais: contexto e sinais cerebrais do indivíduo.

Para cada módulo, foram apresentados os métodos utilizados neste trabalho. A técnica de aquisição dos sinais cerebrais escolhida foi o EEG, devido a sua portabilidade, fácil uso, baixo custo e boa resolução temporal. As técnicas usadas na seleção e classificação dos sinais elétricos cerebrais em emoções foram as *wavelets* e as redes neurais, respectivamente.

As *wavelets* são uma técnica apropriada para o processamento de sinais não estacionários e com muitos eventos transientes, como é o caso dos sinais de EEG. A família

Tabela 3.2: Saída do método baseado nos sinais cerebrais e contexto do indivíduo

Classificação dos Sinais Cerebrais	Classificação do Contexto	Emoções Resultantes
Positivo/Calmo	Positivo	Positivo/Calmo
Positivo/Excitado	Positivo	Positivo/Excitado
Negativo/Calmo	Positivo	Neutro
Negativo/Excitado	Positivo	Neutro
Positivo/Calmo	Neutro	Positivo/Calmo
Positivo/Excitado	Neutro	Positivo/Excitado
Negativo/Calmo	Neutro	Negativo/Calmo
Negativo/Excitado	Neutro	Negativo/Excitado
Positivo/Calmo	Negativo	Neutro
Positivo/Excitado	Negativo	Neutro
Negativo/Calmo	Negativo	Negativo/Calmo
Negativo/Excitado	Negativo	Negativo/Excitado

de *wavelets* utilizada neste trabalho foi discutida na Seção 2.4.2. As redes neurais são sistemas computacionais para resolução de problemas de adaptação de funções e reconhecimento de padrões baseada no comportamento do cérebro humano. Na Seção 2.4.2, é apresentada a rede neural usada na classificação dos sinais cerebrais em emoções.

Por fim, foi apresentada a abordagem escolhida para definição do contexto do usuário, como visto na Seção 2.6. Para obtenção das informações do usuário foi escolhido o método dos 5 Ws e 1 H. Essa abordagem foi aplicada no estudo de caso apresentado na Seção 4.2.

Capítulo 4

Estudo Experimental

Neste Capítulo apresenta-se um estudo de caso para validar o método proposto no Capítulo 3, sendo este dividido em três etapas: sinais cerebrais; informações de contexto; e sinais cerebrais e informações de contexto. Na primeira etapa, o reconhecimento das emoções foi realizado apenas com base nos sinais cerebrais, porém a fase de aquisição dos sinais não foi efetuada no escopo deste trabalho. Ao invés disso, usou-se um banco de dados de sinais de EEG [1].

Na segunda etapa, definiu-se um experimento para avaliar a parte do método referente ao contexto. Para isso, duas tarefas realizadas no dia-a-dia por operadores de uma subestação elétrica foram selecionadas para serem desempenhadas pelos participantes com o uso de um simulador. Durante o experimento adquiriu-se diversos dados dos participantes, como informações pessoais, psicológicas. Essas informações foram usadas para o reconhecimento das emoções a partir do contexto.

A terceira etapa do estudo de caso foi implementada para ilustrar o uso do método proposto no Capítulo 3. O cenário e o procedimento experimental, assim como as ferramentas para coleta de dados foram os mesmos do segundo estudo de caso.

4.1 Etapa 1 do Estudo de Caso

Nesta etapa realizou-se a classificação dos sinais cerebrais de um indivíduo em quatro tipos de emoções: excitado/positivo, excitado/negativo, calmo/positivo e calmo/negativo. Escolheu-se a abordagem bidimensional para ser usada no reconhecimento das emoções humanas devido ao banco de dados usado neste estudo ser baseado nesta abordagem.

4.1.1 Banco de Dados

No desenvolvimento do banco de dados [60] usado neste trabalho, os autores usaram cliques de música para estimular emoções nos participantes do experimento. Inicialmente, foram

selecionados 120 estímulos. Metade desses estímulos foi escolhida através de um método semiautomático, ou seja, foi usada a página da internet de música Last.fm [3].

No Last.fm, o usuário pode acompanhar as músicas que ele geralmente escuta e receber recomendações de novas músicas e eventos. Além disso, os usuários do Last.fm também podem atribuir opiniões às músicas. Muitas das opiniões atribuídas trazem significados emocionais para o usuário, como por exemplo, agressiva ou deprimente. O modo como foi realizada a seleção de 60 estímulos pelo Last.fm é discutido em [60].

Os 60 estímulos restantes foram selecionados manualmente. Após a seleção dos estímulos, um minuto de cada clipe de música foi extraído para ser usado na indução de emoções nos participantes. A seleção dessa amostra de um minuto de cada clipe de música foi realizada de acordo com a carga emocional de cada trecho musical. Finalmente, foram escolhidos 40 estímulos para serem usados no experimento. Esses estímulos foram escolhidos para induzir quatro diferentes tipos de emoções nos indivíduos: positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo. O protocolo usado para realização do experimento é apresentado na Figura 4.1.

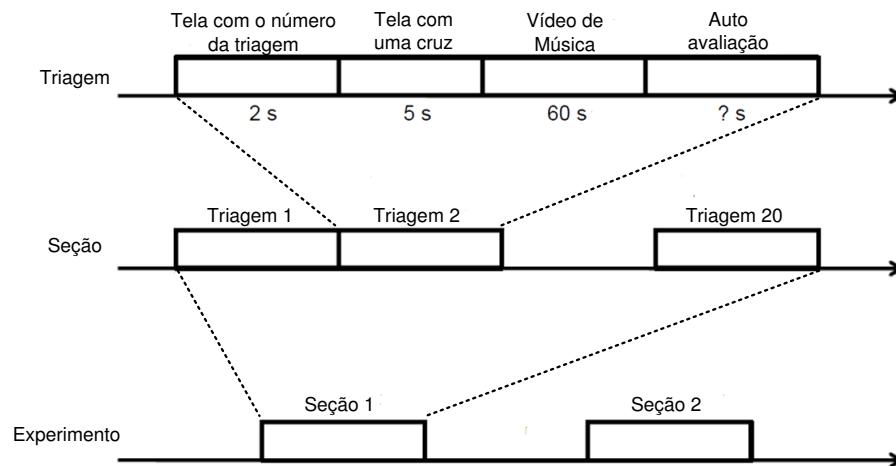


Figura 4.1: Protocolo experimental

Os experimentos foram realizados em dois ambientes laboratoriais com controle de iluminação. Trinta e dois participantes fizeram parte do experimento, tendo seus sinais de EEG e sinais fisiológicos periféricos adquiridos com o sistema *Biosemi Active Two*. Foram usados dois computadores nesse experimento, um para armazenar os dados e outro para apresentação dos estímulos. Para manter os dois computadores sincronizados, foram enviados marcadores de um computador para o outro. Na Figura 4.2, é apresentada a montagem do experimento.

Os sinais de EEG foram adquiridos a uma taxa de amostragem de 512 *Hz* usando 32 eletrodos posicionados de acordo com o sistema Internacional 10-10. Treze sinais fisiológicos periféricos também foram armazenados, entre eles, os movimentos oculares,

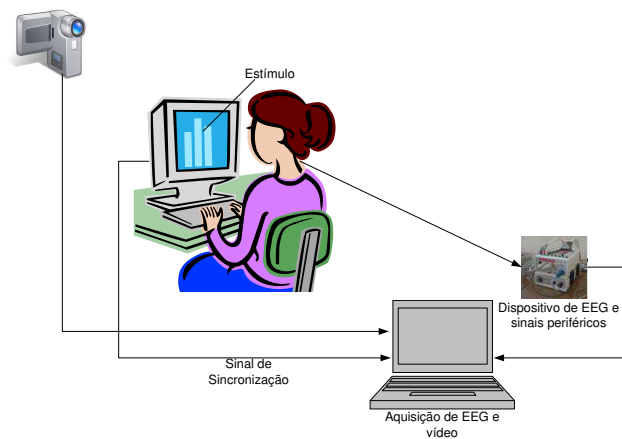


Figura 4.2: Montagem do experimento

movimentos musculares da face, temperatura e pressão do sangue. Além disso, para 22 dos 32 participantes dos experimentos foi armazenado o vídeo dos mesmos na posição frontal usando uma câmera sony DCR-HC27E.

Como resultado dos experimentos obteve-se um banco de dados composto pelos seguintes arquivos:

- `Online_ratings` nos formatos xls, csv, ods spreadsheet. Contém todas as classificações individuais da auto-avaliação;
- `Video_list` nos formatos xls, csv, ods spreadsheet. Contém os nomes das páginas do *YouTube* dos vídeos musicais utilizados na auto-avaliação e no experimento e as estatísticas das classificações individuais da auto-avaliação;
- `Participant_ratings` nos formatos xls, csv, ods spreadsheet. Contém todas as classificações realizadas pelos participantes durante o experimento;
- `Participant_questionnaire` nos formatos xls, csv, ods spreadsheet. Contém as respostas dadas pelos participantes aos questionários aplicados antes do experimento;
- `Face_video` no formato zip. Contém as gravações de vídeo da face na posição frontal dos participantes 1-22 durante o experimento;
- `Data_original` no formato zip. Contém os sinais fisiológicos originais, ou seja, não processados, dos 32 participantes adquiridos durante o experimento no formato BDF (Biosemi Data Format);
- `Data_preprocessed` nos formatos zip para *Python* e *Matlab*. Contém os sinais fisiológicos pré-processados (remoção dos ruídos relacionados aos sinais de EOG, redução da taxa de amostragem, filtragem, segmentação, etc) dos 32 participantes adquiridos no experimento nos formatos *Matlab* e *Python (numpy)*.

Como já foi visto na Seção 2.3, os sinais adquiridos a partir do canal AF3, foram usados para avaliar a parte do método proposto neste trabalho relacionada aos sinais cerebrais. Esses sinais foram extraídos a partir do arquivo `Data_preprocessed` para *Matlab*. As etapas de pré-processamento e processamento desses sinais são discutidas nas próximas Seções.

4.1.2 Pré-Processamento

O pré-processamento dos dados do banco de dados usado neste trabalho foi realizado por seus autores, não sendo parte deste trabalho e pode ser observado em [60]. A seguir, são apresentadas as etapas do pré-processamento.

- a taxa de amostragem dos dados foi reduzida de 512 *Hz* para 128 *Hz*. De acordo com o teorema de *Nyquist*, um sinal deve ser amostrado a uma taxa maior que duas vezes a componente de maior frequência de interesse no sinal para que essa componente seja capturada [110]. Como a maior frequência de interesse é menor que 64 *Hz*, dado que o autor em [60] considerou gama com faixa de frequência entre 30 e 47 *Hz*, a taxa de amostragem foi reduzida para 128 *Hz*.
- os ruídos do sinal de EEG devido ao sinal de EOG foram removidos usando a técnica separação cega de sinais. Tal técnica é usada para separar um conjunto de fontes de sinais de um conjunto de sinais mistos sem nenhuma informação ou muito pouca informação das fontes de sinais e do processo de fusão dos sinais;
- foi aplicado um filtro passa-faixa com frequência de corte mínima de 4 *Hz* e máxima de 45 *Hz*;
- os dados foram ponderados de acordo com uma referência comum;
- os dados foram segmentados em 60 s de amostras, sendo que os 3 primeiros segundos foram removidos.

Os sinais pré-processados foram armazenados em trinta e dois arquivos com formato do *Matlab*, um arquivo por participante do experimento. O arquivo de cada participante contém dois *arrays* de dados, como mostrado na Tabela 4.1.

4.1.3 Processamento dos Sinais

Como já foi discutido na Seção 2.4.2, o processamento do sinal se divide em duas etapas: a seleção das características do sinal e a classificação dessas características em emoções. Neste trabalho, usou-se a transformada *wavelet* e as redes neurais artificiais para selecionar

Nome do Array	Forma do Array	Conteúdo do Array
<i>data</i>	40 x 40 x 8064	Vídeo/triagem x canal x dados
<i>labels</i>	40 x 4	Vídeo/triagem x rótulo(valência, excitação, dominância, liking)

Tabela 4.1: Formato do arquivo de cada participante

as características do sinal de EEG desejadas e classificar essas características em emoções, respectivamente.

Seleção das Características do Sinal de EEG

Neste trabalho, usou-se a transformada *wavelet* discreta *Daubechies 4*, como foi discutido na Seção 2.4.2, para selecionar as características teta e alfa dos sinais de EEG.

Como os arquivos com os sinais de EEG do banco de dados são pré-processados e estão no formato da ferramenta *Matlab* [4], para leitura desses sinais implementou-se uma rotina em *Matlab*. Além disso, essa rotina também possui a função de selecionar as características delta, teta, alfa, beta e gama dos sinais de EEG.

Primeiramente, os sinais de EEG de cada um dos participantes foram carregados no *Matlab*. Porém, apenas o sinal armazenado a partir do canal AF3 foi extraído de cada um dos arquivos do banco de dados. Uma amostra do sinal do canal AF3 é apresentada na Figura 4.3.




Figura 4.3: Amostra de sinal adquirida a partir do canal AF3

Os dados de EEG extraídos foram guardados em um novo arquivo por participante.

Na tabela 4.2 apresenta-se o formato desses arquivos.

Tabela 4.2: Formato do novo arquivo de cada participante

Nome do <i>Array</i>	Forma do <i>Array</i>	Conteúdo do <i>Array</i>
data	40 x 8064	Vídeo/triagem x dados

Depois de selecionar os sinais de EEG do canal AF3, realizou-se uma decomposição de nível 4 dos sinais de EEG usando a transformada *wavelet* Daubechies 4. O nível 4 foi usado pois, apesar da taxa de amostragem dos sinais de EEG do banco de dados ser 512 Hz, no pré-processamento do sinal essa taxa foi reduzida à 128 Hz, como discutido na Seção 4.1.2. A decomposição de nível 4 dos sinais de EEG foi realizada com a função *wavedec*. A sintaxe dessa função é apresentada a seguir:

$$[C,L] = \text{wavedec}(X,N,wname) \tag{4.1}$$

onde, X é o sinal a ser decomposto, N é o nível da decomposição e $wname$ é o tipo da transformada *wavelet*.

A função *wavedec* retorna a *wavelet* de decomposição do sinal no nível N . A estrutura de decomposição de saída contém o vetor *wavelet* de decomposição C e o vetor L . O vetor C é composto pelos coeficientes das *wavelets* e o vetor L contém o tamanho desses coeficientes. Na Figura 4.4, apresenta-se a estrutura desses vetores tendo como exemplo a transformada *wavelet* usada neste trabalho.

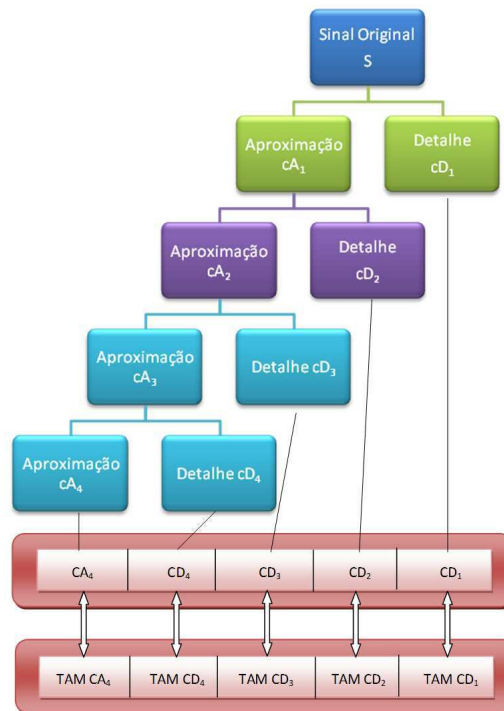


Figura 4.4: Estrutura de decomposição do sinal original

O próximo passo foi a seleção das características do sinal de EEG, sendo que apenas os ritmos teta e alfa são relevantes neste trabalho, pois estão relacionadas com as emoções humanas. Na Tabela 4.3, são apresentados os valores das componentes do sinal de EEG e suas frequências relacionadas com as características do sinal de EEG.

Tabela 4.3: Componentes associadas às características rítmicas do sinal de EEG

Componentes	Características	Frequências
A_4	delta	1 - 4 Hz
D_4	teta	4 - 8 Hz
D_3	alfa	8 - 16 Hz
D_2	beta	16 - 32 Hz
D_1	gama	32 - 64 Hz

As características do sinal de EEG foram selecionadas através da função *wrcoef*, usada para determinar as aproximações e detalhes de um sinal unidimensional dada uma estrutura $[C,L]$ e um tipo específico de *wavelet*. A sintaxe da função *wrcoef* é apresentada a seguir:

$$X = wrcoef(type,C,L,wname,N) \quad (4.2)$$

onde, *type* pode ser “d” se o sinal a ser determinado for um detalhe da *wavelet* ou “a” se for uma aproximação, *wname* é o tipo da *wavelet* e *N* o nível desejado. Na Figura 4.5, apresentam-se exemplos dos gráficos que ilustram o sinal original, os detalhes D_1 (gama), D_2 (beta), D_3 (alfa) e D_4 (teta) e a aproximação A_4 (delta).




Figura 4.5: Gráficos do sinal original, dos detalhes D_1 , D_2 , D_3 e D_4 e da aproximação A_4

Após a obtenção de teta e alfa, foram calculados os valores da entropia e energia desses sinais. A entropia foi calculada com a função *wentropy*, que possui a seguinte sintaxe:

$$Entropia = \text{wentropy}(X,T,P) \quad (4.3)$$

onde, X é o sinal que se deseja calcular a entropia, T é o tipo de entropia e P é um parâmetro opcional e depende de T . Nas Figuras 4.6 e 4.7 são apresentados os gráficos das entropias e energias de teta para um dos trinta e dois participantes, respectivamente.




Figura 4.6: Gráficos das entropias de teta




Figura 4.7: Gráficos da energias de teta

Como pode ser observado, foram calculadas um total de quarenta entropias e quarenta energias para cada característica (teta ou alfa) para cada um dos participantes. Como foi

discutido na Seção 4.1.1, para cada participante tem-se quarenta triagens, e cada triagem possui 8064 amostras. Para cada triagem foram calculados os valores de entropia e de energia de alfa e de teta.

Classificação das Características do Sinal de EEG

Neste trabalho, foi usado o algoritmo redes neurais artificiais na classificação das características dos sinais de EEG em quatro tipos de emoções: positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo.

Numa rede neural artificial existem vários parâmetros a serem definidos, como o número de camadas escondidas, a quantidade de neurônios em cada camada da rede e o método de treinamento. A escolha desses parâmetros neste trabalho foi realizada baseada na literatura e em alguns experimentos cujos resultados são apresentados no Apêndice A.

O primeiro passo no desenvolvimento da rede neural foi a definição do tipo de rede a ser usada. O tipo de rede escolhido foi uma rede direta de múltiplas camadas. Esse tipo de rede é usado em problemas de reconhecimento de padrões [20]. Uma rede direta é criada através da função *newff* em *Matlab* [20]. A sintaxe de tal função é apresentada a seguir:

$$net = newff(P,T,[S_1S_2...S_{(N-l)}],TF_1TF_2...TF_{Nl},BTF,BLF,PF,IPF,OPF,DDF) \quad (4.4)$$

sendo,

- P a matriz $R \times Q_1$ de R vetores de entrada com Q_1 amostras;
- T a matriz $SN \times Q_2$ de SN vetores de alvos com Q_2 amostras;
- S_i o tamanho da camada i , para $N-1$ camadas. Caso não seja definido, o padrão para esse parâmetro é $||$ e nesse caso não existem camadas escondidas. O tamanho SN da camada de saída é definido a partir de T ;
- TF_i é a função de transferência da camada i . Caso não seja definido, o padrão usado para este parâmetro é *tansig* (tangente hiperbólica sigmoide) para as camadas escondidas e *purelin* para a camada de saída;
- BTF é a função usada para o treinamento da rede (o padrão é *trainlm*);
- BLF é a função de aprendizagem para definição dos pesos/bias. A função padrão é definida como *learngdm*;
- PF é a função de desempenho. A função padrão é a *mse*;

- *IPF* é o vetor com as funções de processamento de entrada. O vetor padrão é *fixunknowns, removeconstantrows, mapminma*;
- *OPF* é o vetor com as funções de processamento de saída. O vetor padrão é *removeconstantrows, mapminmax*;
- *DDF* é a função que define o modo pelo qual é realizada a divisão dos dados. A função padrão é a *dividerand*.

A matriz P de entrada da rede neural artificial foi definida como um vetor com as entropias ou energias de teta ou de alfa, sendo necessário apenas um vetor de entrada.

A rede neural artificial foi treinada com quatro diferentes vetores de entrada. Cada um dos vetores foi aplicado a entrada da rede em diferentes momentos. Cada vetor possui quarenta elementos, sendo que cada elemento corresponde a uma das quatro emoções citadas no início desta Seção. Primeiramente, testou-se a rede tendo como entrada um vetor com as energias da componente alfa. Em um segundo momento, aplicou-se à entrada da rede um vetor com os valores referentes à entropia da componente alfa. Depois, usou-se um vetor com os valores para a energia da componente teta como entrada da rede. Por último, aplicou-se um vetor com os valores da entropia da componente teta à entrada da rede neural artificial.

O segundo passo na escolha dos parâmetros da rede foi definir os alvos. Neste trabalho, os sinais de EEG foram classificados de acordo com a abordagem bidimensional, e portanto, é necessária a definição de quatro tipos de alvos: positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo. Cada um dos alvos foi representado por uma combinação binária de quatro elementos, sendo que apenas um deles é o número um e o restante são zeros, como apresentado na Tabela 4.4.

Tabela 4.4: Alvos da rede neural e suas respectivas combinações binárias

Tipo de emoção	Combinação binária
positivo/excitado	1 0 0 0
positivo/calmo	0 1 0 0
negativo/excitado	0 0 1 0
negativo/calmo	0 0 0 1

Para a definição do número de camadas escondidas e da quantidade de neurônios de cada uma dessas camadas, foram realizados experimentos com redes com 2 e 3 camadas escondidas. Além disso, foram realizados testes considerando 10, 20, 30 e 40 neurônios em cada uma das camadas. Com base nesses experimentos, apresentados no Apêndice A, observou-se que os melhores resultados foram obtidos com uma rede neural com duas

camadas escondidas e com quarenta neurônios em cada uma das camadas. Na Figura 4.8, apresenta-se a arquitetura da rede neural usada neste trabalho.

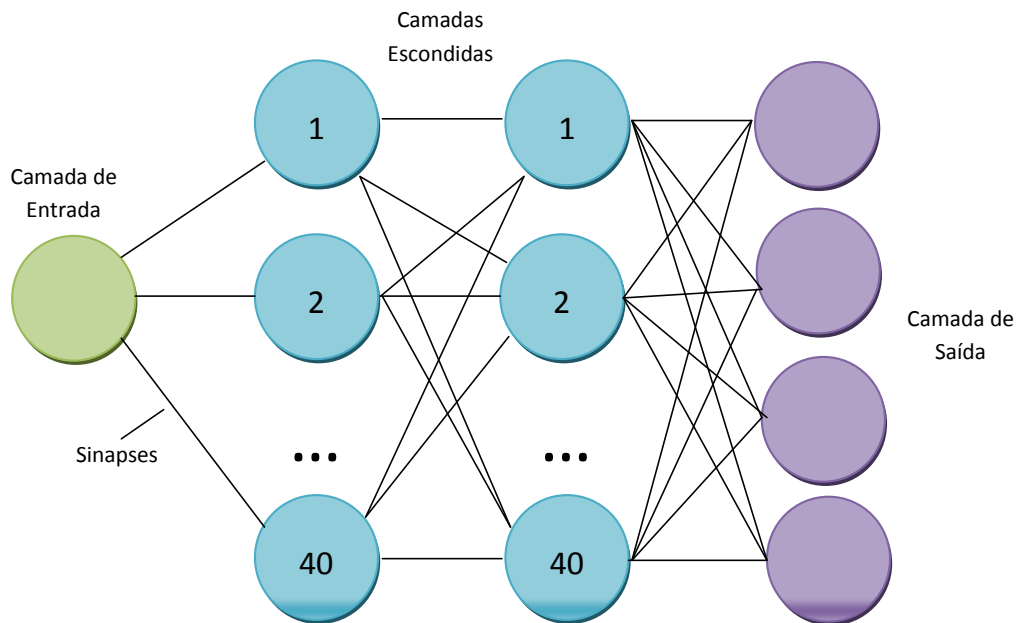


Figura 4.8: Arquitetura da rede neural usada neste trabalho

A função de transferência *tansig* foi usada nas camadas escondidas e na camada de saída. Múltiplas camadas escondidas de neurônios com funções de transferência não-lineares fornecem a rede a capacidade de aprender relações não-lineares entre os vetores de entrada e saída. Além disso, funções sigmóides são normalmente usadas nos neurônios de saída em problemas de reconhecimento de padrões [20]. O gráfico da função de transferência *tansig* é apresentado na Figura 4.9.

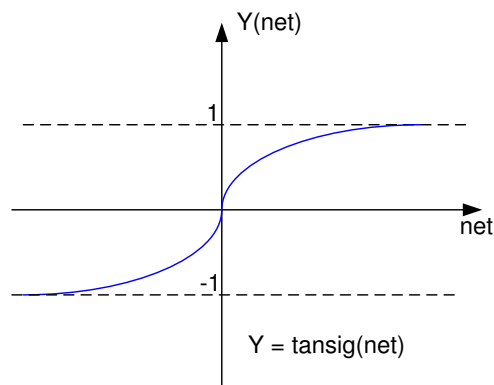


Figura 4.9: Gráfico para a função de transferência tansig

A aprendizagem em redes neurais ocorre com o uso de algoritmos de treinamento desenvolvidos com base no mecanismo de aprendizagem do sistema nervoso humano. Existem

diversos métodos para treinar uma rede neural direta. A lista dos algoritmos de treinamento disponíveis no *software Neural Network Toolbox* [20] são listados na Tabela 4.5.

Tabela 4.5: Algoritmos de treinamento de uma rede neural direta

Função	Nome do método
<i>trainlm</i>	Levenberg-Marquardt
<i>trainbfg</i>	BFGS Quasi-Newton
<i>trainrp</i>	Propagação Resiliente
<i>trainscg</i>	Gradiente Conjugado Escalado
<i>traincgb</i>	Gradiente Conjugado com Reinício Powell/Beale
<i>traincgf</i>	Gradiente Conjugado Fletcher-Powell
<i>traincgp</i>	Gradiente Conjugado Polak-Ribière
<i>trainoss</i>	Secante de uma etapa
<i>traingdx</i>	Propagação com Taxa de Aprendizagem Variável

Em [20], realizaram-se experimentos com seis diferentes tipos de banco de dados. Nesses experimentos, foram aplicados os métodos de treinamento de redes neurais diretas apresentados na Tabela 4.5. Metade dos bancos de dados relaciona-se com problemas de aproximação de função, que está fora do escopo deste trabalho. A outra metade dos bancos de dados é relativa aos problemas de reconhecimento de padrões. Baseado nos resultados obtidos pelos autores, optou-se por usar o algoritmo propagação resiliente neste trabalho. O algoritmo de propagação resiliente é o método mais rápido para resolução de problemas de reconhecimento de padrões.

No restante dos parâmetros da rede empregou-se as funções padrões apresentadas anteriormente. A função usada no aprendizado para definição dos pesos/bias é a *learnngdm*, gradiente descendente com momento. Tal função é usada para calcular a variação no peso dW para cada neurônio dos P neurônios de entrada e o erro E , peso W , taxa de aprendizagem LR e constante de momento MC , de acordo com o gradiente descendente com momento [20]:

$$dW = mc * dW_{prev} + (1 - mc) * lr * gW \quad (4.5)$$

A variação no peso anterior dW_{prev} é armazenada e lida do estado de aprendizagem LS .

Algumas funções de processamento são associadas aos dados de entrada da rede. O processamento dos dados é necessário para colocá-los em uma forma que seja mais fácil e eficiente para a rede. Como foi visto anteriormente são usadas três funções padrões no processamento dos dados de entrada da rede:

- A função *fixunknowns* é usada para recodificar valores desconhecidos (que são re-

presentados como valores *NaN*) em valores numéricos. Essa função armazena informações sobre quais dados são conhecidos e quais dados são desconhecidos [20].

- A segunda função padrão é a *removeconstantrows* e é usada na remoção das linhas de dados que aparecem repetidamente com o objetivo de minimizar o tempo de processamento de informações redundantes, e portanto, sem utilidade para a rede [20].
- A terceira função é a *mapminmax*, que é usada para colocar os valores dos dados de entrada dentro do intervalo $[-1, 1]$. Essa transformação acelera o tempo de processamento da rede e evita que quando usadas funções de transferência do tipo sigmóide ocorra saturação. A saturação em funções sigmóides inicia para valores de entrada da rede maiores que três. Quando a saturação ocorre no início do processo de treinamento, os valores dos gradientes da rede são muito pequenos e o treinamento da rede é muito lento [20].

O diagrama de blocos para o processamento das entradas da rede é apresentado na Figura 4.10.



Figura 4.10: Diagrama de blocos para o processamento das entradas da rede

Da mesma forma que os dados de entrada, existem funções de processamento associadas às saídas da rede. Essas funções são usadas para traduzir os vetores de alvos fornecidos previamente em dados a serem usados pela rede. Então, as saídas da rede são reversamente processadas usando as mesmas funções para produzir dados de saída com as mesmas características dos alvos originais. As funções de processamento de saída padrões são duas: *removeconstantrows*, *mapminmax* [20]. O diagrama de blocos para o processamento das saídas da rede é apresentado na Figura 4.11.



Figura 4.11: Diagrama de blocos para o processamento das saídas da rede

A taxa de aprendizado da rede, tem grande influência no treinamento, já que uma taxa muito baixa torna o processo de aprendizado muito lento e uma taxa muito alta provoca

oscilações na rede o que impede a convergência do processo de aprendizado. Sugere-se na literatura um valor de 0,4 para a taxa de aprendizado para que não ocorra nenhum dos dois problemas citados [48]. Essa taxa foi usada nesse trabalho. O erro máximo admissível foi estipulado em 0,01.

O último parâmetro da rede a ser discutido é a divisão dos dados. Os dados usados neste trabalho como entrada da rede neural foram divididos em três grupos: dados de treinamento, dados de teste e dados de validação da rede. A divisão dos dados foi realizada através da função *dividerand* que fornece uma divisão aleatória [20]. Porém, apesar da divisão ser aleatória, os dados foram divididos de acordo com as seguintes porcentagens:

- 70 % dos dados foram usados para treinar a rede;
- 15 % dos dados foram usados para testar a rede;
- 15 % dos dados foram usados para validar a rede.

Um resumo das características da rede neural usada neste trabalho é apresentado a seguir:

- uma camada de entrada com apenas um neurônio. O sinal de entrada pode ser um vetor com os valores da energia ou entropia das componentes teta ou alfa;
- duas camadas escondidas, sendo que cada uma possui 40 neurônios;
- função de transferência *tansig* nas camadas escondidas e na camada de saída;
- uma camada de saída, sendo que a saída da rede foram os sinais de EEG classificados em emoções como parte deste trabalho: positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo;
- a técnica usada para o treinamento da rede foi a propagação resiliente.
- taxa de aprendizado de 0,4;
- erro máximo admissível de 0,01.

Após criar a rede, o segundo passo foi treinar a mesma. O treinamento foi realizado com o uso da função *train*. A sintaxe dessa função é apresentada a seguir:

$$[net,tr] = train(net,P,T) \quad (4.6)$$

onde, *net* é a rede neural, *P* são os dados de entrada da rede e *T* são os alvos da rede [20].

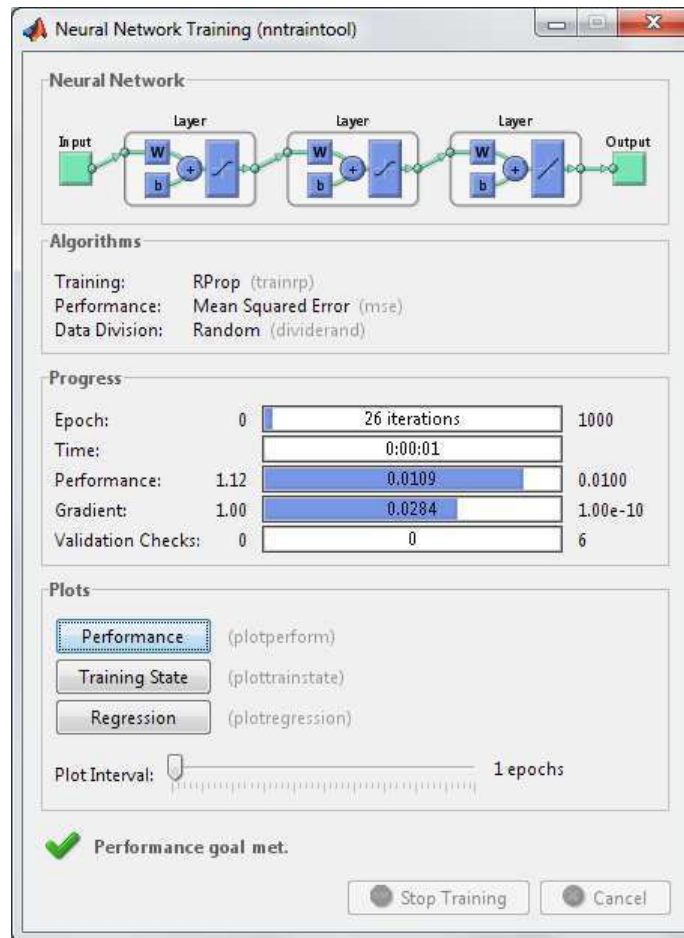


Figura 4.12: Ilustração da tela de treinamento da rede neural

A função *train* retorna a rede neural treinada (*net*) e os dados do treinamento (*tr*). Quando a função *train* é executada, uma ferramenta de treinamento do *Matlab* é carregada [20]. Uma ilustração da tela de treinamento é apresentada na Figura 4.12.

Depois de treinar a rede, a mesma foi simulada com o uso da função *sim*. Essa função retorna as saídas da rede [20]. A sintaxe da função *sim* é apresentada a seguir:

$$Y = \text{sim}(\text{net}, P, T) \quad (4.7)$$

onde, *net* é a rede neural, *P* são os dados de entrada da rede e *T* são os alvos da rede.

Com o resultado da simulação da rede, obteve-se a matriz de confusão [87] com a porcentagem de erros e acertos da rede neural artificial. Essa matriz foi obtida com a função *plotconfusion* do *Matlab*. A sintaxe dessa função é apresentada a seguir:

$$\text{plotconfusion}(\text{targets}, \text{outputs}) \quad (4.8)$$

onde, *targets* são os alvos da rede neural artificial e *outputs* são as saídas.

A matriz de confusão oferece uma medida efetiva do modelo de classificação, ao mostrar o número de classificações corretas versus as classificações previstas para cada classe,

sobre um conjunto de exemplos [87]. Na Figura 4.13 são apresentadas quatro matrizes de confusão, sendo que cada uma delas corresponde aos resultados obtidos a partir da classificação com um dos quatro vetores de entrada.

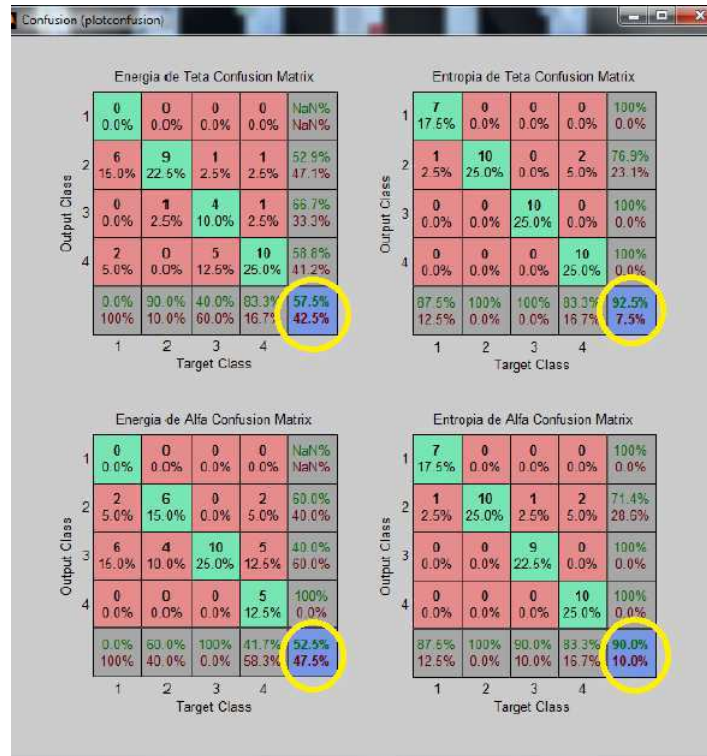


Figura 4.13: Matrizes com porcentagens de erros e acertos na classificação dos sinais de EEG em emoções

Os resultados apresentados nas matrizes são referentes à classificação dos sinais de EEG de um dos trinta e dois participantes em emoções. Pode-se observar que usando como entrada da rede o vetor com a energia de alfa ou de teta, obteve-se resultados insatisfatórios, 52,5 % e 57,5 %, respectivamente. Com o vetor com a entropia de alfa ou teta como entrada da rede, os resultados são bastante satisfatórios, 90 % e 92,5 %, respectivamente.

Por último, para validação da rede foi plotado o gráfico de regressão, no qual pode-se observar a relação entre as saídas da rede e os alvos, como mostrado na Figura 4.14.

Os três gráficos representam os dados de treinamento, validação e teste. A linha pontilhada em cada parcela representa o resultado perfeito (saídas = alvos). A linha sólida representa a melhor linha de regressão linear entre ajuste saídas e alvos. O valor R é uma indicação da relação entre as saídas e os alvos. Se $R = 1$, indica que existe uma relação linear exata entre as saídas e os alvos. Se R é próximo de zero, então não existe uma relação linear entre as saídas e os alvos. Na Figura 4.14, os dados de treino indicam um bom ajuste, aproximadamente 0,86. Os resultados de validação e testes apresentam

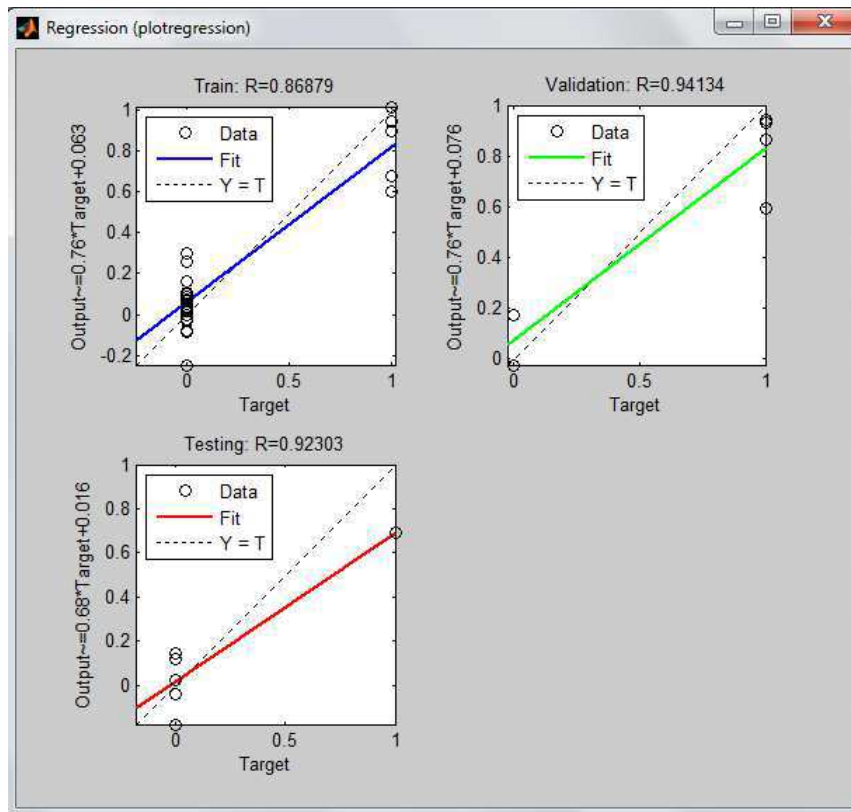


Figura 4.14: Gráficos das relações entre saídas e alvos da rede neural artificial

valores de R maior do que 0,9.

Os procedimentos descritos anteriormente foram aplicados aos sinais de EEG dos trinta e dois participantes para classificação dos mesmos em emoções com o objetivo de verificar se os métodos utilizados para essa finalidade fornecem resultados satisfatórios (entre 80 % e 90 %). Os resultados de cada um dos participantes são apresentados no Apêndice B. Os resultados obtidos são discutidos no Capítulo 5.

4.2 Etapa 2 do Estudo de Caso

Na segunda etapa do estudo de caso implementado neste trabalho tem-se o objetivo de avaliar a parte do método proposto no Capítulo 3 referente ao contexto do indivíduo. Para isso, o cenário escolhido foi o ambiente de trabalho de uma subestação distribuidora de energia elétrica, onde são realizadas manobras em sistemas elétricos diariamente. Durante o desempenho dessas tarefas existem riscos de ocorrer erros humanos, que podem ocasionar desde apagões de grandes regiões até acidentes mais graves, como a morte de indivíduos.

Em um ambiente real, as tarefas desempenhadas pelo operador são descritas a partir de um conjunto de instruções, reproduzidas no roteiro de tarefas apresentado no Apêndice D. Nesse roteiro são propostas duas tarefas complementares realizadas durante a manutenção

de um equipamento: a liberação e a normalização de um disjuntor. Essas tarefas foram executadas pelos participantes com o uso da ferramenta SimuLIHM [33]. Esse simulador é usado no treinamento de operadores de uma subestação e na análise de resultados. A arquitetura do SimuLIHM é modular e possui um ambiente destinado ao tutor e outro ao operador.




Figura 4.15: Tela do SimuLIHM: simulador de uma subestação elétrica [33]

A versão do simulador usada neste trabalho possui um ambiente de simulação baseado em realidade virtual que representa uma sala de operação de uma subestação de energia elétrica como mostrado na Figura 4.15. Os operadores em treinamento podem deslocar-se em torno da sala de operação, interagindo a partir de um *mouse* ou teclado, e realizar suas tarefas de forma semelhante ao que fariam no ambiente real. Para isso, interagem com representações virtuais dos painéis de controle e com um sistema supervisório real, cujo acesso é feito através do ambiente virtual [44].

Os experimentos foram realizados de acordo com o projeto com CAAE (Certificado de Apresentação para Apreciação Ética) número 49721215.6.0000.5182, aprovado pelo Comitê de Ética 5182 - Hospital Universitário Alcides Caneiros / Universidade Federal de Campina Grande.

4.2.1 Procedimento Experimental

O experimento foi planejado de acordo com o protocolo experimental elaborado para apoiar a observação do comportamento humano descrito em [13]. Este protocolo experimental consiste da seguinte sequência de passos: recepção e esclarecimento do participante sobre o que será feito e em quais condições participará; preenchimento de formulários nos quais declara se concorda com as condições do experimento e se concorda com a gravação de imagens e áudio que serão utilizados nas análises. O participante é solicitado a preencher uma ficha de cadastro com dados pessoais de contato e declarando características pessoais para estabelecer se seu perfil coincide com aquele especificado para o universo de participantes e um questionário com o objetivo de determinar o seu nível de atenção

inerente. O participante é esclarecido sobre a possibilidade de interromper sua participação no experimento a qualquer momento. Ao final do experimento o participante é solicitado a expressar sua opinião sobre a tarefa realizada e sobre os instrumentos de trabalho e, solicitado a responder um questionário com o propósito de determinar o esforço percebido durante o experimento. A duração da participação é de 1 hora e 45 minutos, dos quais 50 minutos são reservados para realizar a tarefa planejada. Este protocolo se encontra documentado em várias publicações do grupo de pesquisa que atua no Laboratório de Interface Homem-Máquina (LIHM) da UFCG. As informações colhidas durante o experimento são utilizadas exclusivamente pela equipe de pesquisadores envolvidos com a análise dos dados e têm um caráter de sigilo.

Participantes

Participaram do experimento um total de seis indivíduos, sendo duas mulheres e quatro homens. Todos os participantes são estudantes da graduação ou pós-graduação em Engenharia Elétrica, e por essa razão, possuem o conhecimento básico da tarefa. Foi pedido que cada participante dormisse um determinado número de horas no dia anterior a realização do experimento, sendo que esse número de horas variou entre 0, 5 e 8 horas.

Ambiente de Realização de Teste

O experimento foi realizado na sala de testes do Laboratório de Interface Homem-Máquina (LIHM) da Universidade Federal de Campina Grande (UFCG). O ambiente consiste de duas salas: a sala de teste e a sala de monitoramento.

Na sala de teste foram usados dois computadores, um equipamento de EEG, uma câmera para capturar a imagem da face do participante e um microfone para interação do participante com o tutor. Em um dos computadores foi executado o simulador usado pelo usuário para execução das tarefas. O segundo computador foi usado para executar a aplicação desenvolvida para leitura e armazenamento dos sinais cerebrais. A configuração da sala de teste é apresentada na Figura 4.16.

Na sala de monitoramento foram usados um monitor, um computador e um equipamento de áudio para o caso de necessidade de intervenção durante o experimento. O monitor foi usado para monitoramento das atividades realizadas pelo participante e o computador para apresentação das imagens da câmera. O equipamento de áudio foi usado para responder às questionamentos do usuário em caso de dúvidas do mesmo durante o teste e para algumas intervenções necessárias durante o desempenho das tarefas. A configuração da sala de monitoramento é apresentada na Figura 4.17.

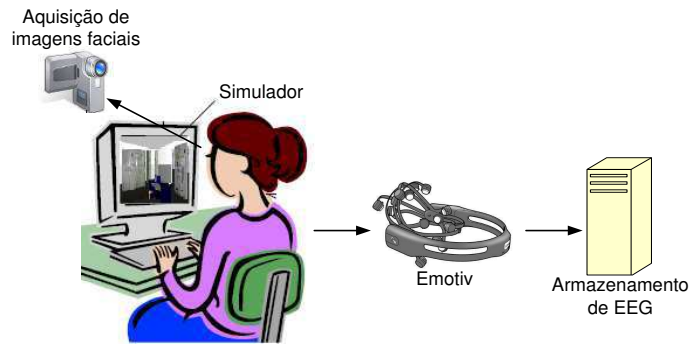


Figura 4.16: Ilustração da configuração da sala de teste



Figura 4.17: Ilustração da configuração da sala de monitoramento

Pré-teste

A primeira fase do pré-teste consistiu da apresentação do protocolo a ser seguido para realização do experimento ao participante, da concordância na participação no experimento a partir da assinatura de um termo, do preenchimento de um questionário para definição de perfil e aplicação do teste D2 para determinar o nível de atenção inerente [19].

No questionário usado para caracterização do perfil do participante incluíram-se questões pessoais, como nome, gênero e idade, relacionadas ao nível de conhecimento do simulador e à personalidade do participante.

O teste D2 trata-se de uma avaliação psicológica utilizada para identificar patologias relacionadas à atenção e concentração de um indivíduo. O respondente deve reconhecer um conjunto de três caracteres específicos em uma sequência de 47 caracteres diversos. A seleção acontece em um total de 14 repetições, onde cada uma tem duração de meio minuto (totalizando 658 para busca). A partir das respostas fornecidas identifica-se um conjunto de índices que, quando analisados, indicam a classificação de normalidade (ou anormalidade) relativa ao desempenho qualitativo e quantitativo na realização do teste, respectivamente : atenção e agilidade. Todas as ferramentas aplicadas na primeira fase do pré-teste são apresentadas no Apêndice D.

Na segunda fase do pré-teste realizaram-se os procedimentos necessários para ocorrência do teste. O equipamento para leitura dos sinais de EEG foi preparado (os eletrodos foram umedecidos com um líquido condutor e encaixados no dispositivo).

O equipamento de EEG usado, o *Emotiv EPOC*, como foi discutido no Capítulo 3, possui quatorze canais para leitura dos sinais elétricos gerados pelos neurônios e dois canais de referência. De acordo com o sistema internacional 10-10, os eletrodos são posicionados em AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4. O dispositivo de EEG foi aplicado à cabeça do participante e a qualidade do sinal de cada eletrodo foi verificada com uso do software Control Panel do fabricante do dispositivo [10].

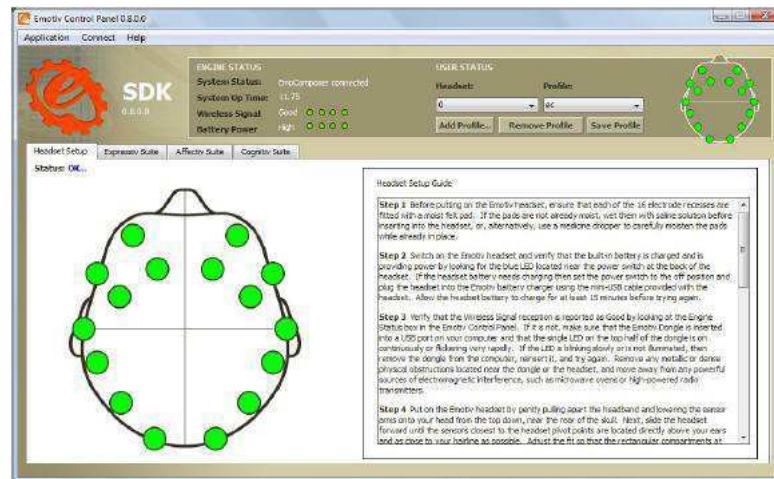


Figura 4.18: Ilustração do *software* de configuração do *Emotiv, Control Panel* [10]

Na Figura 4.18, a imagem apresentada à esquerda é uma representação da localização dos eletrodos na cabeça do indivíduo. Cada círculo representa um eletrodo e sua localização aproximada quando o dispositivo está aplicado à cabeça do usuário. As cores dos círculos que representam os eletrodos correspondem a qualidade do contato. Para alcançar a melhor qualidade de contato possível, todos os eletrodos devem apresentar a cor verde.

Em seguida foram executados dois aplicativos para leitura e armazenamento dos sinais, sendo um para aquisição dos sinais processados pelo *Control Panel* em emoções e movimentos faciais, e outro para leitura dos sinais de EEG. Os aplicativos foram conectados ao *Control Panel* para recebimento dos sinais cerebrais.

Após a aplicação do EEG, explicou-se ao participante o funcionamento do simulador, informando quais comandos do mouse e teclado são usados para interagir com os painéis e se deslocar no ambiente. As chaves dos painéis e suas funcionalidades também foram apresentadas ao participante.

Teste

No contexto do trabalho de operação de subestações elétricas, as tarefas selecionadas para o experimento são classificadas como frequentes e programadas. Estas são compostas por sequências prescritas de ações listadas em um roteiro, que pode ser visto no Apêndice D,

disponíveis para os operadores. Os resultados exigidos devem ser alcançados dentro dos prazos e estritamente de acordo com a sequência prescrita de ações. A tarefa consiste em agir sobre os dispositivos de controle localizados em painéis de controle de um sistema de supervisão. Para fornecer mais realismo ao contexto, os participantes, foram submetidos ao estresse de eventos, durante o desempenho da tarefa, que normalmente ocorrem durante uma jornada habitual de trabalho do operador. Estes consistiram de chamadas telefônicas recebidas e desencadeamento de alarmes do sistema. As duas tarefas descritas no roteiro são complementares e realizadas durante a manutenção de um equipamento: a liberação e a normalização de um disjuntor.

O participante realizou cada uma das tarefas de acordo com o roteiro do operador, sempre assistido pelo avaliador, que acompanhou toda a execução do teste a partir do roteiro do avaliador e equipamentos disponíveis na sala de monitoramento. Além disso, durante o teste foram adquiridos os sinais de EEG do participante, sendo estes armazenados em arquivos de texto, e imagens da face do indivíduo a partir da câmera disponível no ambiente, como pode ser observado na Figura 4.19.



Figura 4.19: Imagem do ambiente de realização de teste

Todas as ações do participante sobre os objetos do simulador foram gravadas no log do simulador. Esse registro inclui o tipo de ação, o objeto sobre o qual a ação foi realizada e o horário em ela foi efetuada.

Pós-teste

Após o encerramento das atividades definidas no roteiro de tarefas, foi apresentado o vídeo da realização das tarefas ao participante e com o uso da ferramenta SAM [66] foi pedido para o participante auto-avaliar seu estado emocional ao final de cada um minuto de vídeo. No SAM as emoções são identificadas a partir de três dimensões:

- valência (positivo para negativo): “feliz / satisfeito / contente” para “triste / insatisfeito / aborrecido”;

- intensidade (alta para baixa): “excitado / estimulado / alerta” para “relaxado / calmo / sonolento”;
- e dominância (dominado para dominante): “controlado / influenciado / submisso” para “em controle / dominante / importante”.

O respondente informa seu sentimento a partir de uma escala não verbal, de nove (9) pontos, que utiliza figuras (bonecos) para representar as dimensões. Estas podem ser analisadas individualmente, ou a partir de um valor único, onde: (intensidade + dominância) * valência.

Também foi aplicado o teste NASA-TLX [9] para medir a carga de trabalho percebida pelo participante. Essa carga é expressa a partir de três aspectos, subdivididos em dimensões:

- comportamento (esforço e o desempenho percebidos);
- tarefa (demandas mental, física e temporal para sua realização);
- subjetivo (frustração percebida)

As seis dimensões abordadas são apresentadas como questões associadas a uma escala de 20 pontos, cada. As dimensões podem ser analisadas isoladamente, mas a quantificação da carga de trabalho se dá a partir do somatório dos valores individuais, onde a carga de trabalho varia de 0 (carga mínima) à 120 (carga máxima), sendo considerada excessiva se obtém acima de 60 pontos. É possível identificar, ainda, quais as dimensões que mais contribuíram para a composição da carga de trabalho geral.

As ferramentas SAM e NASA-TLX são apresentadas no Apêndice D.

4.2.2 Análise dos Dados

Nesse etapa do estudo de caso o objetivo foi definir os pesos de cada fator na caracterização do contexto para o reconhecimento das emoções no ambiente de uma subestação elétrica. Para isso, realizou-se uma análise estatística com os dados obtidos no experimento, com a finalidade de verificar as variáveis mais importantes para definição do contexto com base na quantidade de erros cometidos pelos participantes.

O erro humano foi escolhido como parâmetro para quantificar o peso das variáveis devido à sua relação com as emoções de um indivíduo, como foi discutido no Capítulo 3.

As variáveis para caracterização do contexto foram identificadas com uso da abordagem 5W 1H, considerando a relevância delas com relação ao erro e as emoções de um indivíduo. Os impactos das variáveis nos erros e, conseqüentemente no contexto, foram

obtidos com o modelo de regressão linear múltipla [50], como aprensetado no Capítulo 3. A regressão múltipla é um conjunto de técnicas estatísticas para construir modelos que descrevem de maneira razoável relações entre várias variáveis explicativas de um determinado processo [5]. Os resultados obtidos são apresentados na Seção 5.2.

Nessa etapa, os sinais cerebrais não foram usados no reconhecimento das emoções, devido à alguns problemas operacionais ocorridos durante o processo de aquisição, como dados de um participante que foram sobrescritos pelos de outro participante.

4.3 Etapa 3 do Etudo de Caso

Na terceira etapa do estudo de caso implementado neste trabalho tem-se o objetivo de analisar o método proposto no Capítulo 3, ilustrando a importância do reconhecimento das emoções de um indivíduo durante o desempenho de suas atividades. Para isso, o cenário escolhido foi o mesmo apresentado na Seção 4.2, assim como as tarefas desempenhadas pelos participantes e as ferramentas aplicadas aos mesmos.

O procedimento experimental se diferenciou do efetuado na Seção 4.2, apenas por uma etapa adicionada antes dos participantes desempenharem as tarefas propostas. Nessa etapa, pediu-se que os participantes focassem em um dos painéis do simulador e verificassem a ocorrência de alguma mudança na tensão ou corrente apresentadas no painel durante 10 minutos.

4.3.1 Participantes

Nesse estudo, o experimento foi realizado por uma amostra maior de indivíduos, nove participantes no total, sendo quatro mulheres e cinco homens, todos estudantes da graduação ou pós-graduação de Engenharia Elétrica. Um dos participantes desempenhou duas vezes cada uma das tarefas, em diferentes dias, para analisar o comportamento do indivíduo quando ocorre uma mudança de contexto.

4.3.2 Sinais Cerebrais

Os sinais cerebrais foram adquiridos de forma sequencial e com taxa de amostragem de 128 Hz a partir dos canais disponíveis no Emotiv, mas apenas os sinais do canal AF3 foram considerados para análise e são apresentados na Figura 4.20.

O sinais foram pré-processados pelo próprio equipamento que possui um filtro passa-faixa de quinta ordem com frequência de corte mínima de 0,2 Hz e máxima de 45 Hz , além de um filtro notch na frequência de 50 Hz e outro em 60 Hz , para remover os ruídos devido a rede de energia elétrica.




Figura 4.20: Amostra de sinal adquirida a partir do canal AF3

Os artefatos de eletrooculograma (EOG) se concentram em frequências inferiores a 4 Hz , e são mais proeminentes sobre a região anterior da cabeça [75], [43]. Já os artefatos de eletromiograma (EMG) possuem maior destaque em frequências superiores a 30 Hz [75], [43]. Como nesse trabalho foram consideradas apenas as características teta e alfa, cujas faixas de frequências são superiores a 4 Hz e inferiores a 30 Hz e foram considerados apenas os sinais provenientes da região pré-frontal da cabeça, não foi usada nenhuma técnica para remoção dos artefatos de EOG e EMG.

O processamento dos dados foi realizado de acordo com o método proposto na Seção 4.1.3. Primeiramente, os sinais pré-processados adquiridos a partir do canal AF3 foram divididos em segmentos de sessenta segundos. Em seguida, as características dos sinais de EEG de cada segmento foram selecionadas com a transformada *wavelet Daubechies 4*. Na Figura 4.21, apresentam-se exemplos dos gráficos que ilustram o sinal original, os detalhes D_1 (gama), D_2 (beta), D_3 (alfa) e D_4 (teta) e a aproximação A_4 (delta).

Após a obtenção de teta e alfa, foram calculados os valores da entropia e energia de cada amostra de sessenta segundos dos sinais de EEG do canal AF3. Nas Figuras 4.22 e 4.23 são apresentados os gráficos das entropias e energias de teta para um dos nove participantes, respectivamente.

Como pode ser observado, foram calculadas um total de trinta e oito entropias e trinta e oito energias para cada característica (teta ou alfa) para um dos participantes, porém essa quantidade pode variar já que o tempo de realização das tarefas é diferente para cada indivíduo.

As entropias e energias de cada participante foram usadas como entrada da rede neural artificial, como foi discutido na Seção 4.1.3. Os parâmetros da rede foram os mesmos do estudo de caso 1, apresentado na Seção 4.1.




Figura 4.21: Gráficos do sinal original, dos detalhes D_1 , D_2 , D_3 e D_4 e da aproximação A_4

Com o resultado da simulação da rede, obteve-se a matriz de confusão [87] com a porcentagem de erros e acertos da rede neural artificial. Na Figura 4.24 são apresentadas quatro matrizes de confusão, sendo que cada uma delas corresponde aos resultados obtidos a partir da classificação com um dos quatro vetores de entrada.

Os resultados apresentados nas matrizes são referentes à classificação dos sinais de EEG de um dos participantes em emoções. Pode-se observar que usando como entrada da rede o vetor com a energia de alfa ou de teta, obteve-se resultados insatisfatórios, 60,5 % e 44,7 %, respectivamente. Com o vetor com a entropia de alfa ou teta como entrada da rede, os resultados são bastante satisfatórios, 81,6 % e 86,8 %, respectivamente. Os procedimentos descritos anteriormente foram aplicados aos sinais de EEG dos nove participantes para classificação dos mesmos em emoções com o objetivo de verificar se os métodos utilizados para essa finalidade fornecem resultados satisfatórios (entre 80 % e 90 %). Os resultados de cada um dos participantes são apresentados no Apêndice C. Os resultados obtidos são discutidos no Capítulo 5.

4.3.3 Contexto

Com base nos dados coletados de cada participante e nos resultados obtidos na segunda etapa do estudo de caso, foi realizada a classificação do contexto em emoções. Para verificar os resultados alcançados na classificação, os dados foram analisados e foi efetuada uma avaliação da expressão proposta para o contexto na Seção 5.2.




Figura 4.22: Gráficos das entropias de teta

4.4 Síntese

Neste Capítulo, foram apresentadas as três etapas do estudo de caso implementado neste trabalho. A primeira delas foi realizada para verificar os métodos escolhidos para seleção e classificação das características dos sinais cerebrais em emoções. Os sinais de EEG não foram adquiridos no contexto deste trabalho, como visto no início desse Capítulo, foram usados os sinais de um banco de dados. Ainda na primeira etapa do estudo, foi mostrada a família de *wavelets Daubechies 4* usada na seleção das características teta e alfa dos sinais de EEG e foram definidos todos os parâmetros da rede neural, como visto na Seção 4.1.3.

Na segunda etapa do estudo de caso, foi definido um experimento para identificar as emoções de um indivíduo durante o desempenho de duas manobras no ambiente de simulação de uma sala de operação de uma subestação de energia. O objetivo na realização desse experimento foi avaliar a parte do método proposto no Capítulo 3 referente ao contexto do indivíduo, definindo-se os pesos de cada variável relevante para o contexto a partir de uma análise estatística. Na Seção 4.2.1, foram definidos os procedimentos realizados na etapa de pré-teste, como assinatura de termo concordância, aplicação de questionário e de teste psicológico. Na Seção 4.2.1, foram discutidos os procedimentos realizados durante o teste. Por fim, na Seção 4.2.1, foram apresentadas as ferramentas utilizadas na auto-avaliação realizada pelo participante sobre suas emoções e medição do nível da carga de trabalho.

Na terceira etapa do estudo de caso, realizou-se o mesmo experimento definido na segunda etapa, porém com uma amostra maior de participantes. O objetivo nessa etapa foi avaliar o método proposto no Capítulo 3.




Figura 4.23: Gráficos da energias de teta



Figura 4.24: Matrizes com porcentagens de erros e acertos na classificação dos sinais de EEG em emoções

Capítulo 5

Resultados Obtidos

5.1 Análise dos Resultados da Etapa 1 do Estudo de Caso

Para reconhecer as emoções de um indivíduo, nesta etapa do estudo de caso optou-se pelo uso dos sinais de EEG adquiridos apenas pelo canal AF3. A motivação para essa escolha foi a localização de tal canal, que se encontra na área pré-frontal do cérebro. Essa região cerebral está relacionada com as emoções humanas.

No total, foram processadas 1280 triagens de sinais de EEG incluindo os sinais de todos os trinta e dois participantes do experimento para o desenvolvimento do banco de dados [60]. As componentes teta e alfa desses sinais foram selecionadas e os valores para a energia e entropia de ambas componentes foram calculados e aplicados à rede neural. A rede neural foi treinada, validada e testada com cada um dos vetores aplicados à sua entrada.

Após a realização dos experimentos, a média e o desvio padrão da taxa de acertos foram calculados com base nos resultados obtidos para cada um dos trinta e dois participantes para cada tipo de emoção classificada. Na tabela 5.1, são apresentados os resultados para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção positivo/excitado.

Pode-se observar que a emoção positivo/excitado foi classificada com as médias das taxas de acertos 60,16%, 91,02%, 58,47% e 85,08% quando têm-se como informações do vetor de entrada da rede neural a energia da componente teta, a entropia da componente teta, a energia da componente alfa e a entropia da componente alfa, respectivamente. A maior taxa de acertos na classificação foi obtida com a entropia da componente teta, seguida pela entropia da componente alfa. A pior taxa de acertos obtida na classificação dos sinais cerebrais na emoção positivo/excitado foi com a aplicação do vetor com os valores da energia da componente alfa à entrada da rede neural.

Tabela 5.1: Valores de média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/excitado

Vetor	Média	Desvio Padrão
Teta (Energia)	60,16%	21,52%
Teta (Entropia)	91,02%	7,93%
Alfa (Energia)	58,47%	19,99%
Alfa (Entropia)	85,08%	12,67%

O desvio padrão é uma medida da dispersão dos dados, sendo que quanto mais próximo de zero, menos os dados variam em torno da média. Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 21,52% e 19,99%, respectivamente. Porém, quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 7,93% e 12,67%, respectivamente. Portanto, os resultados obtidos para os trinta e dois participantes possuem uma menor variação em torno da média apresentada na Tabela 5.1 quando considera-se os valores de entropia do que com os de energia como entrada da rede.

Esses resultados sugerem que usando apenas os sinais cerebrais no reconhecimento das emoções, é possível obter resultados satisfatórios (taxa de acertos superior a 80%) no reconhecimento da emoção positivo/excitado quando é considerado o vetor de dados de entropia de teta ou alfa como entrada da rede neural.

Na Tabela 5.2, são apresentados os resultados obtidos para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção positivo/calmo.

Tabela 5.2: Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/calmo

Vetor	Média	Desvio Padrão
Teta (Energia)	63,36%	27,29%
Teta (Entropia)	89,06%	13,76%
Alfa (Energia)	65,88%	25,63%
Alfa (Entropia)	87,67%	15,32%

Na Tabela 5.2, pode-se observar que a emoção positivo/calmo foi classificada com as médias das taxas de acertos de 63,36%, 89,06%, 65,88% e 87,67% quando têm-se como informações do vetor de entrada da rede neural os valores da energia para a componente teta, da entropia para a componente teta, da energia para a componente alfa e da entropia para a componente alfa, respectivamente. A melhor taxa de acertos na classificação

foi obtida com os valores da entropia para a componente teta, seguida pelos valores da entropia para a componente alfa. O pior resultado obtido na classificação dos sinais cerebrais na emoção positivo/calmo foi com a aplicação do vetor com os valores da energia da componente teta à entrada da rede neural.

Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 27,29% e 25,63%, respectivamente. Quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 13,76% e 15,32%, respectivamente. Portanto, os resultados obtidos para os trinta e dois participantes possuem uma menor variação em torno da média apresentada na Tabela 5.2 quando considera-se os valores de entropia do que com os de energia como entrada da rede. Ainda pode-se observar que existe uma maior variação em torno da média da taxa de acertos dos resultados obtidos no reconhecimento da emoção positivo/calmo do que do estado emocional positivo/excitado.

Da mesma forma que no reconhecimento da emoção positivo/excitado, é possível observar pelos resultados apresentados na Tabela 5.2 que foi alcançada uma taxa de acertos alta (superior a 80%) no reconhecimento da emoção positivo/calmo quando é considerado o vetor com os valores da entropia das componentes teta ou alfa como entrada da rede neural.

Na Tabela 5.3, são apresentados os resultados obtidos para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção negativo/excitado.

Tabela 5.3: Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/excitado

Vetor	Média	Desvio Padrão
Teta (Energia)	69,07%	25,15%
Teta (Entropia)	89,37%	8,77%
Alfa (Energia)	69,33%	27,29%
Alfa (Entropia)	87,67%	22,29%

Na Tabela 5.3, pode-se observar que a emoção negativo/excitado foi classificada com as médias das taxas de acertos de 69,07%, 89,37%, 69,33% e 87,67% quando têm-se como informações do vetor de entrada da rede neural os valores da energia da componente teta, da entropia para a componente teta, da energia da componente alfa e da entropia para a componente alfa, respectivamente. A melhor taxa de acertos na classificação foi obtida com os valores da entropia para a componente teta, seguida pelos resultados obtidos com os valores da entropia para a componente alfa. A pior taxa de acertos obtida na classificação dos sinais cerebrais na emoção positivo/calmo foi com a aplicação do vetor

com os valores da energia da componente teta à entrada da rede neural.

Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 25,15% e 27,29%, respectivamente. Quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 8,7759% e 22,29%, respectivamente. Portanto, os resultados obtidos para os trinta e dois participantes possuem uma menor variação em torno das médias apresentadas na Tabela 5.3 quando considera-se os valores de entropia do que com os de energia como entrada da rede.

Da mesma forma que no reconhecimento das duas emoções discutidas anteriormente, foi obtida uma taxa de acertos satisfatória (maior que 80%) nos resultados do reconhecimento da emoção negativo/excitado quando é considerado o vetor entrada com os valores de entropia para as componentes teta ou alfa.

Na Tabela 5.4, são apresentados os resultados obtidos para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção negativo/calmo.

Tabela 5.4: Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/calmo

Vetor	Média	Desvio Padrão
Teta (Energia)	77,49%	17,19%
Teta (Entropia)	87,49%	7,03%
Alfa (Energia)	79,66%	15,32%
Alfa (Entropia)	86,90%	17,27%

Na Tabela 5.4, pode-se observar que a emoção negativo/calmo foi classificada com as médias das taxas de acertos de 77,49%, 87,49%, 79,66% e 86,90% quando têm-se como informações do vetor de entrada da rede neural os valores da energia da componente teta, da entropia da componente teta, da energia para a componente alfa e da entropia para a componente alfa, respectivamente. A melhor taxa de acertos na classificação foi obtida com o vetor de entrada tendo como dados os valores da entropia da componente teta, seguida dos valores da entropia da componente alfa. O pior resultado obtido na classificação dos sinais cerebrais na emoção negativo/calmo foi com a aplicação do vetor com os valores da energia da componente teta à entrada da rede neural.

Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 17,19% e 15,32%, respectivamente. Quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 7,03% e 17,27%, respectivamente. Portanto, os resultados obtidos para os trinta e dois participantes possuem uma menor variação em torno das médias

apresentadas na Tabela 5.4 quando considera-se os valores de entropia do que com os de energia como entrada da rede.

Na detecção da emoção negativo/calmo foi obtida uma taxa de acertos aceitável (maior que 80%) nos resultados quando é considerado o vetor de entrada composto pelos valores da entropia das componentes teta ou alfa, da mesma forma que no reconhecimento das três outras emoções discutidas anteriormente.

As média das taxas de acertos dos resultados obtidos na classificação dos sinais cerebrais em todas as quatro emoções consideradas neste trabalho foram satisfatórias (acima de 80%) quando considera-se os vetores com os valores da entropia de alfa e teta como entrada da rede neural. Porém a taxa de acertos não é uma medida adequada para verificar o desempenho de um classificador, uma vez que pode produzir resultados enganosos se o conjunto de dados é assimétrico (isto é, quando o número de amostras em diferentes classes possuem uma grande variação). Para verificar a consistência da taxa de acertos, realizou-se uma análise mais detalhada dos resultados obtidos com as entropias de alfa e teta [86]. Para definição dos parâmetros usados na análise, considera-se a emoção positivo/excitado:

- Verdadeiros Positivos (TP): dados corretamente classificados como a emoção positivo/excitado [86].
- Falsos Positivos (FP): Dados que foram classificados como a emoção positivo/excitado, mas pertencem a outra classe de emoções [86].
- Verdadeiros Negativos (TN): dados corretamente classificados em outras classes de emoções que não seja a emoção positivo/excitado [86].
- Falsos Negativos (FN): dados que deveriam ser classificados na emoção positivo/excitado, mas foram incorretamente identificados como pertencentes à outras classes de emoções [86].
- Taxa de Verdadeiros Positivos (TPR) ou Sensibilidade: é uma medida da proporção de positivos reais, corretamente identificados como tais, e é complementar à taxa de falsos negativos [86].

$$TPR = \frac{TP}{P} = \frac{TP}{TP + FN} \quad (5.1)$$

- Especificidade (SPC) ou Taxa de Verdadeiros Negativos (TNR): é uma medida da proporção de negativos os quais são corretamente identificados como tais, e é complementar à taxa de falsos positivos [86].

$$SPC = \frac{TN}{N} = \frac{TN}{FP + TN} \quad (5.2)$$

- Precisão ou Valor Preditivo Positivo (PPV): é a proporção de resultados positivos em estatística e testes de diagnóstico que são resultados verdadeiros positivos [86].

$$PPV = \frac{TP}{TP + FP} \quad (5.3)$$

- Valor Preditivo Negativo (NPV): é a proporção de resultados negativos em estatística e testes de diagnóstico que são resultados verdadeiros negativos [86].

$$NPV = \frac{TN}{TN + FN} \quad (5.4)$$

- Taxa de Falsos Positivos (FPR): refere-se à proporção de falsos positivos [86].

$$FPR = \frac{FP}{FP + TN} \quad (5.5)$$

- Taxa de Detecção Falsa (FDR): é uma predição estatística do número de resultados que pode-se esperar que sejam falsos positivos [86].

$$FDR = \frac{FP}{FP + TP} = 1 - PPV \quad (5.6)$$

- Taxa de Falsos Negativos (FNP): refere-se à proporção de falsos negativos [86].

$$FNP = \frac{FN}{FN + TP} \quad (5.7)$$

- Acurácia (ACC): é a proximidade da medida relativamente ao verdadeiro valor da variável [86].

$$FPR = \frac{TP + TN}{P + N} = \frac{TP + TN}{(TP + FN) + (FP + TN)} \quad (5.8)$$

Considerando a média dos verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos obtidos a partir dos resultados dos trinta e dois participantes, calculou-se os valores para todos os parâmetros descritos anteriormente considerando-se as entropias de teta e alfa. Os resultados obtidos são apresentados nas Tabelas 5.5 e 5.6.

Tabela 5.5: Resultado da classificação das emoções com base na entropia de teta

TP	FP	FN	TN	TPR	SPC	PPV	NPV	FPR	FDR	FNP	ACC
8,906	1,094	1,094	28,906	0,891	0,964	0,891	0,964	0,036	0,109	0,109	0,945

Pode-se observar que os resultados nas duas Tabelas são muito próximos, com a acurácia obtida, aproximadamente 94%, superior aos 80% considerados nesta tese como uma boa acurácia, tem-se um resultado satisfatório para o reconhecimento das emoções com base nas entropias das características teta e alfa dos sinais de EEG.

Tabela 5.6: Resultado da classificação das emoções com base na entropia de alfa

TP	FP	FN	TN	TPR	SPC	PPV	NPV	FPR	FDR	FNP	ACC
8,742	1,265	1,250	28,742	0,875	0,958	0,874	0,958	0,042	0,126	0,125	0,937

5.2 Análise dos Resultados da Etapa 2 do Estudo de Caso

No segunda etapa do estudo de caso, para reconhecer as emoções, foi considerado apenas o contexto do usuário, sendo o principal objetivo nessa etapa a caracterização do contexto e o reconhecimento das emoções a partir dele. A partir dos dados coletados foram definidas as seguintes variáveis como relevantes para caracterização do contexto de acordo com a abordagem 5W 1H:

- “Quem?”: nível de conhecimento da tarefa, resultado do teste de atenção concentrada.
- “O que?”: nível de dificuldade das tarefas realizadas.
- “Por que?”: nenhuma informação considerada.
- “Quando?”: período do dia em que as tarefas foram realizadas.
- “Onde?”: local da realização da tarefa.
- “Como?”: número de horas dormidas, nível de carga de trabalho.

Primeiramente, os dados coletados a partir das diversas ferramentas usadas foram analisados. Todas as variáveis definidas como relevantes para o contexto foram colocadas em uma escala de 0 à 2, onde 0 representa o pior caso e 2 o melhor caso.

O nível de conhecimento da tarefa de cada participante foi observado no questionário preenchido na fase de pré-teste e foi classificado como: 0, para o nível baixo; 1, para o nível intermediário; e 2, para o nível de conhecimento alto. Já o resultado do teste de atenção concentrada foi obtido a partir da avaliação do teste D2 e foram categorizados como: 0, para déficit de atenção; 1, para precisão não acompanha rapidez; e 2, para precisão acompanha rapidez.

O nível de dificuldade das tarefas realizadas, apesar de ser uma variável importante na caracterização do contexto, não foi considerado na análise dos dados e nos resultados, pois é o mesmo para todos os participantes. O mesmo foi considerado para a variável local da realização da tarefa.

O período do dia em que as tarefas foram realizadas foi obtido no dia do teste de cada participante, de acordo com o horário em que o experimento foi realizado e foi classificado como: 0, para o período da manhã; 1, para o período da tarde; e 2, para o período da noite.

O número de horas dormidas foi previamente determinado para cada um dos participantes para induzir um certo nível de cansaço em alguns deles e foi categorizado como: 0, para 0 horas dormidas; 1, para 5 horas dormidas; e 2, para 8 horas dormidas.

O nível de carga de trabalho foi obtido a partir da análise do teste NASA-TLX, porém como todos os participantes não perceberam uma sobrecarga de trabalho durante o treinamento, essa variável também não foi considerada na análise dos dados e nos resultados. As variáveis consideradas e seus valores para cada participante são apresentadas na Tabela 5.7.

Tabela 5.7: Dados para análise da influência do contexto no desempenho do participante

Participante	Horas Dormidas	Nível de Conhecimento	Atenção Concentrada	Período do Dia	Número de Erros
1	0: zero horas	2: Alto	2: Precisão/ Rapidez	2: Manhã	5
2	2: oito horas	1: Médio	2: Precisão/ Rapidez	1: Tarde	9
3	0: zero horas	1: Médio	1: Rapidez	2: Manhã	11
4	1: cinco horas	1: Médio	2: Precisão/ Rapidez	1: Tarde	11
5	1: cinco horas	0: Baixo	1: Rapidez	0: Noite	13
6	2: oito horas	0: Baixo	1: Rapidez	2: Manhã	11

A variável “Horas Dormidas” representa o número de horas efetivamente dormidas pelo participante antes da realização do experimento. “Nível de Conhecimento” representa o conhecimento dos participantes com relação ao simulador. A “Atenção Concentrada” representa o nível de atenção inerente do indivíduo. Por último, o “Período de Dia” indica o horário que o teste foi realizado por cada indivíduo.

Os dados do contexto foram estatisticamente analisados para avaliar a correlação entre as variáveis, apesar de se tratar de uma pequena amostra [50]. Os métodos empregados foram: as matrizes de correlação e de p -valores, o teste de normalidade e a análise de regressão linear múltipla. Para a análise, definiu-se um nível de significância de 10 %, devido ao tamanho da amostra.

Para obter a matriz de correlação, calculou-se os coeficientes de correlação de Pearson das variáveis apresentadas na Tabela 5.7. O coeficiente de correlação de Pearson (p) mede o grau de correlação entre duas variáveis e tem valores que variam entre -1 e +1. O sinal

indica se a correlação é positiva ou negativa, ou seja, se as variáveis estão relacionados direta ou inversamente. Para $p > 0,7$, positivo ou negativo, há uma correlação forte; para $0,3 < p < 0,7$, positivo ou negativo, existe uma correlação moderada; e para $p < 0,3$, positivo ou negativo, não existe uma correlação [50].

A matriz de correlação é apresentada na Tabela 5.8. Com base nos valores apresentados, sugere-se que a correlação negativa entre o “Número de Erros” e o “Nível de Conhecimento” (cerca de -0,87) é significativa. Além disso, existe uma correlação moderada entre o “Número de Erros” e o restante das variáveis.

Tabela 5.8: Matriz de correlação de Pearson

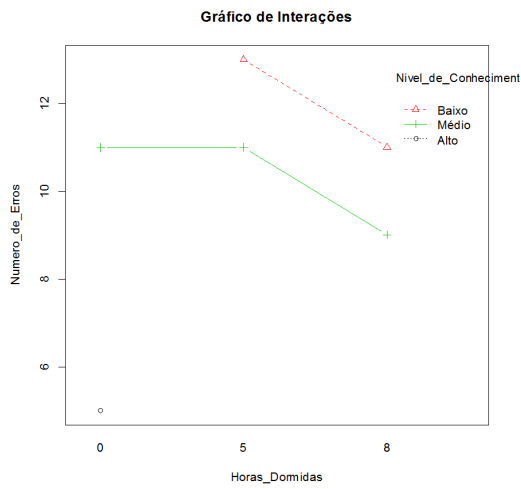
	Número de Erros	Horas Dormidas	Nível de Conhecimento	Atenção Concentrada	Período do Dia
Número de Erros	1,00000	0,40139	-0,86736	-0,66226	-0,53311
Horas Dormidas	0,40139	1,00000	-0,63699	0,00000	0,38399
Nível de Conhecimento	-0,86736	-0,63699	1,00000	0,72760	0,43386
Atenção Concentrada	-0,66226	0,00000	0,72760	1,00000	0,00000
Período do Dia	-0,53314	-0,38399	0,43386	0,00000	1,00000

Com o objetivo de dar suporte aos valores obtidos com a matriz de correlação, calculou-se a matriz de p -valores apresentada na Tabela 5.9. A correlação entre o “Número de Erros” e o “Nível de Conhecimento” é evidenciada pelo p -valor de 0,025, que corresponde ao nível de significância inferior a 10 %. No entanto, não se pode garantir a dependência entre as demais variáveis e o “Número de Erros”, pois os p -valores são maiores do que 0,10.


Tabela 5.9: Matriz de p -valores

	Número de Erros	Horas Dormidas	Nível de Conhecimento	Atenção Concentrada	Período do Dia
Número de Erros	1,00000	0,43024	0,02522	0,15183	0,27608
Horas Dormidas	0,43024	1,00000	0,17374	1,00000	0,45232
Nível de Conhecimento	0,02522	0,17374	1,00000	0,10119	0,39004
Atenção Concentrada	0,15183	1,00000	0,10119	1,00000	1,00000
Período do Dia	0,27608	0,45232	0,39004	1,00000	1,00000


Os gráficos de interações para verificar a interação entre cada par de variáveis são apresentados na Figura 5.1.




(a) “Nível de Conhecimento”/“Horas Dormidas”/“Números de Erros”




(b) “Atenção Concentrada”/“Horas Dormidas”/“Números de Erros”



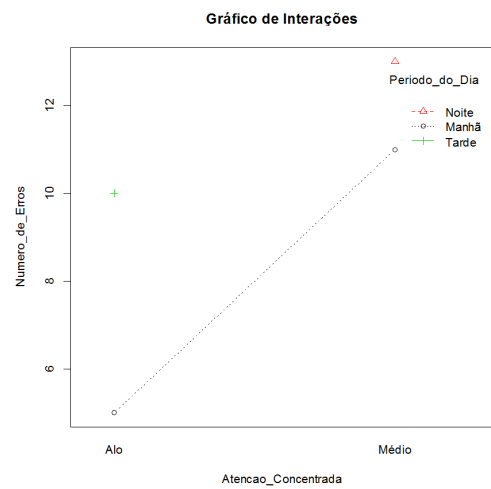
(c) “Período do Dia”/“Horas Dormidas”/“Números de Erros”



(d) “Nível de Conhecimento”/“Atenção Concentrada”/“Números de Erros”



(e) “Período do Dia”/“Nível de Conhecimento”/“Números de Erros”




(f) “Período do Dia”/“Atenção Concentrada”/“Números de Erros”

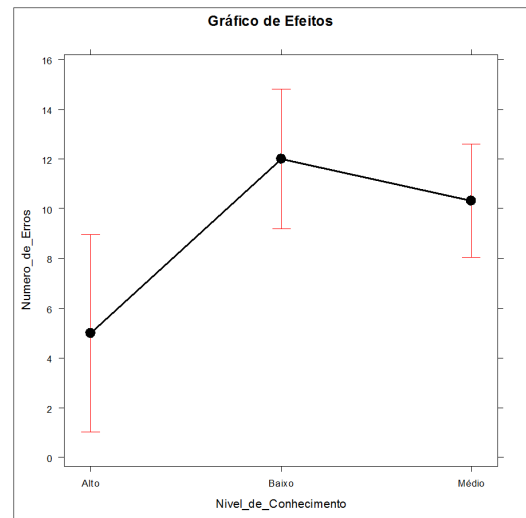
Figura 5.1: Gráficos de interações

A partir do gráfico de interação mostrado na Figura 5.1a, pode-se observar que a variável “Nível de Conhecimento” tem um impacto maior sobre o número de erros do que a variável “Horas Dormidas”. No entanto, a combinação das duas variáveis tem um impacto maior sobre o “Número de Erros”. Nas Figuras 5.1b, 5.1c, 5.1d, 5.1e e 5.1f pode ser observado que as variáveis “Atenção Concentrada” e “Período do Dia” não têm influência significativa sobre a incidência de erros.


Uma outra ferramenta usada neste estudo foram os gráficos de efeitos para ilustrar a relação entre o “Número de Erros” e as demais variáveis, e são apresentados na Figura 5.2.



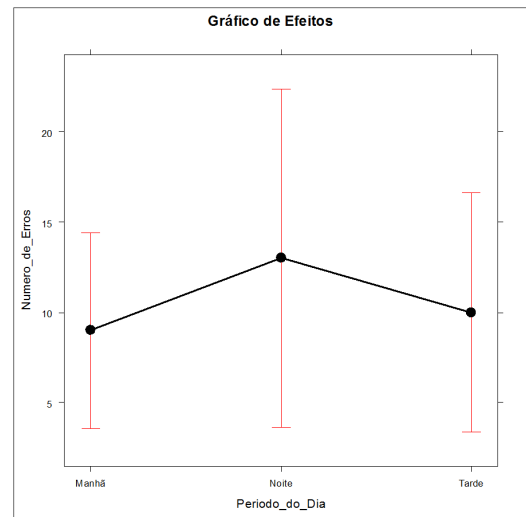
(a) “Horas Dormidas” x “Números de Erros”



(b) “Nível de Conhecimento” x “Números de Erros”



(c) “Atenção Concentrada” x “Números de Erros”



(d) “Período do Dia” x “Números de Erros”

Figura 5.2: Gráficos de efeitos

Pode ser observado a partir dos gráficos, que o “Nível de Conhecimento” e a “Atenção Concentrada” têm o maior impacto sobre o desempenho do participante. Quanto maior

o “Nível de Conhecimento” do participante no simulador, menor o “Número de Erros” durante a execução de tarefas.

Para definir o modelo a ser usado para identificação do impacto das variáveis “Nível de Conhecimento”, “Horas Dormidas”, “Atenção Concentrada” e “Período do Dia”, aplicou-se o teste de normalidade realizado para verificar se os erros cometidos pelos participantes seguem uma distribuição normal. Os resultados obtidos são: Estatística de *Shapiro-Wilk* igual a 0,856559154 e o *p*-valor igual a 0,177670299. Como o *p*-valor é 17,77%, aceitou-se a hipótese de normalidade. Assim, com nível de confiança de 95%, têm-se evidências de que os dados seguem uma distribuição normal. A partir do gráfico apresentado na Figure 5.3, também pode-se ver que os dados se aproximam da reta e, portanto, seguem uma distribuição normal.




Figura 5.3: Teste de normalidade

Como os dados seguem uma distribuição normal, foi definido um modelo de regressão linear múltipla [50] para os dados usados neste experimento. Nesses modelos é necessária a definição de um subconjunto de variáveis independentes que melhor expliquem o comportamento da variável resposta, dentre todas as variáveis explicativas disponíveis. Para a seleção dessas variáveis, usou-se a técnica de seleção de todos os modelos do software de análise estatística *Action* [7]. O modelo mais adequado para análise dos erros é definido da seguinte forma:

$$\begin{aligned} \text{NumerodeErros} = & \beta_1 \text{HorasDormidas} + \beta_2 \text{NiveldeConhecimento} \\ & + \beta_3 \text{NiveldeAtencao} + \beta_3 \text{PeriododoDia} \end{aligned} \quad (5.9)$$

Onde, *NumerodeErros*, é a variável de saída; β_1 , indica uma mudança na resposta média a cada unidade de mudança na variável *HorasDormidas*, quando as demais variáveis são mantidas fixas; β_2 , indica uma mudança na resposta média a cada unidade de mudança na variável *NiveldeConhecimento* quando as demais variáveis são mantidas fixas; β_3 , indica uma mudança na resposta média a cada unidade de mudança na variável *NiveldeAtencao* quando as demais variáveis são mantidas fixas; e β_4 , indica uma mudança na resposta média a cada unidade de mudança na variável *PeriododoDia* quando as demais variáveis são mantidas fixas.

Para verificar se o modelo definido é o mais adequado e se as variáveis explicativas são significativas para variação da variável dependente, testou-se a hipótese nula de que os coeficientes para estas variáveis são nulos:

$$\begin{aligned}
 H_0 : \beta_1, \beta_2, \beta_3, \beta_4 &= 0 \\
 H_1 : \beta_1, \beta_2, \beta_3, \beta_4 &\neq 0
 \end{aligned}
 \tag{5.10}$$

Os resultados do teste podem ser observados nas Tabelas 5.10, 5.11, 5.12 e 5.13.

Tabela 5.10: Análise de Variância

Fatores	Graus de Liberdade	Soma dos Quadrados	Quadrado Médio	Estat. F	p-valor
Horas Dormidas	1	409,60000	409,60000	24,45373	0,03854
Nível de Conhecimento	1	77,90819	77,90819	4,65123	0,09354
Nível de/ Atenção	1	60,65846	60,65846	3,62140	0,09875
Período do Dia	1	56,33333	56,33333	3,36318	0,20811
Resíduos	2	33,50000	16,75000	-	-

Tabela 5.11: Análise Exploratória (Resíduos)

Mínimo	1Q	Média	Mediana	3Q	Máximo
-2,58300	-1,64600	0,20800	0,36110	2,37500	3,50000

Analisando a Tabela 5.10 pode-se afirmar que as variáveis “Horas Dormidas”, “Nível de Conhecimento” e “Nível de Atenção” são significativas para o modelo uma vez que o p-valor para os três coeficientes foram maiores do que o nível de significância de 0,10.

Na Tabela 5.11 apresenta-se uma análise descritiva dos resíduos do modelo, contendo os valores dos quartis, máximos e mínimos, média e mediana.

Tabela 5.12: Coeficientes do modelo de regressão linear

Preditor	Estimativa	Desvio Padrão	Estat. F	p-valor
Horas Dormidas	-6,33333	4,72581	-1,34015	0,31215
Nível de Conhecimento	-17,91666	8,39580	-2,13400	0,09892
Nível de Atenção	16,75000	6,93947	2,41372	0,09987
Período/ do Dia	4,33333	2,36290	1,83389	0,20811

Tabela 5.13: Desvio Padrão dos Resíduos

Desvio Padrão dos Resíduos	Graus de Liberdade	R^2	R^2 Ajustado
4,09267	2	0,94749	0,84247

Na Tabela 5.12 têm-se as estimativas dos coeficientes relacionados às variáveis de entrada. Como os coeficientes das variáveis “Horas Dormidas” e “Nível de Conhecimento” são negativos, concluiu-se que no intervalo da análise, um aumento destas provoca uma redução na variável dependente Erros. Com relação ao “Nível de Atenção”, uma diminuição dele provoca um aumento no número de erros. A Tabela apresenta também os p -valores para cada coeficiente. A hipótese nula é que os coeficientes das variáveis são não significativos. Como os valores calculados para as variáveis “Nível de Conhecimento” e “Nível de Atenção” foram menores do que o nível de significância de 0,10 pode-se rejeitar a hipótese nula para esses coeficientes, podendo-se afirmar que essas variáveis são importantes para o modelo. O mesmo não acontece para as variáveis “Horas Dormidas” e “Período do Dia”.

Na Tabela 5.13 apresenta-se o valor de R^2 Ajustado com o qual se pode avaliar a qualidade do ajuste do modelo. Dado seu valor, de 0,84247, tem-se que cerca de 84% da variabilidade dos dados é explicada pelo modelo de regressão ajustado, e assim, tem-se um indício de que o modelo se ajustou bem ao conjunto de dados.

Com base nos resultados obtidos, têm-se indícios de que os erros cometidos pelos participantes no desempenho de uma tarefa são dependentes, principalmente, do nível de experiência e do nível de atenção do indivíduo. Apesar disso, na definição do modelo para identificação do contexto considerou-se o período do dia em que a atividade foi realizada e as horas dormidas pelo participante, considerando que os mesmos possuem uma menor influência. Como cada fator tem um impacto diferente na variável dependente, como foi visto no modelo de regressão linear, e foi definido no Capítulo 3 que o contexto é uma média ponderada dos diversos fatores considerados, tem-se a seguinte equação para o

contexto no cenário considerado neste estudo de caso:

$$C = \frac{w_1HD + w_2NC + w_3AC + w_4PD}{w_1 + w_2 + w_3 + w_4} \quad (5.11)$$

onde, C é o contexto; w_1, w_2, w_3 e w_4 são os pesos das variáveis e estão relacionados com a influência destas nos erros; HD é a variável “Horas Dormidas”; NC é o “Nível de Conhecimento”; AC é a variável “Atenção Concentrada”; e PD é o “Período do Dia”.

Os pesos das variáveis foram determinados pelo modelo de regressão linear e são o módulo das estimativas dos coeficientes. De acordo com os resultados obtidos, a variável que possui maior influência no contexto é o “Nível de Conhecimento, seguida pelo “Nível de Atenção, “Horas Dormidas” e “Período do Dia” . Por essa razão, considerou-se os seguintes pesos 6, 18, 16, 4 para w_1, w_2, w_3 e w_4 , respectivamente.

Na Tabela 5.14 são apresentados os resultados obtidos na classificação do contexto em emoções dos participantes.

Tabela 5.14: Resultado da classificação do Contexto em emoções

Participantes	Contexto	Emoções
1	1,72	Positivo
2	1,50	Positivo
3	0,95	Negativo
4	1,36	Positivo
5	0,50	Negativo
6	0,81	Negativo

Pode-se observar que usando o modelo proposto neste trabalho para determinar as emoções de um indivíduo, os participantes que cometeram menos erros tiveram suas emoções classificadas como positivas.

5.3 Análise dos Resultados da Etapa 3 do Estudo de Caso

No terceira etapa do estudo de caso, para reconhecer as emoções, foram considerados os sinais cerebrais e o contexto do usuário, com o objetivo de avaliar o método proposto no Capítulo 3. O experimento foi a realização de duas tarefas desempenhadas no dia a dia por operadores em uma sala de operação de uma subestação de energia. As tarefas foram realizadas em um simulador por nove participantes, que tiveram seus dados coletados a partir de diversas ferramentas como discutido na Seção 4.2.

Primeiramente, os dados coletados a partir das diversas ferramentas usadas foram analisados e todas as variáveis definidas como relevantes para o contexto foram colocadas

em uma escala de 0 à 2, onde 0 representa o pior caso e 2 o melhor caso como na Seção 5.2.

A variável nível de carga de trabalho foi considerada, devido à percepção de uma sobrecarga de trabalho por alguns participantes, sendo considerada: 0, para uma carga de trabalho alta; e 2 para uma carga de trabalho baixa. As variáveis consideradas e seus valores para cada participante são apresentadas na Tabela 5.15.

Tabela 5.15: Dados para análise da influência do contexto no desempenho do participante

Participante	Horas Dormidas	Nível de Conhecimento	Atenção Concentrada	Período do Dia	Carga de Trabalho
1	1: 4 horas	2: Alto	2: Precisão/ Rapidez	2: Manhã	2: Baixa
2	2: 8 horas	0: Baixo	2: Precisão/ Rapidez	0: Noite	0: Alta
3	1: 4 horas	1: Médio	2: Precisão/ Rapidez	1: Tarde	2: Baixa
4	1: 8 horas	2: Alto	2: Precisão	2: Manhã	0: Alta
5	1: 4 horas	0: Baixo	1: Rapidez	2: Manhã	2: Baixa
6	2: 8 horas	0: Baixo	1: Rapidez	2: Manhã	2: Baixa
7	1: 4 horas	1: Médio	1: Rapidez	2: Manhã	2: Baixa
8	2: 8 horas	2: Alto	1: Rapidez	2: Manhã	2: Baixa
9	2: 8 horas	0: Baixo	1: Precisão/	2: Manhã	2: Baixa
9	1: 4 horas	2: Alto	1: Precisão/	1: Tarde	2: Baixa

O participante 9 aparece duas vezes na Tabela 5.15, pois o mesmo realizou o experimento duas vezes em dias diferentes, com 8 horas dormidas no primeiro dia de teste e 4 horas dormidas no segundo dia. No primeiro dia de teste o participante não tinha conhecimento do simulador, porém no segundo dia considerou-se um conhecimento alto, pois o mesmo realizou as mesmas tarefas do primeiro dia. Essa situação foi definida para avaliar o impacto da mudança de contexto para um mesmo indivíduo. Por essa razão, três das variáveis passíveis de mudanças (“Horas Dormidas”, “Nível de Conhecimento” e “Período do Dia”) tiveram valores diferentes em cada um dos dois testes.

Com base nos resultados obtidos na Seção 5.2 para o método usado na caracterização do contexto e nas informações apresentadas na Tabela 5.15, têm-se os resultados para a classificação do contexto dos participantes em emoções, que são apresentados na Tabela 5.16.

Pode-se observar que três dos participantes estão em um estado emocional negativo e, por essa razão, mais susceptíveis a cometer erros do que os participantes em um estado emocional positivo. Além disso, dois dos participantes estão em um estado neutro. O participante 9 aparece duas vezes na Tabela 5.16, sendo que na primeira situação ele aparece no estado emocional negativo, enquanto na segunda ele está no estado positivo devido às mudanças no seu contexto discutidas anteriormente.

Com as informações disponíveis no *log* do simulador, banco de dados usado para

Tabela 5.16: Resultado da classificação do contexto em emoções

Participantes	Contexto	Emoções
1	1,86	Positivo
2	1,00	Neutro
3	1,36	Positivo
4	1,63	Positivo
5	0,68	Negativo
6	0,82	Negativo
7	1,09	Neutro
8	1,63	Positivo
9	0,82	Negativo
9	1,41	Positivo

armazenar todas as ações realizadas pelos participantes durante o teste, e com base nas tarefas descritas no roteiro de testes no Apêndice D, obteve-se o número de erros cometidos por cada um dos participantes durante a realização das duas manobras no SimuLIHM. O “Número de Erros e as emoções de cada um dos participantes estão apresentados na Tabela 5.17.

Tabela 5.17: Número de erros cometidos pelos participantes

Participantes	Número de Erros	Emoções
1	4	Positivo
2	11	Neutro
3	4	Positivo
4	1	Positivo
5	15	Negativo
6	12	Negativo
7	6	Neutro
8	6	Positivo
9	13	Negativo
9	4	Positivo

Pode-se observar que apenas um participante no estado emocional neutro cometeu muitos erros (onze erros), se comparado ao restante dos participantes. Os participantes no estado emocional negativo cometeram uma série de erros, quinze, doze e treze. O participante 9 cometeu treze erros quando estava no estado emocional negativo e apenas quatro no estado positivo, o que mostra evidências da influência das emoções na qualidade do trabalho que um indivíduo realiza.

Com os dados dos participantes apresentados na Tabela 5.15 e o “Número de Erros” e as “Emoções” apresentados na Tabela 5.17, realizou-se uma análise estatística como a

mostrada na Seção 5.2 para comprovar a influência das emoções nos erros cometidos pelos participantes, como discutido anteriormente, e verificar a influência da “carga de trabalho” obtida a partir do teste NASA-TLX. Além disso, as variáveis testadas na Seção 5.2, foram consideradas novamente na análise para verificar a consistência dos resultados obtidos no segundo estudo de caso considerando uma amostra maior e mais homogênea.

Na análise estatística, considerando um nível de significância de 10%, primeiramente calculou-se a matriz de *Pearson* apresentada na Tabela 5.18.

Tabela 5.18: Matriz de correlação de Pearson

	Número de Erros	Horas Dormidas	Nível de Conhec.	Atenção Concent.	Período do Dia	Carga de Trabalho	Emoções
Número de Erros	1,00000	0,22230	-0,89460	-0,47190	0,01340	0,17780	-0,92290
Horas Dormidas	0,22230	1,00000	-0,22360	0,00000	0,00000	-0,50000	-0,22940
Nível de Conhec.	-0,89460	-0,22360	1,00000	0,22820	0,16850	0,00000	0,89770
Atenção Concent.	-0,47180	0,00000	0,22820	1,00000	-0,43080	-0,61240	0,51510
Período do Dia	0,01340	0,00000	0,16850	-0,43080	1,00000	0,45230	-0,20750
Carga de Trabalho	0,17780	-0,50000	0,00000	0,61240	0,45220	1,00000	-0,17200
Emoções	-0,92290	-0,22940	0,89770	0,51510	-0,20750	-0,17210	1,00000

A partir dos resultados obtidos, pode-se observar que existe uma forte correlação entre as “Emoções” e o “Número de Erros”, coeficiente de *Pearson* igual a -0,9229. O sinal negativo nesse caso indica que quando o participante tem suas emoções classificadas como negativas, a quantidade de erros cometidos é muito superior a quando as emoções são classificadas como positivas. O resultado obtido na Seção 5.2 para a correlação entre o “Número de Erros” e o “Nível de Conhecimento” foi comprovado neste estudo, como pode ser observado a partir do coeficiente de *Pearson* igual a -0,8946, que indica que existe uma forte correlação. Pode-se observar também, uma correlação moderada entre o “Nível de Atenção” e o “Número de Erros” com o coeficiente de *Pearson* igual a -0,4718. Para o restante das variáveis obteve-se uma fraca correlação entre as mesmas e o “Número de Erros”. Também pode-se ver que existe uma fraca correlação entre as “Emoções” e todas as variáveis, com exceção do “Nível de Conhecimento” e do “Nível de Atenção”.

Os níveis de significância dos valores obtidos na correlação entre as variáveis foram calculados e estão apresentados na matriz *p*-valores na Tabela 5.19.

Pode-se observar a partir dos resultados mostrados na matriz *p*-valores que com um nível de significância de 0,00010, inferior ao nível considerado de 0,1, evidencia-se uma forte correlação entre o “Número de Erros” e as “Emoções”, como foi proposto na Seção 5.2 quando foi definida a expressão que caracteriza o contexto com base nos erros. Além disso,

Tabela 5.19: Matriz de p -valores

	Número de Erros	Horas Dormidas	Nível de Conhec.	Atenção Concent.	Período do Dia	Carga de Trabalho	Emoções
Número de Erros	1,00000	0,53710	0,00050	0,16850	0,97070	0,62310	0,00010
Horas Dormidas	0,53710	1,00000	0,53450	1,00000	1,00000	0,14110	0,52370
Nível de Conhec.	0,00050	0,53450	1,00000	0,52970	0,64160	1,00000	0,00040
Atenção Concent.	0,16850	1,00000	0,52590	1,00000	0,21380	0,05980	0,12780
Período do Dia	0,97070	1,00000	0,64160	0,21380	1,00000	0,18940	0,56510
Carga de Trabalho	0,62310	0,14110	1,00000	0,59840	0,18940	1,00000	0,63460
Emoção	0,00010	0,52370	0,00040	0,56110	0,63450	1,00000	1,00000

com um nível de significância de 0,00050, a forte correlação entre o “Número de Erros” e o “Nível de Conhecimento” apresentada na matriz de *Pearson* é evidenciada, comprovando o resultado obtido no estudo de caso 2. A partir do p -valor de 0,00040, também confirma-se uma forte correlação entre as “Emoções” e o “Nível de Conhecimento”, o que era esperado, já que essa variável é a que possui maior influência na caracterização do contexto e, consequentemente, na classificação do mesmo em emoções.

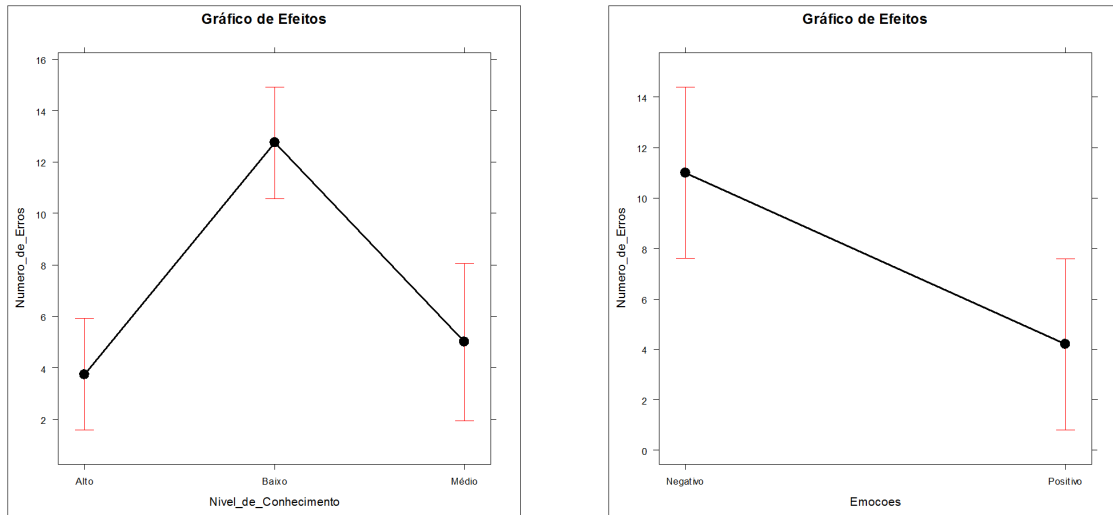
A ferramenta gráficos de efeitos foi usada para mostrar de forma gráfica a relação entre o “Nível de Conhecimento” e o “Número de Erros, devido à forte correlação existente entre eles. Além disso, foi traçado o gráfico de efeitos para ilustrar a relação entre as “Emoções” e o “Número de Erros”. Os gráficos de efeitos são apresentados na Figura 5.4.

Pode-se observar no gráfico apresentado na Figura 5.4a, que quando a variável “Nível de Conhecimento” é classificada como um nível alto, o número de erros é menor do que quando é classificada como um nível baixo. Com esse resultado, têm-se indícios de que quanto maior o nível de conhecimento, melhor a qualidade do trabalho desempenhado e menor o número de erros cometidos pelos participantes.

Na Figura 5.4b, pode-se ver que existe uma relação entre o “Número de Erros” e as “Emoções”, sendo que os participantes no estado emocional negativo cometeram mais erros do que os indivíduos no estado positivo, como esperado com a discussão apresentada na Seção 5.2 sobre o contexto.

Como discutido na Seção 4.3, os sinais de EEG adquiridos a partir do canal AF3 foram considerados no reconhecimento das emoções nesse estudo. Os sinais coletados de cada um dos participantes foram divididos em amostras de sessenta segundos.

Na classificação dos sinais de EEG em emoções, foram considerados os vetores com as entropias e energias de alfa e teta como entrada da rede neural, como discutido na Seção 4.3. Todas as amostras foram processadas de acordo com o método definido na



(a) “Nível de Conhecimento” x “Números de Erros”

(b) “Emoções” x “Números de Erros”

Figura 5.4: Gráficos de efeitos

Seção 3. Os sinais foram classificados nas emoções positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo.

A média e o desvio padrão da taxa de acertos foram calculados com base nos resultados obtidos para cada um dos participantes para cada tipo de emoção classificada. Na tabela 5.20, são apresentados os resultados para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção positivo/excitado.

Tabela 5.20: Valores de média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/excitado

Vetor	Média	Desvio Padrão
Teta (Energia)	62,08%	30,18%
Teta (Entropia)	80,25%	34,12%
Alfa (Energia)	63,33%	29,83%
Alfa (Entropia)	82,25%	23,06%

Pode-se observar que a emoção positivo/excitado foi classificada com as médias das taxas de acertos 62,08%, 80,25%, 63,33% e 82,25% quando têm-se como informações do vetor de entrada da rede neural a energia da componente teta, a entropia da componente teta, a energia da componente alfa e a entropia da componente alfa, respectivamente. A maior taxa de acertos na classificação foi obtida com a entropia da componente alfa, seguida pela entropia da componente teta. A pior taxa de acertos obtida na classificação dos sinais cerebrais na emoção positivo/excitado foi com a aplicação do vetor com os

valores da energia da componente teta à entrada da rede neural.

Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 30,18% e 29,83%, respectivamente. Quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 34,12% e 23,06%, respectivamente. Portanto, os resultados obtidos para os participantes possuem uma variação alta em torno da média apresentada na Tabela 5.20 quando considera-se qualquer um dos parâmetros como entrada da rede.

Esses resultados sugerem que usando apenas os sinais cerebrais no reconhecimento das emoções, é possível obter resultados satisfatórios (taxa de acertos superior a 80%) no reconhecimento da emoção positivo/excitado quando é considerado o vetor de dados de entropia de teta ou alfa como entrada da rede neural.

Na Tabela 5.21, são apresentados os resultados obtidos para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção positivo/calmo.

Tabela 5.21: Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção positivo/calmo

Vetor	Média	Desvio Padrão
Teta (Energia)	61,88%	34,88%
Teta (Entropia)	82,07%	30,57%
Alfa (Energia)	72,97%	27,86%
Alfa (Entropia)	80,57%	24,44%

Pode-se observar que a emoção positivo/calmo foi classificada com as médias das taxas de acertos 61,88%, 82,07%, 72,97% e 80,57% quando têm-se como informações do vetor de entrada da rede neural a energia da componente teta, a entropia da componente teta, a energia da componente alfa e a entropia da componente alfa, respectivamente. A maior taxa de acertos na classificação foi obtida com a entropia da componente teta, seguida pela entropia da componente alfa. A pior taxa de acertos obtida na classificação dos sinais cerebrais na emoção positivo/calmo foi com a aplicação do vetor com os valores da energia da componente teta à entrada da rede neural.

Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 34,88% e 27,86%, respectivamente. Quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 30,57% e 24,44%, respectivamente. Portanto, os resultados obtidos para os participantes possuem uma variação alta em torno da média apresentada na Tabela 5.21 quando considera-se qualquer um dos parâmetros como entrada da rede.

Da mesma forma que no reconhecimento da emoção positivo/excitado, é possível observar pelos resultados apresentados na Tabela 5.2 que foi alcançada uma taxa de acertos

alta (superior a 80%) no reconhecimento da emoção positivo/calmo quando é considerado o vetor com os valores da entropia das componentes teta ou alfa como entrada da rede neural.

Na Tabela 5.22, são apresentados os resultados obtidos para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção negativo/excitado.

Tabela 5.22: Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/excitado

Vetor	Média	Desvio Padrão
Teta (Energia)	64,01%	37,96%
Teta (Entropia)	81,67%	29,15%
Alfa (Energia)	61,83%	40,28%
Alfa (Entropia)	81,66%	19,13%

Pode-se observar que a emoção negativo/excitado foi classificada com as médias das taxas de acertos 64,01%, 81,67%, 61,83% e 81,66% quando têm-se como informações do vetor de entrada da rede neural a energia da componente teta, a entropia da componente teta, a energia da componente alfa e a entropia da componente alfa, respectivamente. A maior taxa de acertos na classificação foi obtida com a entropia da componente teta, seguida pela entropia da componente alfa. A pior taxa de acertos obtida na classificação dos sinais cerebrais na emoção negativo/excitado foi com a aplicação do vetor com os valores da energia da componente alfa à entrada da rede neural.

Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 37,96% e 40,28%, respectivamente. Quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 29,15% e 19,13%, respectivamente. Portanto, os resultados obtidos para os participantes possuem uma variação alta em torno da média apresentada na Tabela 5.22 quando considera-se qualquer um dos parâmetros como entrada da rede.

Da mesma forma que no reconhecimento das duas emoções discutidas anteriormente, foi obtida uma taxa de acertos satisfatória (maior que 80%) nos resultados do reconhecimento da emoção negativo/excitado quando é considerado o vetor entrada com os valores de entropia para as componentes teta ou alfa.

Na Tabela 5.23, são apresentados os resultados obtidos para a média e o desvio padrão das taxas de acertos obtidas na classificação dos sinais cerebrais na emoção negativo/calmo.

Pode-se observar que a emoção negativo/calmo foi classificada com as médias das taxas de acertos 78,41%, 80,75%, 82,14% e 81,16% quando têm-se como informações do

Tabela 5.23: Valores para a média e desvio padrão dos resultados relacionados ao reconhecimento da emoção negativo/calmo

Vetor	Média	Desvio Padrão
Teta (Energia)	78,41%	26,15%
Teta (Entropia)	80,75%	20,78%
Alfa (Energia)	82,14%	22,45%
Alfa (Entropia)	81,16%	16,90%

vetor de entrada da rede neural a energia da componente teta, a entropia da componente teta, a energia da componente alfa e a entropia da componente alfa, respectivamente. A maior taxa de acertos na classificação foi obtida com a energia da componente alfa, seguida pela entropia da componente alfa. A pior taxa de acertos obtida na classificação dos sinais cerebrais na emoção negativo/calmo foi com a aplicação do vetor com os valores da energia da componente teta à entrada da rede neural.

Quando aplica-se os vetores com os valores da energia das componentes teta ou alfa à entrada da rede têm-se os desvios padrões de 37,96% e 40,28%, respectivamente. Quando tem-se como entrada da rede os vetores com os valores da entropia das componentes teta ou alfa, os desvios são 29,15% e 19,13%, respectivamente. Portanto, os resultados obtidos para os participantes possuem uma variação alta em torno da média apresentada na Tabela 5.23 quando considera-se qualquer um dos parâmetros como entrada da rede.

Na detecção da emoção negativo/calmo foi obtida uma taxa de acertos aceitável (maior que 80%) nos resultados quando é considerado o vetor de entrada composto pelos valores da entropia das componentes teta ou alfa e de energia da componente alfa.

Da mesma forma que na Seção 5.1, para verificar a consistência da taxa de acertos, realizou-se uma análise mais detalhada dos resultados obtidos com as entropias de alfa e teta [86]. Considerando a média dos verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos obtidos a partir dos resultados dos participantes, calculou-se os valores para todos os parâmetros descritos na Seção 5.1 considerando-se as entropias de teta e alfa. Os resultados obtidos são apresentados nas Tabelas 5.24 e 5.25.

Tabela 5.24: Resultado da classificação das emoções com base na entropia de teta

TP	FP	FN	TN	TPR	SPC	PPV	NPV	FPR	FDR	FNP	ACC
19,812	5,185	5,120	69,8825	0,795	0,931	0,792	0,931	0,069	0,208	0,205	0,897

Pode-se observar que os resultados nas duas Tabelas são muito próximos. Com a acurácia obtida, aproximadamente 89%, superior aos 80% considerados nesta tese como uma boa acurácia, tem-se um resultado satisfatório para o reconhecimento das emoções

Tabela 5.25: Resultado da classificação das emoções com base na entropia de alfa

TP	FP	FN	TN	TPR	SPC	PPV	NPV	FPR	FDR	FNP	ACC
19,635	5,607	5,607	69,175	0,778	0,925	0,778	0,925	0,075	0,222	0,222	0,888

com base nas entropias das características teta e alfa dos sinais de EEG.

Um resumo dos resultados obtidos relacionando as emoções sentidas pelos participantes com a ocorrência de erros quando considerada a entropia de teta no reconhecimento das emoções é apresentado na Figura 5.5. Nessa Figura, a legenda Positivo corresponde ao estado emocional positivo e a legenda Negativo corresponde ao estado negativo. O eixo x do gráfico representa os participantes do experimento e o eixo y, o número de erros cometidos por eles.




Figura 5.5: Resultados obtidos a partir da entropia de teta

A partir dos resultados apresentados, tem-se que 73,70% dos erros cometidos por todos os participantes ocorreram durante o estado emocional negativo quando considerado o vetor com os valores das entropias de teta como entrada da rede neural.

Um resumo dos resultados obtidos relacionando as emoções sentidas pelos participantes com a ocorrência de erros quando considerada a entropia de alfa no reconhecimento das emoções é apresentado na Figura 5.6.

Pode-se observar a partir dos resultados apresentados que os participantes cometeram 77,63% dos erros durante o sentimento de uma emoção negativa, quando considerado o vetor com os valores das entropias de alfa como entrada da rede neural. Como discutido




Figura 5.6: Resultados obtidos a partir da entropia de teta

na Seção 5.2, durante o sentimento de uma emoção negativa, o ser humano está mais susceptível a cometer erros, o que pode ser observado nos resultados obtidos nas Figuras 5.5 e 5.6.

Nas Tabelas 5.26 e 5.27 são apresentados os resultados para o reconhecimento das emoções com base nos sinais de EEG e no contexto, considerando-se as entropias de teta e alfa, respectivamente. A classificação dos sinais de EEG em emoções é apresentada na coluna sinais cerebrais das Tabelas. Ela foi obtida a partir da quantidade de amostras de sessenta segundos classificadas em cada emoção, sendo que a emoção predominante é a apresentada.

Pode-se observar que a maior parte dos participantes que tiveram suas emoções classificadas como positivas a partir dos sinais cerebrais, também tiveram suas emoções classificadas como positivas a partir dos resultados obtidos para o contexto. Do mesmo modo, a maior parte dos participantes que tiveram suas emoções classificadas como negativas, tiveram suas emoções classificadas como negativas a partir do contexto, considerando-se as entropias de teta ou alfa. Com os resultados obtidos nesse estudo têm-se evidências de que com o uso do método proposto no Capítulo 3 é possível reconhecer as emoções de um indivíduo durante atividades do seu dia a dia. Além disso, pode ser observado que as informações de contexto servem para dar respaldo as informações dos sinais cerebrais, possibilitando o reconhecimento das emoções de modo mais confiável.

Tabela 5.26: Reconhecimento das emoções com base nos sinais de EEG e contexto considerando a entropia de teta

Participante	Sinais Cerebrais	Contexto	Emoções Resultantes
1	Positivo/Excitado	Positivo	Positivo/Excitado
2	Negativo/Excitado	Neutro	Negativo/Excitado
3	Negativo/Calmo	Positivo	Neutro
4	Positivo/Calmo	Positivo	Positivo/Calmo
5	Negativo/Excitado	Negativo	Negativo/Excitado
6	Negativo/Excitado	Negativo	Negativo/Excitado
7	Positivo/Calmo	Neutro	Positivo/Calmo
8	Positivo/Calmo	Positivo	Positivo/Calmo
9	Negativo/Calmo	Negativo	Negativo/Calmo
9	Negativo/Calmo	Positivo	Neutro

Tabela 5.27: Reconhecimento das emoções com base nos sinais de EEG e contexto considerando a entropia de alfa

Participante	Sinais Cerebrais	Contexto	Emoções Resultantes
1	Positivo/Excitado	Positivo	Positivo/Excitado
2	Negativo/Excitado	Neutro	Negativo/Excitado
3	Negativo/Excitado	Positivo	Neutro
4	Positivo/Calmo	Positivo	Positivo/Calmo
5	Negativo/Calmo	Negativo	Negativo/Calmo
6	Negativo/Excitado	Negativo	Negativo/Excitado
7	Positivo/Calmo	Neutro	Positivo/Calmo
8	Positivo/Excitado	Positivo	Positivo/Excitado
9	Negativo/Calmo	Negativo	Negativo/Calmo
9	Positivo/Calmo	Positivo	Positivo/Calmo

5.4 Síntese

Neste Capítulo foram discutidos os resultados obtidos com a realização das três etapas do estudo de caso. Na Seção 5.1, foram discutidos os resultados obtidos na classificação dos sinais de EEG em quatro emoções: positivo/excitado; positivo/calmo; negativo/excitado, e; negativo/calmo. A análise dos resultados foi realizada a partir da média das taxas de acertos obtidas pelos participantes do experimento para o desenvolvimento do banco de dados usado no primeiro estudo de caso. Além disso, foram considerados os verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos obtidos na classificação dos sinais. Foi observado que os melhores resultados foram obtidos com as entropias para as componentes alfa ou teta sendo usadas como entradas da rede neural.

Na Seção 5.2, foi apresentada a análise dos resultados obtidos no segundo estudo de

caso. Na análise dos dados foram definidas todas as variáveis relevantes para a caracterização do contexto. Além disso, realizou-se uma análise estatística para identificar a influência de cada uma das variáveis no contexto considerando-se o número de erros cometidos pelos participantes. Definiu-se uma expressão para o contexto que foi usada na classificação do mesmo em emoções.

Na Seção 5.3, avaliou-se o método proposto no Capítulo 3. Primeiramente, com a expressão do contexto definida na Seção 5.2, os contextos dos participantes foram classificados em emoções. Em seguida, verificou-se a relação existente entre as emoções e os erros cometidos pelos participantes e realizou-se uma análise estatística com as variáveis usadas para caracterizar o contexto. Além disso, os sinais de EEG foram classificados nas emoções: positivo/excitado; positivo/calmo; negativo/excitado, e; negativo/calmo. A análise dos resultados foi realizada a partir da média das taxas de acertos obtidas como no estudo de caso 1. Além disso, foram considerados os verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos obtidos na classificação dos sinais. Foi observado que os melhores resultados foram obtidos com as entropias para as componentes alfa ou teta sendo usadas como entradas da rede neural. Por último, foi apresentado o reconhecimento das emoções a partir dos sinais de EEG e do contexto.

Capítulo 6

Conclusões e Trabalhos Futuros

As emoções são fundamentais na qualidade do trabalho realizado por um indivíduo. Nas relações humanas, uma pessoa identifica as emoções de uma outra pessoa a partir de seu comportamento, expressões, palavras e entonação, e busca se adequar a situação. Porém, cada vez mais as relações humanas vêm sendo substituídas pelas relações homem-máquina. Seja no ambiente de trabalho ou de lazer, é frequente observar pessoas interagindo com computadores e celulares. Nesse tipo de relação, uma máquina não é capaz de interpretar o comportamento emocional de um indivíduo.

Nesse contexto, recentemente vêm sendo estudados os sistemas para o reconhecimento de emoções humanas com o objetivo de melhorar e facilitar a interação homem-máquina. Como foi visto no Capítulo 1, existem diversas fontes para detecção afetiva, como por exemplo, as expressões faciais e corporais, entonação da voz e sinais fisiológicos. A principal lacuna encontrada na computação afetiva é a ausência do contexto nos sistemas de identificação das emoções, apesar da dependência que existe entre as emoções e o contexto.

O objetivo dessa pesquisa foi introduzir um método para auxiliar no reconhecimento das emoções considerando-se dois tipos de informações, os sinais cerebrais e as informações de contexto, durante o desempenho de atividades do cotidiano. Os estudos de caso apresentados para avaliação do método foram definidos no âmbito da operação de sistemas elétricos.

6.1 Considerações

Como resultado desta pesquisa foi introduzido um método para detecção afetiva baseado nos sinais cerebrais e nas informações de contexto, que consiste na técnica para aquisição dos sinais cerebrais, algoritmos usados na seleção e classificação das características desses sinais, abordagem usada para definição de informações relevantes para o contexto, abordagem usada para caracterização do contexto e estratégia usada para classificação dos

sinais cerebrais e contexto em emoções. A definição e resolução do problema apresentado nesta tese foram realizadas em cinco etapas que são detalhadas a seguir. Ao final deste capítulo são apresentados os trabalhos futuros.

6.1.1 Desenvolvimento da Tese

O primeiro passo foi a identificação do problema. Para isso, foi realizada uma pesquisa na literatura sobre os sistemas de reconhecimento das emoções, analisando-se as principais fontes de dados usadas na detecção afetiva. Nessa análise, foram observadas as vantagens e desvantagens de cada uma das fontes e constatou-se que os sinais de EEG possuem diversas vantagens com relação as fontes apresentadas no Capítulo 1, como a não susceptibilidade à interpretação ambígua e falsas simulações; a independência de raça, gênero e idade; a disponibilidade de equipamentos portáteis e fáceis de usar; e a boa resolução temporal de aproximadamente 1 *ms*. Por essas razões, os sinais de EEG foram selecionados como fonte de informações para o reconhecimento das emoções neste trabalho. Além disso, considerando-se a fonte escolhida, investigou-se os problemas encontrados nos sistemas de detecção afetiva, sendo identificado que o principal impasse nos sistemas apresentados na literatura é que o contexto é desconsiderado no reconhecimento das emoções. Porém, as emoções são dependentes do contexto, e o contexto é essencial para a definição das emoções. Portanto, o problema identificado foi a ausência do contexto e como adicionar essas informações aos sistemas de reconhecimento de emoções.

O segundo passo foi a busca por uma solução para o problema identificado, onde optou-se pela introdução de um método para o reconhecimento das emoções a partir dos sinais cerebrais e informações de contexto. Também foi realizado um estudo para definição dos algoritmos usados para a classificação dos sinais de EEG em emoções, sendo selecionada a transformada *wavelet* para seleção das características e as redes neurais para classificação. Ainda nessa etapa, foi realizado um estudo sobre contexto, identificando as definições e abordagens para caracterização do contexto. A partir dessa pesquisa, definiu-se que as informações de contexto relevantes para o trabalho seriam determinadas com o uso da abordagem dos 5W 1H. Na caracterização do contexto, observou-se que cada informação possui uma influência diferente no contexto e, por essa razão, definiu-se o contexto como uma média ponderada das diferentes variáveis, onde o peso de cada uma delas deve ser identificado para classificação do contexto.

O terceiro passo foi a definição da abordagem usada para classificação das emoções. Nesse passo, optou-se pela classificação das características dos sinais de EEG de acordo com a abordagem bidimensional (positivo/excitado, positivo/calmo, negativo/excitado, negativo/calmo) e a classificação do contexto em positivo, negativo e neutro.

O quarto passo foi a análise para realização da fusão dos sinais de EEG com as in-

formações de contexto. Como os dados dessas duas fontes possuem diferentes resoluções, optou-se pela fusão de dados apenas na etapa de decisão, ou seja, após os sinais de EEG e as informações de contexto serem classificados em emoções, ocorre a fusão.

O quinto passo foi a definição da avaliação do método introduzido. Como o método apresentado no Capítulo 3 é composto por duas componentes (os sinais cerebrais e o contexto), foram definidos três estudos de caso para avaliação do mesmo. No primeiro estudo, a componente do método referente aos sinais cerebrais foi avaliada. Nesse estudo, foi utilizado um banco de dados de sinais de EEG como fonte de dados para analisar os algoritmos propostos para classificação dos sinais de EEG em emoções. Como discutido na Seção 4.1.3, as características alfa e teta dos sinais de EEG de trinta e dois indivíduos foram selecionadas com o algoritmo *wavelets*. Após a seleção foram calculadas a entropia e a energia de cada uma das características. Os vetores com cada um desses parâmetros foram usados na identificação das emoções positivo/excitado, positivo/calmo, negativo/excitado e negativo/calmo a partir do algoritmo redes neurais. Como resultado obteve-se aproximadamente 94 % de acurácia na classificação dos sinais de EEG em emoções considerando-se a entropia de alfa ou teta. Com esse resultado têm-se indícios de que o canal escolhido como fonte de sinais, os algoritmos utilizados e a entropia das características alfa e teta, são adequados para identificação das emoções de acordo com a abordagem bidimensional.

O objetivo com o desenvolvimento do segundo estudo de caso foi avaliar a componente do método relativa ao contexto. Para isso, o cenário escolhido foi o ambiente de trabalho de uma subestação distribuidora de energia elétrica, onde são realizadas manobras em sistemas elétricos diariamente. Durante o desempenho dessas tarefas existem riscos de ocorrer erros humanos, que podem ocasionar desde apagões de grandes regiões até acidentes mais graves, como a morte de indivíduos. Considerando esse cenário, um experimento foi realizado com seis indivíduos em um simulador que representa uma sala de operação de uma subestação. Os participantes desempenharam com o uso do simulador duas tarefas complementares realizadas durante a manutenção de um equipamento: a liberação e a normalização de um disjuntor. Para caracterização do contexto de cada um dos participantes, foram coletadas informações a partir de questionário de perfil e testes. Os dados coletados foram analisados e as variáveis relevantes para o contexto foram identificadas com a abordagem dos 5W 1H. A influência de cada uma dessas variáveis sobre o contexto foi identificada e uma expressão para o contexto foi definida. Os contextos dos participantes foram classificados nas emoções positiva, negativa e neutra. A partir dos resultados obtidos, pode-se observar que os participantes que cometeram mais erros estavam em um estado emocional negativo, como discutido na Seção 4.2.2.

No terceiro estudo de caso, avaliou-se o método proposto no Capítulo 3. O cenário

escolhido foi o mesmo usado no segundo estudo de caso, assim como as tarefas definidas para realização do experimento e as ferramentas usadas na coleta de dados. O experimento nesse estudo foi realizado com nove indivíduos, sendo que um deles desempenhou duas vezes as tarefas propostas em dias diferentes, com o objetivo de identificar as emoções de um mesmo indivíduo em contextos diferentes. Os contextos dos participantes foram obtidos a partir da expressão definida para o contexto no segundo estudo de caso e foram classificados nas emoções positiva, negativa e neutra. Com exceção de uma participante, os indivíduos cujo contexto foi classificado como uma emoção negativa cometeram mais erros do que aqueles cujo contexto foi classificado como uma emoção positiva. Além disso, para o participante que realizou o experimento duas vezes, identificou-se diferentes emoções para os diferentes contextos. Nesse estudo, os sinais cerebrais dos participantes também foram classificados em emoções de acordo com o método proposto na Seção 4.1.3. Pode-se observar a partir dos resultados obtidos que a maior parte dos participantes que tiveram seus sinais de EEG classificados como uma emoção positiva, tiveram seu contexto classificado como uma emoção positiva. Do mesmo modo, a maior parte dos participantes que tiveram seus sinais de EEG classificados como uma emoção negativa, tiveram seu contexto classificado como uma emoção negativa.

Com os resultados obtidos nos três estudos de caso, têm-se indícios de que o método proposto é uma importante contribuição na área de computação afetiva, pois como foi mostrado a partir dos estudos de caso, é possível identificar as emoções considerando-se o contexto e os sinais de EEG com a utilização do método, sendo uma informação usada para dar respaldo a outra, o que proporciona uma detecção afetiva mais confiável.

6.2 Trabalhos Futuros Sugeridos

Considerando-se as limitações encontradas nesse trabalho, são sugeridas algumas possibilidades de trabalhos futuros. Do ponto de vista do reconhecimento das emoções em atividades do cotidiano, uma limitação deste trabalho foi que os dados foram coletados e após o experimento foram analisados e classificados em emoções, portanto sugere-se que como continuidade desta pesquisa os algoritmos usados para processamento dos sinais de EEG sejam implementados em dispositivos portáteis como celulares ou *tablets* e que as informações de contexto sejam coletadas automaticamente e traduzidas em emoções com o uso desses dispositivos, de forma que o reconhecimento das emoções aconteça durante a realização da atividade.

Também propõe-se que para caracterização do contexto sejam consideradas outras variáveis, como por exemplo, para a aplicação de diferentes tarefas, examinar o uso da variável nível de dificuldade. Além disso, sugere-se que o método seja avaliado em outros

cenários, como na educação, para auxiliar no aprendizado de estudantes.

Por último, propõe-se que o método seja estendido para outras fontes de dados, substituindo-se, por exemplo, a componente sinais cerebrais pelas expressões faciais, pois o problema da ausência de contexto na computação afetiva é encontrado em sistemas de reconhecimento de emoções baseados em qualquer fonte de informação e não apenas nos sinais cerebrais

Referências Bibliográficas

- [1] DEAP dataset. <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/>. [Online; accessed 23-April-2015].
- [2] Família de wavelets daubechies. <http://ceres.ugr.es/~alumnos/sigpro/cap4.html>. [Online; accessed 23-April-2015].
- [3] Last.fm. <http://www.last.fm>. [Online; accessed 31-August-2015].
- [4] Mathworks. <http://www.mathworks.com/products/matlab/>. [Online; accessed 23-April-2015].
- [5] Modelo de regressão linear múltipla. <http://www.portalaction.com.br/analise-de-regressao/regressao-linear-multipla>. [Online; accessed 04-May-2015].
- [6] NeuroSky. <http://www.neurosky.com>. [Online; accessed 07-April-2015].
- [7] Portal Action. <http://www.portalaction.com.br>. [Online; accessed 07-May-2015].
- [8] Sistema internacional 10-10. <http://www.bem.fi/book/13/13.htm>. [Online; accessed 07-September-2015].
- [9] Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. In P. A. Hancock and N. Meshkati, editors, *Human Mental Workload*, chapter 7, pages 139–183. Elsevier, 1988.
- [10] *Emotiv Software Development Kit User Manual*, 2010.
- [11] *Emotiv Epoc - Brain Computer Interface and Scientific Contextual EEG Specifications.*, 2014.
- [12] M.K. Abd El Meguid and M.D. Levine. Fully automated recognition of spontaneous facial expressions in videos using random forest classifiers. *IEEE Transactions on Affective Computing*, 5(2):141–154, April 2014.

- [13] Yuska PC Aguiar, MFQ Vieira, Edith Galy, Jean-Marc Mercantini, and Charles Santoni. Extending a user observation protocol to account for psychological traits. In *IADIS Multi Conference on Computer Science and Information Systems*, 2011.
- [14] Fernando Alonso-Martín, María Malfaz, João Sequeira, Javier F. Gorostiza, and Miguel A. Salichs. A multimodal emotion detection system during human robot interaction. *Sensors*, 13(11):15549–15581, 2013.
- [15] A. O. Artero. *Inteligência Artificial Teoria e Prática*. EDITORA LIVRARIA DA FÍSICA, 2009.
- [16] F. Gregory Ashby, Alice M. Isen, and A. U. Turken. A neuropsychological theory of positive affect and its influence on cognition. *Psychological Review*, 106:529, 1999.
- [17] Anne Aula and Veikko Surakka. Auditory emotional feedback facilitates human-computer interaction. In Kristine Faulkner, Janet Finlay, and Françoise Détienne, editors, *People and Computers XVI - Memorable Yet Invisible*, pages 337–349. Springer London, 2002.
- [18] S. Baillet, J.C. Mosher, and R.M. Leahy. Electromagnetic brain mapping. *Signal Processing Magazine, IEEE*, 18(6):14–30, November 2001.
- [19] Marsha E. Bates and Edward P. Lemay. The D2 test of attention: Construct validity and extensions in scoring techniques. *Journal of the International Neuropsychological Society*, 10:392–400, 5 2004.
- [20] M. Beale, M. T. Hagan, and H. Demuth. Neural network toolbox. The MathWorks, Inc, 2015.
- [21] A. Bhardwaj, A. Gupta, P. Jain, A. Rani, and J. Yadav. Classification of human emotions from EEG signals using SVM and LDA classifiers. In *2nd International Conference on Signal Processing and Integrated Networks (SPIN), 2015*, pages 180–185, Feb 2015.
- [22] D. O. Bos. EEG-based emotion recognition the influence of visual and auditory stimuli. *Emotion*, 57(7):1798–806, 2006.
- [23] P.J. Brown, J.D. Bovey, and Xian Chen. Context-aware applications: from the laboratory to the marketplace. *Personal Communications, IEEE [see also IEEE Wireless Communications]*, 4(5):58–64, 1997.
- [24] C. S. Burrus, R. A. Gopinath, and H. Guo. *Introduction to Wavelets and Wavelet Transforms, A Primer*. Prentice Hall, 1998.

- [25] Paul Cairns, Pratyush Pandab, and Christopher Power. The influence of emotion on number entry errors. In *Proceedings of the 32Nd Annual ACM Conference on Human Factors in Computing Systems*, CHI '14, pages 2293–2296, New York, NY, USA, 2014. ACM.
- [26] Rafael A. Calvo and Sidney D'Mello. Affect Detection: An Interdisciplinary Review of Models, Methods, and Their Applications. *IEEE Transactions on Affective Computing*, 1(1):18–37, January 2010.
- [27] Andrew T. Campbell, Tanzeem Choudhury, Shaohan Hu, Hong Lu, Matthew K. Mukerjee, Mashfiqui Rabbi, and Rajeev D. S. Raizada. NeuroPhone: Brain-Mobile Phone Interface using a Wireless EEG Headset. In *MobiHeld 2010*. ACM, ACM, 2010.
- [28] C. Chakrabarti and M. Vishwanath. Efficient realizations of the discrete and continuous wavelet transforms: from single chip implementations to mappings on SIMD array computers. *Signal Processing, IEEE Transactions on*, 43(3):759–771, March 1995.
- [29] G. Chanel, C. Rebetz, M. Bétrancourt, and T. Pun. Emotion assessment from physiological signals for adaptation of game difficulty. *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 41(6):1052–1063, November 2011.
- [30] G. Chen and R. Hou. A new machine double-layer learning method and its application in non-linear time series forecasting. In *Mechatronics and Automation, 2007. ICMA 2007. International Conference on*, pages 795–799, August 2007.
- [31] Guey-Shya Chen and Min-Feng Lee. Detecting emotion model in e-learning system. In *International Conference on Machine Learning and Cybernetics (ICMLC), 2012*, volume 5, pages 1686–1691, 2012.
- [32] Cristina Conati and Heather Maclaren. Modeling user affect from causes and effects. In Geert-Jan Houben, Gord McCalla, Fabio Pianesi, and Massimo Zancanaro, editors, *User Modeling, Adaptation, and Personalization*, volume 5535 of *Lecture Notes in Computer Science*, pages 4–15. Springer Berlin Heidelberg, 2009.
- [33] A.V. da Silva Netto and M. de Fatima Queiroz Vieira. Virtual reality training environment a proposed architecture. In *IEEE International Conference on Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS), 2010*, pages 77–81, Sept 2010.

- [34] A. Damásio. *O Mistério da consciência: do corpo e das emoções ao conhecimento de si*. Companhia Das Letras, 2002.
- [35] I. Daubechies. *Ten Lectures on Wavelets*. Number 61. pub-siam, 1992.
- [36] Anind K. Dey. Context-aware computing: The cyberdesk project. In *AAAI 1998 Spring Symposium on Intelligent Environments*, pages 51–54, Palo Alto, 1998. AAAI Press.
- [37] Anind K. Dey and G. D. Abowd. Towards a better understanding of context and context-awareness. In *Computer Human Intraction 2000 Workshop on the What, Who, Where, When, Why and How of Context-Awareness*, 2000.
- [38] K. Dong, S. Ahn, S. Park, and M. Whang. Interactive emotional lighting system using physiological signals. *IEEE Transactions on Consumer Electronics*, 59(4):765–771, November 2013.
- [39] Chen Dongwei, Wu Fang, Wang Zhen, Li Haifang, and Chen Junjie. EEG-based emotion recognition with brain network using independent components analysis and granger causality. In *International Conference on Computer Medical Applications (ICCMA), 2013*, pages 1–6, 2013.
- [40] Ruo-Nan Duan, Jia-Yi Zhu, and Bao-Liang Lu. Differential entropy feature for EEG-based emotion classification. In *6th International IEEE/EMBS Conference on Neural Engineering (NER), 2013*, pages 81–84, Nov 2013.
- [41] R. Dubey and A. Pathak. Digital analysis of EEG brain signal. *Journal Webmed-Central BRAIN*, 11(1), 2010.
- [42] Matthieu Duvinage, Thierry Castermans, Mathieu Petieau, Thomas Hoellinger, Guy Cheron, and Thierry Dutoit. Performance of the emotiv epoc headset for P300-based applications. *BioMedical Engineering OnLine*, 12(1), 2013.
- [43] M. Fatourechí, A. Bashashati, R. K. Ward, and G. E. Birch. EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical Neurophysiology*, 118(3):480 – 494, 2007.
- [44] T. F. Filho, R. C. Costa, and M. F. Q. Vieira. Ambiente para o treinamento de operadores em painéis e supervisorío apoiado por um módulo tutor. In *Anais do X Simpósio Brasileiro de Automação Inteligente*, pages 857–862, 2011.

- [45] B. L. Fredrickson. Extracting meaning from past affective experiences: the importance of peaks, ends, and specific emotions. *Cognition and Emotion*, 14(4):577–606, 2000.
- [46] J. M. Fuster. The prefrontal cortex - an update: Time is of the essence. *Neuron*, 30(2):319 – 333, 2001.
- [47] J. M. Fuster. Chapter 4 - animal neuropsychology. In J. M. Fuster, editor, *The Prefrontal Cortex (Fourth Edition)*, pages 125 – 170. Academic Press, San Diego, fourth edition edition, 2008.
- [48] S.S. HAYKIN. *Redes Neurais - 2ed.* BOOKMAN COMPANHIA ED, 2001.
- [49] Pari Jahankhani, Vassilis Kodogiannis, and Kenneth Revett. EEG signal classification using wavelet feature extraction and neural networks. In *Proceedings of the IEEE John Vincent Atanasoff 2006 International Symposium on Modern Computing*, pages 120–124, Washington, DC, USA, 2006. IEEE Computer Society.
- [50] Raj Jain. *The art of computer systems performance analysis - techniques for experimental design, measurement, simulation, and modeling.* Wiley professional computing. Wiley, 1991.
- [51] S. Jang. *Implementation of Context-Aware Application Model in Smart Environments.* Phd thesis, Gwangju Institute of Science and Technology, 2005.
- [52] Zhaohui Jiang, Lili Lu, Xiaowei Huang, and Chunjie Tan. Design of wearable home health care system with emotion recognition function. In *International Conference on Electrical and Control Engineering (ICECE), 2011*, pages 2995–2998, 2011.
- [53] Suwicha Jirayucharoensak, Setha Pan-Ngum, and Pasin Israsena. EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation. *The Scientific World Journal*, 2014, 2014.
- [54] A. Kandaswamy, C.Sathish Kumar, Rm.Pl. Ramanathan, S. Jayaraman, and N. Malmurugan. Neural classification of lung sounds using wavelet coefficients. *Computers in Biology and Medicine*, 34(6):523 – 537, 2004.
- [55] Y. Kazuki and H. Tsunashima. Development of portable brain-computer interface using NIRS. In *International Conference on Control, 2014 UKACC*, pages 702–707, July 2014.
- [56] Jeong-Dong Kim, Jiseong Son, and Doo-Kwon Baik. Ca5w1honto: Ontological context-aware model based on 5w1h. *IJDSN*, 2012, 2012.

- [57] M.Kemal Kiymik, Inan Güler, Alper Dizibüyük, and Mehmet Akin. Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application. *Computers in Biology and Medicine*, 35(7):603 – 616, 2005.
- [58] A. Kleinsmith and N. Bianchi-Berthouze. Affective body expression perception and recognition: A survey. *IEEE Transactions on Affective Computing*, 4(1):15–33, Jan 2013.
- [59] Kwang-Eun Ko, Hyun-Chang Yang, and Kwee-Bo Sim. Emotion recognition using EEG signals with relative power values and Bayesian network. *International Journal of Control, Automation and Systems*, 7(5):865–870, October 2009.
- [60] S. Koelstra, C. Muehl, M. Soleymani, J. S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt, and I. Patras. DEAP: A database for emotion analysis using physiological signals. *IEEE Transaction on Affective Computing, Special Issue on Naturalistic Affect Resources for System Building and Evaluation*, 2006. in press.
- [61] Roman Krepki. *Design and implementation of an online BCI system for the control in gaming applications and virtual limbs*. PhD dissertation, Berlin University, Department of Electrical engineering and computer science, Nov 2004.
- [62] Andrea Kubler and Klaus-Robert Muller. *Toward Brain-Computer Interfacing*, chapter An Introduction to Brain-Computer Interfacing, pages 1 – 25. The MIT Press, 2007.
- [63] C. Kyoung ho and M. Sasaki. EEG data classification with several mental tasks. In *Systems, Man and Cybernetics, 2002 IEEE International Conference on*, volume 6, pages 4 pp. vol.6–, October 2002.
- [64] T. N. Lal, T. Hinterberger, G. Widman, M. Schröder, J. Hill, W. Rosenstiel, C. E. Elger, B. Schölkopf, and N. Birbaumer. Methods towards invasive human brain computer interfaces. In *IN ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS 17*, pages 737–744. MIT Press, 2005.
- [65] Peter J. Lang, Margaret M. Bradley, and B. N. Cuthbert. International affective picture system (IAPS): Affective ratings of pictures and instruction manual. Technical Report A-8, The Center for Research in Psychophysiology, University of Florida, Gainesville, FL, 2008.

- [66] Peter J. Lang, Mark K. Greenwald, Margaret M. Bradley, and Alfons O. Hamm. Looking at pictures: Affective, facial, visceral, and behavioral reactions. *Psychophysiology*, 30(3):261–273, 1993.
- [67] Haifang Li, Xiaoyan Qiao, Junjie Chen, and Jie Xiang. The study of data analysis methods based on fMRI brain-computer interface. In *IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA), 2010*, pages 989–993, Sept 2010.
- [68] Youn-Kyung Lim, Justin Donaldson, Heekyoung Jung, Breanne Kunz, David Royer, Shruti Ramalingam, Sindhia Thirumaran, and Erik Stolterman. Affect and emotion in human-computer interaction. chapter Emotional Experience and Interaction Design, pages 116–129. Springer-Verlag, Berlin, Heidelberg, 2008.
- [69] Chin-Teng Lin, Lun-De Liao, Yu-Hang Liu, I-Jan Wang, Bor-Shyh Lin, and Jyh-Yeong Chang. Novel dry polymer foam electrodes for long-term EEG measurement. *IEEE Transactions on Biomedical Engineering*, 58(5):1200–1207, May 2011.
- [70] Changchun Liu, Karla Conn, Nilanjan Sarkar, and Wendy Stone. Physiology-based affect recognition for computer-assisted intervention of children with autism spectrum disorder. *Int. J. Hum.-Comput. Stud.*, 66:662–677, September 2008.
- [71] Changchun Liu, P. Rani, and N. Sarkar. An empirical study of machine learning techniques for affect recognition in human-robot interaction. In *IEEE/RSJ International Conference on Intelligent Robots and Systems, 2005. (IROS 2005). 2005*, pages 2662–2667, 2005.
- [72] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi. A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 4:24, 2007.
- [73] A.B.M. Machado. *Neuroanatomia funcional*. Biblioteca biomédica : Série morfológica. Livraria Atheneu, 2000.
- [74] S.G. Mallat. A theory for multiresolution signal decomposition: the wavelet representation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 11(7):674–693, July 1989.
- [75] D. J. McFarland, L. M. McCane, S. V. David, and J. R. Wolpaw. Spatial filter selection for EEG-based communication. *Electroencephalography and Clinical Neurophysiology*, 103(3):386 – 394, 1997.

- [76] M. Misiti, Y. Misiti, G. Oppenheim, and J.-M. Poggi. Wavelet toolbox. The MathWorks, Inc, 2008.
- [77] M. Murugappan and S. Murugappan. Human emotion recognition through short time electroencephalogram (eeg) signals using fast fourier transform (fft). In *IEEE 9th International Colloquium on Signal Processing and its Applications (CSPA), 2013*, pages 289–294, March 2013.
- [78] M. Murugappan, R. Nagarajan, and S. Yaacob. Appraising human emotions using time frequency analysis based EEG alpha band features. In *Innovative Technologies in Intelligent Systems and Industrial Applications, 2009. CITISIA 2009*, pages 70–75, july 2009.
- [79] M. Murugappan, M. Rizon, R. Nagarajan, and S. Yaacob. EEG feature extraction for classifying emotions using FCM and FKM. In *Proceedings of the 7th WSEAS International Conference on Applied Computer and Applied Computational Science, ACACOS'08*, pages 299–304, Stevens Point, Wisconsin, USA, 2008. World Scientific and Engineering Academy and Society (WSEAS).
- [80] J. A. N. Neto, M. F. Q. Vieira, C. Santoni, and D. Scherer. Proposing strategies to prevent the human error in automated industrial environments. In DylanD. Schmorow, IvyV. Estabrooke, and Marc Grootjen, editors, *Foundations of Augmented Cognition. Neuroergonomics and Operational Neuroscience*, volume 5638 of *Lecture Notes in Computer Science*, pages 279–288. Springer Berlin Heidelberg, 2009.
- [81] L. F. Nicolas-Alonso and J. Gomez-Gil. Brain computer interfaces, a review. *Sensors*, 12(2):1211–1279, 2012.
- [82] Cheonshu Park, Jungwoo Ryu, Joochan Sohn, and Hyunkyung Cho. An emotion expression system for the emotional robot. In *IEEE International Symposium on Consumer Electronics, 2007. ISCE 2007.*, pages 1–6, 2007.
- [83] S. Paul, A. Mazumder, P. Ghosh, D.N. Tibarewala, and G. Vimalarani. EEG based emotion recognition system using MFDFFA as feature extractor. In *International Conference on Robotics, Automation, Control and Embedded Systems (RACE), 2015*, pages 1–5, Feb 2015.
- [84] M.B. Perkusich, T.S. Rached, and A. Perkusich. ThinkContacts: Use your mind to dial your phone. In *IEEE International Conference on Consumer Electronics (ICCE), 2011*, pages 105–106, Jan 2011.

- [85] K.L. Phan, T. Wager, S. F. Taylor, and I. Liberzon. Functional neuroanatomy of emotion: A meta-analysis of emotion activation studies in PET and fMRI. *NeuroImage*, 16(2):331 – 348, 2002.
- [86] D. M. W. Powers. Evaluation: From precision, recall and f-measure to roc., informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1):37–63, 2011.
- [87] F. Provost and R. Kohavi. On applied research in machine learning. In *Machine learning*, pages 127–132, 1998.
- [88] T. Rached, F. Torres, Y. Aguiar, M.F.Q. Vieira, and A. Perkusich. Fatigue and emotions driven products: Assessing safety and performance using mobile devices. In *IEEE International Conference on Consumer Electronics (ICCE), 2014*, pages 496–497, Jan 2014.
- [89] Taciana Saad Rached and Angelo Perkusich. *Brain-Computer Interface Systems - Recent Progress and Future Prospects*, chapter Emotion Recognition Based on Brain-Computer Interface Systems, pages 253–268. InTech, 2013.
- [90] T.S. Rached, D.F. de S Santos, A. Perkusich, H. Almeida, and M.M. de Almeida Holanda. BCI-aware pervasive multimedia for motor disabled people. In *International Conference on Information Society (i-Society), 2010*, pages 86–91, 2010.
- [91] T.S. Rached, D.F. S. Santos, A. Perkusich, and H. Almeida. Controlling interactive digital television applications by brain-computer interface. In *8th European Conference on Interactive TV and Video, ACM*, pages 71–74, june 2010.
- [92] T.S. Rached, D.F. S. Santos, A. Perkusich, and H. Almeida. Sistemas interface cérebro-computador pervasivos multimídia para pessoas com deficiências motoras severas. In *Congresso Brasileiro de Informática na Saúde*, pages 51–53, 2010.
- [93] Osvaldo A. Rosso, Susana Blanco, Juliana Yordanova, Vasil Kolev, Alejandra Figliola, Martin Schürmann, and Erol Basar. Wavelet entropy: a new tool for analysis of short duration brain electrical signals. *Journal of Neuroscience Methods*, 105(1):65 – 75, 2001.
- [94] J. A. Russell. Core affect and the psychological construction of emotion. *Psychological Review*, pages 145–172, 2003.
- [95] N. Ryan, J. Pascoe, and D. Morse. Enhanced reality fieldwork: the context-aware archaeological assistant. In V. Gaffney, M. van Leusen, and S. Exxon, editors,

- Computer Applications and Quantitative Methods in Archaeology (CAA 97)*, Oxford, 1997.
- [96] M. B. Naghibi-Sistani S. A. Hosseini. Emotion recognition method using entropy analysis of eeg signals. *IJIGSP*, 3(5):30–36, 2011.
- [97] N.I. Sabra and M. Wahed. The use of MEG-based brain computer interface for classification of wrist movements in four different directions. In *28th National Radio Science Conference (NRSC), 2011*, pages 1–7, April 2011.
- [98] Gerwin Schalk and Jürgen Mellinger. Brain sensors and signals. In *A Practical Guide to Brain-Computer Interfacing with BCI2000*, pages 9–35. Springer London, 2010.
- [99] K Scherer. What are emotions? and how can they be measured? *Social Science Information*, January 2005.
- [100] B. N. Schilit and M. M. Theimer. Disseminating active map information to mobile hosts. *Network, IEEE*, 8(5):22–32, 1994.
- [101] A. Schlogl and C. Brunner. Biosig: A free and open source software library for BCI research. *Computer*, 41(10):44–50, 2008.
- [102] G. Singh, A. Jati, A. Khasnobish, S. Bhattacharyya, A. Konar, D.N. Tibarewala, and R. Janarthanan. Negative emotion recognition from stimulated EEG signals. In *Third International Conference on Computing Communication Networking Technologies (ICCCNT), 2012*, pages 1–8, 2012.
- [103] Lindsay I Smith. *A tutorial on Principal Components Analysis*. 2002.
- [104] A. Sohaib, S. Qureshi, J. Hagelbäck, O. Hilborn, and P. Jerčić. Evaluating classifiers for emotion recognition using EEG. In D. Schmorow and C. Fidopiastis, editors, *Foundations of Augmented Cognition*, volume 8027 of *Lecture Notes in Computer Science*, pages 492–501. Springer Berlin Heidelberg, 2013.
- [105] O. Sourina and Yisi Liu. EEG-enabled affective applications. In *Humaine Association Conference on Affective Computing and Intelligent Interaction (ACII), 2013*, pages 707–708, Sept 2013.
- [106] R. Spehlmann. *EEG Primer*. Elsevier/North-Holland Biomedical, 1981.
- [107] A. Subasi. EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*, 32(4):1084 – 1093, 2007.

- [108] Emotion: Theory, research, and experience. In R. P. Kellerman, editor, *Theories of Emotion*. Academic Press, 1980.
- [109] Jianhua Tao and Tieniu Tan. Affective computing: A review. In Jianhua Tao, Tieniu Tan, and RosalindW. Picard, editors, *Affective Computing and Intelligent Interaction*, volume 3784 of *Lecture Notes in Computer Science*, pages 981–995. Springer Berlin Heidelberg, 2005.
- [110] P.P. Vaidyanathan. Generalizations of the sampling theorem: Seven decades after Nyquist. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 48(9):1094–1109, September 2001.
- [111] A.E. Vijayan, D. Sen, and A.P. Sudheer. EEG-based emotion recognition using statistical measures and auto-regressive modeling. In *IEEE International Conference on Computational Intelligence Communication Technology (CICT), 2015*, pages 587–591, Feb 2015.
- [112] A. Vinciarelli, M. Pantic, D. Heylen, C. Pelachaud, I. Poggi, F. D’Errico, and M. Schroeder. Bridging the gap between social animal and unsocial machine: A survey of social signal processing. *IEEE Transactions on Affective Computing*, 3(1):69–87, 2012.
- [113] Kunxia Wang, Ning An, Bing Nan Li, Yanyong Zhang, and Lian Li. Speech emotion recognition using Fourier parameters. *IEEE Transactions on Affective Computing*, 6(1):69–75, Jan 2015.
- [114] X.-W. Wang, D. Nie, and B.-L. Lu. Emotional state classification from EEG data using machine learning approach. *Neurocomputing*, 129:94 – 106, 2014.
- [115] Wanhui Wen, Guangyuan Liu, Nanpu Cheng, Jie Wei, P. Shanguan, and Wenjin Huang. Emotion recognition based on multi-variant correlation of physiological signals. *IEEE Transactions on Affective Computing*, 5(2):126–140, April 2014.
- [116] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 1:767–791, March 2002.
- [117] Ed Zintel. Tools and products. *Computer Graphics and Applications, IEEE*, 28(4):103 –104, july-aug. 2008.

Apêndice A

Tabela A.1: Resultados da classificação dos dados dos sinais de EEG do banco de dados 1

Característica	Parâmetro	Número de Camadas	Número de Neurônios	Técnica de Treinamento	Amostras de Teste	Amostras de Validação	Amostras de Teste	Resultados
Teta	Entropia	2	10	trainlm	70 %	15 %	15 %	55,2 %
Teta	Entropia	2	10	trainlm	40 %	30 %	30 %	43,7 %
Teta	Entropia	2	10	trainlm	50 %	25 %	25 %	48,3 %
Teta	Entropia	2	10	trainlm	60 %	20 %	20 %	54 %
Teta	Energia	2	10	trainlm	70 %	15 %	15 %	46 %
Teta	Energia	2	10	trainlm	40 %	30 %	30 %	46 %
Teta	Energia	2	10	trainlm	50 %	25 %	25 %	48,3 %
Teta	Energia	2	10	trainlm	60 %	20 %	20 %	49,4 %
Alfa	Entropia	2	10	trainlm	70 %	15 %	15 %	55,2 %
Alfa	Entropia	2	10	trainlm	40 %	30 %	30 %	49,4 %
Alfa	Entropia	2	10	trainlm	50 %	25 %	25 %	48,3 %
Alfa	Entropia	2	10	trainlm	60 %	20 %	20 %	46 %
Alfa	Energia	2	10	trainlm	70 %	15 %	15 %	58,6 %
Alfa	Energia	2	10	trainlm	40 %	30 %	30 %	48,3 %
Alfa	Energia	2	10	trainlm	50 %	25 %	25 %	51,7 %
Alfa	Energia	2	10	trainlm	60 %	20 %	20 %	50,6 %

Teta	Entropia	2	10	trainbr	70 %	15 %	15 %	47,1 %
Teta	Entropia	2	10	trainbr	40 %	30 %	30 %	50,6 %
Teta	Entropia	2	10	trainbr	50 %	25 %	25 %	42,5 %
Teta	Entropia	2	10	trainbr	60 %	20 %	20 %	48,3 %
Teta	Energia	2	10	trainbr	70 %	15 %	15 %	33,3 %
Teta	Energia	2	10	trainbr	40 %	30 %	30 %	33,3 %
Teta	Energia	2	10	trainbr	50 %	25 %	25 %	33,3 %
Teta	Energia	2	10	trainbr	60 %	20 %	20 %	39,1 %
Alfa	Entropia	2	10	trainbr	70 %	15 %	15 %	50,6 %
Alfa	Entropia	2	10	trainbr	40 %	30 %	30 %	33,3 %
Alfa	Entropia	2	10	trainbr	50 %	25 %	25 %	48,3 %
Alfa	Entropia	2	10	trainbr	60 %	20 %	20 %	48,3 %
Alfa	Energia	2	10	trainbr	70 %	15 %	15 %	51,7 %
Alfa	Energia	2	10	trainbr	40 %	30 %	30 %	33,3 %
Alfa	Energia	2	10	trainbr	50 %	25 %	25 %	47,1 %
Alfa	Energia	2	10	trainbr	60 %	20 %	20 %	49,4 %
Teta	Entropia	2	10	trainrp	70 %	15 %	15 %	55,2 %
Teta	Entropia	2	10	trainrp	40 %	30 %	30 %	48,3 %
Teta	Entropia	2	10	trainrp	50 %	25 %	25 %	50,6 %
Teta	Entropia	2	10	trainrp	60 %	20 %	20 %	50,6 %
Teta	Energia	2	10	trainrp	70 %	15 %	15 %	48,3 %
Teta	Energia	2	10	trainrp	40 %	30 %	30 %	39,1 %
Teta	Energia	2	10	trainrp	50 %	25 %	25 %	41,4 %
Teta	Energia	2	10	trainrp	60 %	20 %	20 %	40,2 %
Alfa	Entropia	2	10	trainrp	70 %	15 %	15 %	47,1 %
Alfa	Entropia	2	10	trainrp	40 %	30 %	30 %	56,3 %
Alfa	Entropia	2	10	trainrp	50 %	25 %	25 %	52,9 %
Alfa	Entropia	2	10	trainrp	60 %	20 %	20 %	50,6 %
Alfa	Energia	2	10	trainrp	70 %	15 %	15 %	56,3 %
Alfa	Energia	2	10	trainrp	40 %	30 %	30 %	52,9 %
Alfa	Energia	2	10	trainrp	50 %	25 %	25 %	52,9 %
Alfa	Energia	2	10	trainrp	60 %	20 %	20 %	50,6 %

Teta	Entropia	2	20	trainrp	70 %	15 %	15 %	51,7 %
Teta	Entropia	2	20	trainrp	40 %	30 %	30 %	54 %
Teta	Entropia	2	20	trainrp	50 %	25 %	25 %	49,1 %
Teta	Entropia	2	20	trainrp	60 %	20 %	20 %	54 %
Teta	Energia	2	20	trainrp	70 %	15 %	15 %	43,7 %
Teta	Energia	2	20	trainrp	40 %	30 %	30 %	42,5 %
Teta	Energia	2	20	trainrp	50 %	25 %	25 %	47,1 %
Teta	Energia	2	20	trainrp	60 %	20 %	20 %	51,7 %
Alfa	Entropia	2	20	trainrp	70 %	15 %	15 %	50,6 %
Alfa	Entropia	2	20	trainrp	40 %	30 %	30 %	51,7 %
Alfa	Entropia	2	20	trainrp	50 %	25 %	25 %	49,1 %
Alfa	Entropia	2	20	trainrp	60 %	20 %	20 %	51,7 %
Alfa	Energia	2	20	trainrp	70 %	15 %	15 %	57,5 %
Alfa	Energia	2	20	trainrp	40 %	30 %	30 %	49,4 %
Alfa	Energia	2	20	trainrp	50 %	25 %	25 %	45,5 %
Alfa	Energia	2	20	trainrp	60 %	20 %	20 %	55,2 %
Teta	Entropia	2	30	trainrp	70 %	15 %	15 %	51,7 %
Teta	Entropia	2	30	trainrp	60 %	20 %	20 %	52,9 %
Teta	Energia	2	30	trainrp	70 %	15 %	15 %	54 %
Teta	Energia	2	30	trainrp	60 %	20 %	20 %	51,7 %
Alfa	Entropia	2	30	trainrp	70 %	15 %	15 %	56,3 %
Alfa	Entropia	2	30	trainrp	60 %	20 %	20 %	55,2 %
Alfa	Energia	2	30	trainrp	70 %	15 %	15 %	57,5 %
Alfa	Energia	2	30	trainrp	60 %	20 %	20 %	55,2 %
Teta	Entropia	2	40	trainrp	70 %	15 %	15 %	56,3 %
Teta	Entropia	2	40	trainrp	60 %	20 %	20 %	60,9 %
Teta	Energia	2	40	trainrp	70 %	15 %	15 %	54 %
Teta	Energia	2	40	trainrp	60 %	20 %	20 %	51,7 %
Alfa	Entropia	2	40	trainrp	70 %	15 %	15 %	57,5 %
Alfa	Entropia	2	40	trainrp	60 %	20 %	20 %	55,2 %
Alfa	Energia	2	40	trainrp	70 %	15 %	15 %	62,1 %
Alfa	Energia	2	40	trainrp	60 %	20 %	20 %	51,7 %

Teta	Entropia	3	30	trainrp	70 %	15 %	15 %	54 %
Teta	Entropia	3	30	trainrp	60 %	20 %	20 %	56,3 %
Teta	Energia	3	30	trainrp	70 %	15 %	15 %	46 %
Teta	Energia	3	30	trainrp	60 %	20 %	20 %	48,3 %
Alfa	Entropia	3	30	trainrp	70 %	15 %	15 %	52,9 %
Alfa	Entropia	3	30	trainrp	60 %	20 %	20 %	51,7 %
Alfa	Energia	3	30	trainrp	70 %	15 %	15 %	55,2 %
Alfa	Energia	3	30	trainrp	60 %	20 %	20 %	60,9 %
Teta	Entropia	3	40	trainrp	70 %	15 %	15 %	55,2 %
Teta	Entropia	3	40	trainrp	60 %	20 %	20 %	54 %
Teta	Energia	3	40	trainrp	70 %	15 %	15 %	55,2 %
Teta	Energia	3	40	trainrp	60 %	20 %	20 %	55,2%
Alfa	Entropia	3	40	trainrp	70 %	15 %	15 %	58,6 %
Alfa	Entropia	3	40	trainrp	60 %	20 %	20 %	63,2 %
Alfa	Energia	3	40	trainrp	70 %	15 %	15 %	64,4 %
Alfa	Energia	3	40	trainrp	60 %	20 %	20 %	58,6 %
Teta	Entropia	4	30	trainrp	70 %	15 %	15 %	50,6 %
Teta	Entropia	4	30	trainrp	60 %	20 %	20 %	51,7 %
Teta	Energia	4	30	trainrp	70 %	15 %	15 %	39,1 %
Teta	Energia	4	30	trainrp	60 %	20 %	20 %	46 %
Alfa	Entropia	4	30	trainrp	70 %	15 %	15 %	50,6 %
Alfa	Entropia	4	30	trainrp	60 %	20 %	20 %	49,4 %
Alfa	Energia	4	30	trainrp	70 %	15 %	15 %	49,4 %
Alfa	Energia	4	30	trainrp	60 %	20 %	20 %	47,1 %
Teta	Entropia	4	40	trainrp	70 %	15 %	15 %	54 %
Teta	Entropia	4	40	trainrp	60 %	20 %	20 %	60,9 %
Teta	Energia	4	40	trainrp	70 %	15 %	15 %	48,3 %
Teta	Energia	4	40	trainrp	60 %	20 %	20 %	46%
Alfa	Entropia	4	40	trainrp	70 %	15 %	15 %	55,2 %
Alfa	Entropia	4	40	trainrp	60 %	20 %	20 %	51,7 %
Alfa	Energia	4	40	trainrp	70 %	15 %	15 %	52,9 %
Alfa	Energia	4	40	trainrp	60 %	20 %	20 %	50,6 %

Apêndice B

Tabela B.1: Resultados do indivíduo 1 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	62,5 %	70 %	100 %	91,7 %	82,5 %
Teta	Energia	62,5 %	70 %	80 %	100 %	78,12 %
Alfa	Entropia	75 %	90 %	90 %	100 %	88,75 %
Alfa	Energia	75 %	60 %	70 %	83,3 %	72,07 %

Tabela B.2: Resultados do indivíduo 2 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	0 %	90 %	58,3 %	60 %
Teta	Energia	75 %	70 %	60 %	83,3 %	72,07 %
Alfa	Entropia	87,5 %	50 %	0 %	91,7 %	57,3 %
Alfa	Energia	75 %	80 %	40 %	100 %	73,75 %

Tabela B.3: Resultados do indivíduo 3 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	50 %	60 %	80 %	83,3 %	70 %
Teta	Energia	50 %	80 %	50 %	91,7 %	67,92 %
Alfa	Entropia	75 %	90 %	90 %	83,3 %	84,58 %
Alfa	Energia	87,5 %	80 %	80 %	66,7 %	78,55 %

Tabela B.4: Resultados do indivíduo 4 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	50 %	90 %	100 %	58,3 %	75 %
Teta	Energia	50 %	70 %	0 %	83,3 %	50,82 %
Alfa	Entropia	75 %	90 %	80 %	91,7 %	84,18 %
Alfa	Energia	50 %	40 %	30 %	100 %	55 %

Tabela B.5: Resultados do indivíduo 5 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	0 %	60 %	66,7 %	50 %
Teta	Energia	100 %	50 %	90 %	75 %	78,75 %
Alfa	Entropia	87,5 %	80 %	90 %	83,3 %	85,2 %
Alfa	Energia	75 %	60 %	70 %	83,3 %	72,08 %

Tabela B.6: Resultados do indivíduo 6 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	60 %	80 %	50 %	70 %
Teta	Energia	37,5 %	70 %	90 %	83,3 %	70,2 %
Alfa	Entropia	75 %	100 %	90 %	83,3 %	87,08 %
Alfa	Energia	50 %	100 %	50 %	91,7 %	72,92 %

Tabela B.7: Resultados do indivíduo 7 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	87,5 %	90 %	60 %	58,3 %	72,5 %
Teta	Energia	50 %	80 %	80 %	91,7 %	75,42 %
Alfa	Entropia	87,5 %	100 %	90 %	91,7 %	92,3 %
Alfa	Energia	25 %	80 %	40 %	50 %	48,75 %

Tabela B.8: Resultados do indivíduo 8 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	90 %	90 %	100 %	90 %
Teta	Energia	75 %	60 %	40 %	91,7 %	66,68 %
Alfa	Entropia	50 %	70 %	70 %	66,7 %	64,18 %
Alfa	Energia	87,5 %	60 %	50 %	83,3 %	70,2 %

Tabela B.9: Resultados do indivíduo 9 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	87,5 %	90 %	100 %	83,3 %	90 %
Teta	Energia	37,5 %	50 %	60 %	50 %	49,38 %
Alfa	Entropia	87,5 %	100 %	90 %	100 %	94,38 %
Alfa	Energia	62,5 %	60 %	90 %	58,3 %	67,7 %

Tabela B.10: Resultados do indivíduo 10 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	80 %	40 %	83,3 %	70 %
Teta	Energia	100 %	20 %	90 %	83,3 %	73,32 %
Alfa	Entropia	87,5 %	90 %	90 %	91,7 %	89,8 %
Alfa	Energia	87,5 %	70 %	60 %	91,7 %	77,3 %

Tabela B.11: Resultados do indivíduo 11 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	37,5 %	70 %	50 %	75 %	60 %
Teta	Energia	100 %	40 %	70 %	58,3 %	67,08 %
Alfa	Entropia	87,5 %	100 %	90 %	91,7 %	92,3 %
Alfa	Energia	50 %	30 %	90 %	66,7 %	59,18 %

Tabela B.12: Resultados do indivíduo 12 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	50 %	50 %	80 %	91,7 %	70 %
Teta	Energia	50 %	80 %	40 %	83,3 %	63,32 %
Alfa	Entropia	75 %	100 %	80 %	100 %	88,75 %
Alfa	Energia	62,5 %	60 %	80 %	91,7 %	73,55 %

Tabela B.13: Resultados do indivíduo 13 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	60 %	90 %	91,7 %	80 %
Teta	Energia	62,5 %	60 %	80 %	66,7 %	67,3 %
Alfa	Entropia	100 %	80 %	90 %	91,7 %	90,42 %
Alfa	Energia	50 %	60 %	90 %	75 %	68,75 %

Tabela B.14: Resultados do indivíduo 14 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	30 %	90 %	83,3 %	70 %
Teta	Energia	25 %	80 %	70 %	83,3 %	64,58 %
Alfa	Entropia	87,5 %	80 %	90 %	83,3 %	85,2 %
Alfa	Energia	62,5 %	90 %	90 %	75 %	79,38 %

Tabela B.15: Resultados do indivíduo 15 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	90 %	100 %	83,3 %	92,5 %
Teta	Energia	50 %	80 %	10 %	83,3 %	55,82 %
Alfa	Entropia	87,5 %	90 %	100 %	83,3 %	90,2 %
Alfa	Energia	50 %	80 %	100 %	83,3 %	78,32 %

Tabela B.16: Resultados do indivíduo 16 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	80 %	90 %	91,7 %	90 %
Teta	Energia	87,5 %	0 %	50 %	83,3 %	55,2 %
Alfa	Entropia	75 %	100 %	90 %	91,7 %	89,18 %
Alfa	Energia	75 %	90 %	70 %	83,3 %	79,58 %

Tabela B.17: Resultados do indivíduo 17 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	87,5 %	100 %	100 %	91,7 %	95 %
Teta	Energia	75 %	40 %	90 %	91,7 %	74,18 %
Alfa	Entropia	100 %	100 %	90 %	91,7 %	95,42 %
Alfa	Energia	25 %	60 %	20 %	83,3 %	47,08 %

Tabela B.18: Resultados do indivíduo 18 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	80 %	80 %	83,3 %	85 %
Teta	Energia	37,5 %	50 %	70 %	75 %	58,12 %
Alfa	Entropia	87,5 %	80 %	90 %	100 %	89,38 %
Alfa	Energia	37,5 %	0 %	100 %	66,7 %	55,05 %

Tabela B.19: Resultados do indivíduo 19 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	90 %	80 %	83,3 %	82,5 %
Teta	Energia	75 %	70 %	100 %	66,7 %	77,92 %
Alfa	Entropia	75 %	90 %	90 %	83,3 %	84,58 %
Alfa	Energia	62,5 %	40 %	40 %	91,7 %	58,55 %

Tabela B.20: Resultados do indivíduo 20 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	100 %	50 %	83,3 %	77,5 %
Teta	Energia	50 %	100 %	40 %	75 %	66,25 %
Alfa	Entropia	100 %	90 %	90 %	91,7 %	92,92 %
Alfa	Energia	50 %	100 %	90 %	75 %	78,75 %

Tabela B.21: Resultados do indivíduo 21 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	87,5 %	60 %	80 %	75 %	75 %
Teta	Energia	62,5 %	70 %	90 %	83,3 %	76,45 %
Alfa	Entropia	87,5 %	100 %	80 %	91,7 %	89,8 %
Alfa	Energia	50 %	100 %	90 %	83,3 %	80,82 %

Tabela B.22: Resultados do indivíduo 22 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	87,5 %	80 %	80 %	50 %	72,5 %
Teta	Energia	75 %	30 %	90 %	83,3 %	69,58 %
Alfa	Entropia	62,5 %	60 %	100 %	58,3 %	70,2 %
Alfa	Energia	62,5 %	50 %	40 %	100 %	63,12 %

Tabela B.23: Resultados do indivíduo 23 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	60 %	70 %	50 %	67,5 %
Teta	Energia	37,5 %	80 %	70 %	33,3 %	55,2 %
Alfa	Entropia	100 %	100 %	100 %	91,7 %	97,92 %
Alfa	Energia	50 %	70 %	80 %	66,7 %	66,68 %

Tabela B.24: Resultados do indivíduo 24 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	40 %	70 %	83,3 %	72,5 %
Teta	Energia	75 %	60 %	70 %	66,7 %	67,92 %
Alfa	Entropia	100 %	100 %	100 %	83,3 %	95,82 %
Alfa	Energia	62,5 %	60 %	90 %	83,3 %	73,95 %

Tabela B.25: Resultados do indivíduo 25 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	62,5 %	20 %	90 %	83,3 %	65 %
Teta	Energia	50 %	80 %	70 %	75 %	68,75 %
Alfa	Entropia	62,5 %	80 %	90 %	50 %	70,62 %
Alfa	Energia	37,5 %	90 %	100 %	83,3 %	77,7 %

Tabela B.26: Resultados do indivíduo 26 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	50 %	70 %	70 %	83,3 %	70 %
Teta	Energia	87,5 %	30 %	80 %	83,3 %	70,2 %
Alfa	Entropia	100 %	90 %	100 %	100 %	92,5 %
Alfa	Energia	87,5 %	20 %	80 %	66,7 %	63,55 %

Tabela B.27: Resultados do indivíduo 27 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	90 %	80 %	50 %	77,5 %
Teta	Energia	65 %	80 %	80 %	83,3 %	77,08 %
Alfa	Entropia	100 %	100 %	100 %	83,3 %	95,82 %
Alfa	Energia	87,5 %	20 %	60 %	75 %	60,62 %

Tabela B.28: Resultados do indivíduo 28 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	80 %	50 %	75 %	70 %
Teta	Energia	37,5 %	100 %	80 %	83,3 %	75,2 %
Alfa	Entropia	87,5 %	90 %	100 %	83,3 %	90,2 %
Alfa	Energia	37,5 %	100 %	90 %	91,7 %	79,8 %

Tabela B.29: Resultados do indivíduo 29 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	87,5 %	90 %	90 %	83,3 %	87,5 %
Teta	Energia	37,5 %	90 %	90 %	91,7 %	77,3 %
Alfa	Entropia	87,5 %	100 %	100 %	83,3 %	92,7 %
Alfa	Energia	12,5 %	90 %	90 %	83,3 %	68,95 %

Tabela B.30: Resultados do indivíduo 30 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	70 %	90 %	91,7 %	87,5 %
Teta	Energia	62,5 %	60 %	100 %	83,3 %	76,45 %
Alfa	Entropia	87,5 %	90 %	100 %	83,3 %	90,2 %
Alfa	Energia	75 %	90 %	90 %	75 %	82,5 %

Tabela B.31: Resultados do indivíduo 31 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	37,5 %	40 %	90 %	50 %	55 %
Teta	Energia	25 %	70 %	60 %	50 %	51,25 %
Alfa	Entropia	100 %	80 %	70 %	91,7 %	85,42 %
Alfa	Energia	60 %	50 %	0 %	75 %	43,75 %

Tabela B.32: Resultados do indivíduo 32 do banco de dados 2

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	60 %	20 %	33,3 %	45 %
Teta	Energia	75 %	40 %	80 %	58,3 %	63,32 %
Alfa	Entropia	87,5 %	100 %	90 %	83,3 %	90,2 %
Alfa	Energia	37,5 %	30 %	70 %	75 %	53,12 %

Apêndice C

Tabela C.1: Resultados do indivíduo 1 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	40 %	0 %	30 %	80 %	37,5 %
Teta	Energia	60 %	40 %	100 %	40 %	60 %
Alfa	Entropia	60 %	80 %	50 %	80 %	67,5 %
Alfa	Energia	40 %	80 %	40 %	100 %	65 %

Tabela C.2: Resultados do indivíduo 2 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	100 %	100 %	50 %	87,5 %
Teta	Energia	50 %	0 %	0 %	25 %	18,75 %
Alfa	Entropia	100 %	75 %	100 %	75 %	87,5 %
Alfa	Energia	25 %	25 %	0 %	25 %	18,75 %

Tabela C.3: Resultados do indivíduo 3 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	87,5 %	80 %	90 %	83,3 %	85,2 %
Teta	Energia	62,5 %	60 %	0 %	91,7 %	53,55 %
Alfa	Entropia	87,5 %	70 %	80 %	83,3 %	80,2 %
Alfa	Energia	75 %	100 %	80 %	83,3 %	84,58 %

Tabela C.4: Resultados do indivíduo 4 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	75 %	80 %	30 %	91,7 %	69,18 %
Teta	Energia	75 %	100 %	90 %	91,7 %	89,18%
Alfa	Entropia	75 %	100 %	60 %	83,3 %	79,57 %
Alfa	Energia	100 %	90 %	90 %	91,7 %	92,92 %

Tabela C.5: Resultados do indivíduo 5 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	100 %	100 %	100 %	100 %
Teta	Energia	60 %	57,1 %	100 %	75 %	73,02 %
Alfa	Entropia	100 %	100 %	100 %	87,5 %	96,88 %
Alfa	Energia	100 %	100 %	100 %	87,5 %	96,88 %

Tabela C.6: Resultados do indivíduo 6 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	100 %	100 %	100 %	100 %
Teta	Energia	100 %	20 %	50 %	100 %	67,5 %
Alfa	Entropia	100 %	100 %	60 %	100 %	90 %
Alfa	Energia	66,7 %	80 %	75 %	100 %	80,42 %

Tabela C.7: Resultados do indivíduo 7 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	85,7 %	100 %	87,5 %	93,3 %
Teta	Energia	80 %	100 %	100 %	100 %	95 %
Alfa	Entropia	100 %	100 %	83,3 %	87,5 %	92,7 %
Alfa	Energia	60 %	100 %	33,3 %	87,5 %	70,2 %

Tabela C.8: Resultados do indivíduo 8 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	100 %	100 %	100 %	100 %
Teta	Energia	100 %	100 %	66,7 %	85,7 %	88,1 %
Alfa	Entropia	100 %	85,7 %	83,3 %	100 %	92,25 %
Alfa	Energia	100 %	71,4 %	100 %	71,4 %	85,7 %

Tabela C.9: Resultados do indivíduo 9 - Exp. 1 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	0 %	75 %	66,7 %	40 %	45,42 %
Teta	Energia	33,3 %	75 %	66,7 %	75 %	62,5 %
Alfa	Entropia	33,3 %	75 %	100 %	40 %	62,08 %
Alfa	Energia	33,3 %	50 %	100 %	75 %	64,575 %

Tabela C.10: Resultados do indivíduo 9- Exp. 2 banco de dados Emotiv

Característica	Parâmetro	Excitado / Positivo	Calmo / Positivo	Excitado / Negativo	Calmo / Negativo	Média
Teta	Entropia	100 %	100 %	100 %	75 %	93,75 %
Teta	Energia	0 %	66,7 %	66,7 %	100 %	58,35 %
Alfa	Entropia	66,7 %	20 %	100 %	75 %	65,42 %
Alfa	Energia	33,3 %	33,3 %	0 %	100 %	41,65 %

Apêndice D



Laboratório de Interface Homem-Máquina

<http://lihm.dee.ufcg.edu.br/index.html>

lihm.avaliaproductos@gmail.com
(83) 2101-1387

Termo de aceitação das condições de participação no Experimento "Monitoramento do desempenho e da fadiga na operação de sistemas elétricos no ambiente SimuLIHM" **com uso de equipamentos de monitoramento de sinais biológicos e o registro de sons e imagens.**

A participação no Experimento "Monitoramento do desempenho e da fadiga na operação de sistemas elétricos no ambiente SimuLIHM" consiste no preenchimento de uma ficha de cadastro, na utilização de um equipamento para monitoramento dos sinais de EEG e ECG, durante a realização de um conjunto de tarefas no ambiente SimuLIHM, no preenchimento de questionários sobre seu nível de atenção, sua experiência e o esforço empregados durante o experimento.

As informações fornecidas pelo participante serão utilizadas apenas pela equipe de avaliadores para elaboração do diagnóstico do teste e não serão divulgadas sem seu consentimento

Eu, _____, portador do CPF/RG _____, estou ciente dos procedimentos a serem realizados durante o Experimento "Monitoramento do desempenho e da fadiga na operação de sistemas elétricos no ambiente SimuLIHM" e, concordo em participar nestas condições.

Declaro que **autorizo a utilização das imagens e sons registrados** durante as sessões do teste de usabilidade conduzidos pela equipe de avaliadores do LIHM – Laboratório de Interfaces Homem-Máquina. Saliento que tais imagens e sons poderão ser utilizados para fins de análise de dados e geração de relatórios acadêmicos.

Campina Grande, ____ de _____ de _____.

Assinatura



Laboratório de Interface Homem-Máquina

<http://lihm.dee.ufcg.edu.br/index.html>
55 (83) 2101-1387

Experimento: Monitoramento do desempenho e da fadiga na operação de sistemas elétricos

Sessão de Teste:

Data:

Usuário participante:

Questionário Pré-Teste	
Gênero:	() Masculino () Feminino
Idade:	
Uso de lentes corretivas	() Sim () Não
Formação	Área: Nível:
Nível de conhecimento no contexto de operação de sistemas elétricos	() Baixo () Médio () Alto
Nível de conhecimento na operação do SimuLIHM	() Baixo () Médio () Alto
Quantas horas (em média) você dorme por dia:	
Como você avalia seu/sua:	
Nível de curiosidade:	() Baixo () Médio () Alto
Persistência para alcançar objetivos:	() Baixa () Média () Alta
Capacidade de solucionar problemas:	() Baixa () Média () Alta
Capacidade de aprendizado, memorização e aplicação de conhecimentos:	() Baixa () Média () Alta
Senso de orientação:	() Baixo () Médio () Alto
Senso de abstração:	() Baixo () Médio () Alto
Capacidade de organização e planejamento:	() Baixa () Média () Alta
Capacidade de gestão do tempo:	() Baixa () Média () Alta
Capacidade de analisar situações:	() Baixa () Média () Alta
Capacidade de antecipar e analisar situações:	() Baixa () Média () Alta
Capacidade de tomar decisões:	() Baixa () Média () Alta

Perfil psicológico: Como você se descreve nos aspectos a seguir, no que concerne a realização de tarefas sob pressão de tempo:

Ansioso		Tranquilo	
Estressado		Relaxado	
Proativo		Reativo	
Autônomo		Dependente	
Motivado		Indiferente	

Agradecemos sua participação!

Date du test : _____ N° : _____

Nom : _____

Prénom : _____

Niveau d'études : _____

Profession : _____

Sexe


M

F

Age : _____

	NB	%	RP(Q)	NS
GZ (rythme)				
F (soin)				
GZ-F				
KL (concentration)				
SB				

F₂ = Répartition E Syndr. Û



Date _____ Numéro _____ Age _____
 Nom _____ Prénom _____ Sexe F H
 Profession _____ Niveau d'études _____

Exemple " d " d " d " d

Essai " d " p " d " d " d " p " d " d " p " d " d " d " p " p " d " " d " " p " d " d
 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22

	NB	%	RP	NS
GZ		—		
F				—
GZ - F		—		
SB		—		—
F-vert Répartition d'erreurs				

	GZ	F ₁	F ₂
1. d d p d d p p d p d d d d p d d d p p d d d p d d d p p d d d p p d d d p p d d d p			
2. p d p p d d d p d p d d d p d d p d p p d d p d d d p d d p d p d d d p d d d p d p d d			
3. d d d d p p d p d p p d d p d p d p d d p d d p d d p d d p d d p d d p d d d d p d			
4. d d p d d d p p d p d d d d d p d p d d d p p d d d d d p d p d d p p d d d d p p d p d d p			
5. p d p p d d d p d p d d d p d d p d p d p d d p d d p d d p d p d p d d d d p d d p d d			
6. d d d d p p d p d p p d d p d p d d p d d p d d p d p d p d d d p d d p d p d d d d p d			
7. d d p d d p p d p d p d d d d p d p d d d d p d d d d p d d p d d p d d d d p d p d d p			
8. p d p p d d d p d p d d d p d d p d p d p d d p d d p d d d p d p d p d p d d d d p d p d d			
9. d d d d p p d p d p p d d p d p d p d d p d d p d d p d p d d d d p d d p d d p d d d p d			
10. d d p d d d p p d p d d d d d p d p d d d p p d d d p p d d d d d p d p d d p p d d d p p d p d d			
11. p d p p d d d p d p d d d p d d p d p d p d d p d d p d d d d p d p d p d p d d d d p d p d d			
12. d d d d p p d p d p p d d p d p d p d d p d p d d p d d p d d p d d d p d d d p d d d p d			
13. d d p d d d p p d p d d d d d p d p d d d d p d d p d d p p d d d d p p d d p d d p			
14. p d p p d d d p d p d d d p d d p d d p d d p d p d d p d d d p d p d p d p d d d d p d p d d			



Laboratório de Interface Homem-Máquina

<http://lihm.dee.ufcg.edu.br/index.html>
(83) 2101-1387

Experimento: *Monitoramento do desempenho e da fadiga na operação de sistemas elétricos*

Sessão de Teste:

Data:

Usuário participante

Ficha de Observação

Tarefa 1: Liberação de disjuntor		
Tempo de realização	Início:	Fim:
Status da Tarefa	<input type="checkbox"/> Concluída com sucesso <input type="checkbox"/> Concluída com falha/erro <input type="checkbox"/> Não concluída; Abandonada; Interrompida	
Solicitação de ajuda Externa	<input type="checkbox"/> Sim <input type="checkbox"/> Não	
Estado do usuário durante a realização da tarefa	<input type="checkbox"/> Concentrado <input type="checkbox"/> Desconfortável <input type="checkbox"/> Ansioso <input type="checkbox"/> Confuso	<input type="checkbox"/> Desmotivado <input type="checkbox"/> Com fadiga física <input type="checkbox"/> Com fadiga mental <input type="checkbox"/> Outro
Observações:		
Tarefa 2: Normalização do disjuntor		
Tempo de realização	Início:	Fim:
Status da Tarefa	<input type="checkbox"/> Concluída com sucesso <input type="checkbox"/> Concluída com falha/erro <input type="checkbox"/> Não concluída; Abandonada; Interrompida	
Solicitação de ajuda Externa	<input type="checkbox"/> Sim <input type="checkbox"/> Não	
Estado do usuário durante a realização da tarefa	<input type="checkbox"/> Concentrado <input type="checkbox"/> Desconfortável <input type="checkbox"/> Ansioso <input type="checkbox"/> Confuso	<input type="checkbox"/> Desmotivado <input type="checkbox"/> Com fadiga física <input type="checkbox"/> Com fadiga mental <input type="checkbox"/> Outro
Observações:		

**Laboratório de Interface Homem-Máquina**

<http://lihm.dee.ufcg.edu.br/index.html>

(83) 2101-1387

Experimento: Monitoramento do desempenho e da fadiga na operação de sistemas elétricos

Sessão de Teste:

Data:

Usuário participante

Roteiro das Tarefas do Experimento – Avaliador**Instruções fornecidas aos participantes:**

*Este experimento reproduz a atividade de treinamento de um operador em uma sala de controle da subestação usando o simulador 3D para treinamento - SimuLIHM. Durante o experimento, você irá atuar como operador de uma subestação do sistema elétrico, durante treinamento. Normalmente, durante um turno de trabalho sem intercêrências, o operador deve executar tarefas predeterminadas de acordo com um conjunto prescrito de instruções, reproduzido neste documento. O roteiro de tarefas é extraído de um manual operacional. Durante este experimento o roteiro diz respeito a duas tarefas complementares realizadas durante a manutenção de um equipamento: **liberação** e **normalização** de um disjuntor. Durante um dia de trabalho outras tarefas podem surgir como resultado de eventos inesperados, os quais são sinalizados através de alarmes.*

*O objetivo deste trabalho é investigar a influência do nível de fadiga do operador sobre o resultado da tarefa. O nível de fadiga é investigado através do monitoramento e análise das expressões faciais, bem como da aplicação de ferramentas de psicologia, e o monitoramento de sinais biológicos (EEG e ECG). A análise dos dados coletados é confrontada com o **log da sessão**, também registrado durante o experimento.*

*A duração deste experimento, incluindo a preparação e **debriefing** é de aproximadamente duas horas. Se a qualquer momento durante o experimento que você desejar interromper ou parar a sua participação sinta-se livre para fazê-lo, avisando à equipe de pesquisa sobre sua intenção.*

- Observações:**
1. Se tiver dúvidas durante a execução das tarefas, pergunte aos pesquisadores;
 2. Caso alguma das informações solicitadas não for encontrada, avise aos pesquisadores e prossiga para a tarefa seguinte;
 3. O teste de usabilidade pode ser interrompido quando você desejar, não sendo necessário que todas as tarefas sejam realizadas.
 4. Caso se sinta à vontade, solicitamos que comente em voz alta a sua atividade e as dúvidas que possam surgir durante o teste.

Executar o roteiro de manobra

A sequência deve ser seguida para que o experimento seja realizado com sucesso.

Obs.: Caso algum alarme sonoro seja disparado durante a execução dessa manobra, interrompa a execução da etapa e desabilite o alarme, localizando o painel onde ocorreu e reconhecendo (desligar) o alarme antes de prosseguir com a tarefa a partir do ponto onde foi interrompida.

Tratamento/ reconhecimento de alarmes

Na ocorrência de um alarme sonoro você deve identificar o painel associado ao evento. Para reconhecer o alarme no painel existe uma botoeira de alarme que está localizada na parte superior do painel a qual deverá estar acesa (indicação em amarelo), após reconhecer o alarme você deve retomar a tarefa interrompida.

Tarefa 1: Liberação do Disjuntor 14V2 (com eventos estressores)

Em decorrência da substituição do Disjuntor 14D1, será necessário efetuar a transferência de carga do barramento. Nesta tarefa, o avaliador atuará como o operador do centro de operações do sistema (CROL) e você atuará como o operador da subestação SE CGD (CGD), executando as manobras descritas neste item. Anote a hora em que cada ação foi concluída. Você tem aproximadamente 20 minutos para realizar esta tarefa.

1	LIBERAÇÃO 14V2		HORA
1.1	CGD	Recebe do responsável a solicitação de liberação 14V2.	
1.2	CGD	Aguarda confirmação de autorização para liberação do 14V2.	
1.3	CROL	Autoriza CGD liberação 14V2.	
1.4	CGD	Confirma se o disjuntor 14D1, localizado no painel 04V2, está aberto.	
1.5	CGD	Fecha a chave 34V2-6, no painel 04V2	
1.6	CGD	Coloca a chave 43 -14D1 na posição 'TRANSFERÊNCIA', no painel 14D1	
Disparar um dos alarmes (pisca) no anunciador e nas lâmpadas dos painéis correspondentes			
1.7	CGD	Coloca a chave 43 -14V2 na posição 'TRANSFERÊNCIA', no painel 04V2	
Tocar o telefone			
1.8	CGD	Fecha o disjuntor 14D1, no painel 14D1	
1.9	CGD	Abre disjuntor 14V2, no painel 04V2	
Tocar o telefone (se tiver sido desligado pelo usuário)			
1.10	CGD	Colocar a chave CLT-14V2 na posição 'LOC', no painel 04V2	
1.11	CGD	Abre chaves seccionadoras 34V2-4 e 34V2-5, no painel 04V2	
1.12	CGD	Informa ao responsável (avaliador) a liberação do equipamento 14V2	

Tarefa 2: Normalização do Disjuntor 14V2

Após a substituição do equipamento, será necessário religar o disjuntor. Como já informado, o avaliador atuará como o operador do centro de operações do sistema e você atuará como o

operador da subestação SE CGD, executando as manobras descritas neste item. Anote a hora em que cada ação foi concluída. Você tem aproximadamente 20 minutos para realizar esta tarefa.

2	NORMALIZAÇÃO 14V2 (com eventos estressores)		HORA
2.1	CGD	Recebe do responsável (pesquisador) solicitação para iniciar a manobra e o 14V2 para operação	
2.2	CGD	Aguarda do CROL autorização para normalização do 14V2	
2.3	CROL	Autoriza CGD normalização 14V2	
2.4	CGD	Fecha chaves seccionadoras 34V2-4 e 34V2-5, no painel 04V2	
Disparar o alarme sonoro			
2.5	CGD	Fecha disjuntor 14V2, no painel 04V2	
2.6	CGD	Abre disjuntor 14D1, no painel 14D1	
Tocar o telefone			
2.7	CGD	Coloca a chave 43 -14V2 na posição 'NORMAL', no painel 04V2	
Disparar um dos alarmes no anunciador			
2.8	CGD	Coloca a chave 43 -14D1 na posição 'NORMAL', no painel 14D1	
2.9	CGD	Abre a chave seccionadora 34V2-6, no painel 04V2	
Disparar um dos alarmes no anunciador			
2.10	CGD	Colocar a chave CLT-14V2 na posição 'TEL', no painel 04V2	
2.11	CGD	Informa que concluiu a normalização do 14V2	

Parabéns você concluiu seu treinamento e o experimento.

Agradecemos sua participação!

**Laboratório de Interface Homem-Máquina**

<http://lihm.dee.ufcg.edu.br/index.html>

(83) 2101-1387

Experimento: Monitoramento do desempenho e da fadiga na operação de sistemas elétricos

Sessão de Teste:

Data:

Usuário participante

Roteiro das Tarefas do Experimento – Operador

*Este experimento reproduz a atividade de treinamento de um operador em uma sala de controle da subestação usando o simulador 3D para treinamento - SimuLIHM. Durante o experimento, você irá atuar como operador de uma subestação do sistema elétrico, durante treinamento. Normalmente, durante um turno de trabalho sem intercorrências, o operador deve executar tarefas predeterminadas de acordo com um conjunto prescrito de instruções, reproduzido neste documento. O roteiro de tarefas é extraído de um manual operacional. Durante este experimento o roteiro diz respeito a duas tarefas complementares realizadas durante a manutenção de um equipamento: **liberação e normalização** de um disjuntor. Durante um dia de trabalho outras tarefas podem surgir como resultado de eventos inesperados, os quais são sinalizados através de alarmes.*

*O objetivo deste trabalho é investigar a influência do nível de fadiga do operador sobre o resultado da tarefa. O nível de fadiga é investigado através do monitoramento e análise das expressões faciais, bem como da aplicação de ferramentas de psicologia, e o monitoramento de sinais biológicos (EEG e ECG). A análise dos dados coletados é confrontada com o **log da sessão**, também registrado durante o experimento.*

A duração deste experimento, incluindo a preparação e debriefing é de aproximadamente duas horas. Se a qualquer momento durante o experimento que você desejar interromper ou parar a sua participação sinta-se livre para fazê-lo, avisando à equipe de pesquisa sobre sua intenção.

- Observações:**
1. Se tiver dúvidas durante a execução das tarefas, pergunte aos pesquisadores;
 2. Caso alguma das informações solicitadas não for encontrada, avise aos pesquisadores e prossiga para a tarefa seguinte;
 3. O teste de usabilidade pode ser interrompido quando você desejar, não sendo necessário que todas as tarefas sejam realizadas.
 4. Caso se sinta à vontade, solicitamos que comente em voz alta a sua atividade e as dúvidas que possam surgir durante o teste.

Executar o roteiro de manobra

A sequência deve ser seguida para que o experimento seja realizado com sucesso.

Obs.: Caso algum alarme sonoro seja disparado durante a execução dessa manobra, interrompa a execução da etapa e desabilite o alarme, localizando o painel onde ocorreu e reconhecendo (desligar) o alarme antes de prosseguir com a tarefa a partir do ponto onde foi interrompida.

Tratamento/ reconhecimento de alarmes

Na ocorrência de um alarme sonoro você deve identificar o painel associado ao evento. Para reconhecer o alarme no painel existe uma botoeira de alarme que está localizada na parte superior do painel a qual deverá estar acesa (indicação em amarelo), após reconhecer o alarme você deve retomar a tarefa interrompida.

Tarefa1: Liberação do Disjuntor 14V2

Em decorrência da substituição do Disjuntor 14D1, será necessário efetuar a transferência de carga do barramento. Nesta tarefa, o avaliador atuará como o operador do centro de operações do sistema (CROL) e você atuará como o operador da subestação SE CGD (CGD), executando as manobras descritas neste item. Anote a hora em que cada ação foi concluída. Você tem aproximadamente 20 minutos para realizar esta tarefa.

1	LIBERAÇÃO 14V2		HORA
1.1	CGD	Recebe do responsável a solicitação de liberação 14V2.	
1.2	CGD	Aguarda confirmação de autorização para liberação do 14V2.	
1.3	CROL	Autoriza CGD liberação 14V2.	
1.4	CGD	Confirma se o disjuntor 14D1, localizado no painel 04V2, está aberto.	
1.5	CGD	Fecha a chave 34V2-6, no painel 04V2	
1.6	CGD	Coloca a chave 43 -14D1 na posição 'TRANSFERÊNCIA', no painel 14D1	
1.7	CGD	Coloca a chave 43 -14V2 na posição 'TRANSFERÊNCIA', no painel 04V2	
1.8	CGD	Fecha o disjuntor 14D1, no painel 14D1	
1.9	CGD	Abre disjuntor 14V2, no painel 04V2	
1.10	CGD	Colocar a chave CLT-14V2 na posição 'LOC', no painel 04V2	
1.11	CGD	Abre chaves seccionadoras 34V2-4 e 34V2-5, no painel 04V2	
1.12	CGD	Informa ao responsável (avaliador) a liberação do equipamento 14V2	

Tarefa 2: Normalização do Disjuntor 14V2

Após a substituição do equipamento, será necessário religar o disjuntor. Como já informado, o avaliador atuará como o operador do centro de operações do sistema e você atuará como o operador da subestação SE CGD, executando as manobras descritas neste item. Anote a hora em que cada ação foi concluída. Você tem aproximadamente 20 minutos para realizar esta tarefa.

2	NORMALIZAÇÃO 14V2		HORA
2.1	CGD	Recebe do responsável (pesquisador) solicitação para iniciar a manobra e o 14V2 para operação	
2.2	CGD	Aguarda do CROL autorização para normalização do 14V2	
2.3	CROL	Autoriza CGD normalização 14V2	
2.4	CGD	Fecha chaves seccionadoras 34V2-4 e 34V2-5, no painel 04V2	
2.5	CGD	Fecha disjuntor 14V2, no painel 04V2	
2.6	CGD	Abre disjuntor 14D1, no painel 04V2	
2.7	CGD	Coloca a chave 43 -14V2 na posição 'NORMAL', no painel 04V2	
2.8	CGD	Coloca a chave 43 -14D1 na posição 'NORMAL', no painel 14D1	
2.9	CGD	Abre a chave seccionadora 34V2-6, no painel 04V2	
2.10	CGD	Colocar a chave CLT-14V2 na posição 'TEL', no painel 04V2	
2.11	CGD	Informa que concluiu a normalização do 14V2	

Parabéns você concluiu seu treinamento e, o experimento.

Agradecemos sua participação!



Laboratório de Interface Homem-Máquina

<http://lihm.dee.ufcg.edu.br>
+ 55 (83) 2101-1387

Experimento: *Monitoramento do desempenho e da fadiga na operação de sistemas elétricos*

Sessão de Teste
Usuário participante


Data:

NASA-TLX


Como você classifica o **esforço mental** necessário para realizar a tarefa no simulador?




Como você classifica o **esforço físico** necessário para realizar a tarefa no simulador?



Como você classifica o **prazo** para concluir a tarefa?




Como você classifica a **taxa de sucesso** alcançada durante a execução da tarefa ? (Você conseguiu realizar aquilo que lhe foi solicitado no teste ?)



Como você classifica o **nível de dificuldade** para completar a tarefa?



Com qual intensidade os sentimentos combinados (**incerteza, desânimo, irritação, estresse e aborrecimento**) foram sentidos por você quando terminou a tarefa?



Agradecemos sua participação!



Laboratório de Interface Homem-Máquina


<http://lihm.dee.ufcg.edu.br>
+ 55 (83) 2101-1387

Experimento: *Monitoramento do desempenho e da fadiga na operação de sistemas elétricos*
Sessão de Teste _____ Data _____
Usuário participante _____


SAM

Como você classifica sua experiência durante a execução da tarefa nos seguintes aspectos:


Valência /
Satisfação



Despertar /
Manter a atenção



Domínio (controle)



Agradecemos sua participação !